Edukacja 2026, 3(178)
DOI 10.24131/3724.260302
e-ISSN 2449-8998

Otrzymano: **06.05.2026**
Zaakceptowano: **14.07.2026**
Dostępny online: **od 31.08.2026**

Między wsparciem a zastępowaniem – wpływ generatywnej sztucznej inteligencji na procesy poznawcze i samoregulację uczenia się

✉ ***Marcin Ślawski*** / Akademia Nauk Stosowanych im. Stanisława Staszica w Pile
e-mail: mslawski@ans.pila.pl

ORCID: 0009-0002-1527-500X

Streszczenie

Wprowadzenie: Rozwój generatywnej sztucznej inteligencji (GenAI) coraz wyraźniej zmienia warunki, w jakich przebiega uczenie się. Narzędzia te mogą wspierać pracę ucznia, ale jednocześnie pojawiają się poważne wątpliwości dotyczące ich wpływu na wysiłek poznawczy i jakość przetwarzania informacji. **Cel badań:** Celem artykułu jest uporządkowanie wyników badań dotyczących wykorzystania generatywnej sztucznej inteligencji w edukacji, głównie pod kątem wpływu na procesy poznawcze i samoregulację uczącego się oraz zaproponowanie modelu wyjaśniającego, od czego zależą efekty jej zastosowania. **Stan wiedzy:** Przegląd literatury pokazuje, że wpływ AI na uczenie się nie jest jednoznaczny. Wiele badań prezentuje sprzeczne wyniki. Według niektórych GenAI wpływa pozytywnie na poprawę wyników, ale paradoksalnie obniża głębokość rozumienia. Wyniki te można wyjaśnić poprzez odwołanie do mechanizmów poznawczych, procesów samoregulacji oraz warunków dydaktycznych. Szczególne znaczenie ma odciążenie poznawcze, które w określonych warunkach wspiera uczenie się, a w innych zaczyna zastępować aktywne przetwarzanie informacji. W artykule przyjęto ujęcie, w którym jego działanie ma charakter nieliniowy i zależy od przekroczenia pewnego progu odciążenia. **Podsumowanie:** Otrzymane wnioski wskazują, że efekty wykorzystania generatywnej sztucznej inteligencji zależą przede wszystkim od sposobu jej użycia. Kluczowe znaczenie ma takie projektowanie zadań i interakcji, które utrzymuje zaangażowanie poznawcze uczącego się. Zaproponowany model pozwala uporządkować rozproszone wyniki badań i wskazuje kierunki dalszych analiz.

Słowa kluczowe: **generatywna sztuczna inteligencja, odciążenie poznawcze, obciążenie poznawcze, samoregulacja uczenia się, metapoznanie, projektowanie dydaktyczne**

©Instytut Badań Edukacyjnych – Państwowy Instytut Badawczy

© 2026 Autor(zy). Artykuł opublikowany w otwartym dostępie, rozpowszechniany na warunkach licencji Creative Commons Uznanie autorstwa 4.0 Międzynarodowe (CC BY 4.0). / © 2026 Author(s). This is an open access article distributed under the terms of the Creative Commons Attribution 4.0 International License (CC BY 4.0).

Between Support and Substitution – The Impact of Generative Artificial Intelligence on Cognitive Processes and Self-Regulated Learningand

Abstract

Introduction: The rapid development of generative artificial intelligence is changing the conditions under which learning takes place. These tools can support students' work, but they also raise questions about their impact on cognitive effort and the depth of information processing. **Research Aim:** The aim of this article is to organize research findings on the use of generative artificial intelligence in education and to propose a model explaining the conditions under which its use supports or weakens learning outcomes. Evidence-based **Facts:** The reviewed literature shows that the effects of AI on learning are not consistent. Some studies report improved performance, while others indicate reduced depth of understanding. These differences can be interpreted through the interaction of cognitive mechanisms, self-regulated learning processes, and instructional conditions. In particular, cognitive offloading plays a central role. Depending on the context, it may either support learning or replace active processing. In this article, it is treated as a non-linear process, changing its function once a certain threshold is exceeded. **Summary:** The findings suggest that the effectiveness of generative AI depends primarily on how it is used. What matters is not the tool itself, but the way tasks and interactions are structured. The proposed model helps to integrate dispersed findings and offers a framework for further research on the role of AI in learning.

Keywords: **generative artificial intelligence, cognitive offloading, cognitive load, self-regulated learning, metacognition, instructional design**

1. WPROWADZENIE

Entuzjazm w stosunku do nowych technologii w edukacji nie jest zjawiskiem nowym. Rozwój takich technologii jak radio, telewizja czy komputery prawie zawsze wiązał się z ogłoszeniem rewolucji, która miała odmienić nauczanie. Larry Cuban w swojej książce *Oversold and Underused* opisuje technologie edukacyjne jako często nadmiernie promowane, a jednocześnie słabo wykorzystywane w praktyce szkolnej (Cuban, 2001). Autor wyjaśnia ten paradoks przez cechy samego szkolnictwa. Nauczyciele mają ograniczony czas, autonomię i wsparcie, a technologie często nie pasują do ich codziennej praktyki pedagogicznej. Podobne podejście charakteryzuje książkę Is Technology Good for Education? (2016) Neila Selwyna. Autor wskazuje, że nowe technologie są przydatne tylko przy świadomym wdrożeniu z jasnym celem pedagogicznym, a reformy oparte na technologii rzadko trafiają do tych, którzy najbardziej potrzebują wsparcia, pogłębiając zamiast niwelować nierówności. Stanowi to kontekst dla obecnej debaty o AI.

Obecnie technologią, która szybko upowszechnia się w edukacji, jest generatywna sztuczna inteligencja. Różni się ona od wcześniej wprowadzanych rozwiązań zarówno funkcjonalnie, jak i poznawczo. Nie jest już wyłącznie narzędziem wspierającym pracę nauczyciela, lecz systemem zdolnym do generowania treści, prowadzenia dialogu oraz częściowego symulowania relacji pedagogicznej. Oleśniewicz i Kostka (2026) wskazują, że integracja AI w edukacji może stanowić zmianę o szerokim znaczeniu dla sposobu organizacji procesu dydaktycznego. Jak zauważa Kleiber (2026), generatywna sztuczna inteligencja należy do pierwszych technologii edukacyjnych, które weszły do powszechnego użycia przed pojawieniem się rozbudowanej bazy badań empirycznych. W odróżnieniu od wcześniejszych technologii GenAI może aktywnie uczestniczyć w procesie poznawczym uczącego się, co sprawia, że pytanie o jej wpływ na wysiłek intelektualny ucznia staje się szczególnie istotne.

Dotychczasowe przeglądy badań wskazują, że zastosowania sztucznej inteligencji w edukacji obejmują szerokie spektrum działań – od systemów wspierających ocenianie po narzędzia personalizujące proces uczenia się – jednak ich efektywność pozostaje silnie zależna od kontekstu dydaktycznego oraz sposobu integracji z procesem nauczania (Zawacki-Richter i in., 2019). Jednocześnie podkreśla się, że potencjał AI w edukacji wiąże się zarówno z możliwościami wsparcia uczenia się, jak i z ryzykiem jego uproszczenia (Holmes i in., 2019).

W ostatnich latach liczba badań dotyczących wykorzystania sztucznej inteligencji w edukacji rośnie bardzo dynamicznie. Dominują jednak analizy prowadzone w języku angielskim, koncentrujące się głównie na szkolnictwie wyższym w krajach anglosaskich. Nadal stosunkowo niewiele jest badań o charakterze długoterminowym, analizujących wpływ AI na procesy poznawcze uczących się oraz trwałość efektów uczenia się. W literaturze polskiej przeważają opracowania dotyczące implikacji wdrożeniowych i zmian systemowych, natomiast rzadziej podejmowane są analizy odnoszące się do mechani-

© 2026 Author(s). CC BY 4.0

zmów poznawczych i samoregulacji uczenia się (Tytko i in., 2023). Wśród dostępnych polskich badań empirycznych warto odnotować projekt Kmity (2025), dotyczący użycia ChatGPT przez studentów Uniwersytetu Gdańskiego – choć realizowany w ramach pracy studenckiej, stanowi jeden z nielicznych krajowych przykładów bezpośredniego badania wzorców korzystania z AI przez uczących się. Wskazuje to na istotną lukę badawczą dotyczącą warunków, w których wykorzystanie AI może wspierać lub osłabiać proces uczenia się.

Analiza dostępnych badań wskazuje, że generatywna sztuczna inteligencja nie osłabia procesów poznawczych w sposób nieuchronny. Negatywne efekty pojawiają się przede wszystkim wtedy, gdy jest wykorzystywana jako substytut wysiłku poznawczego, a nie jego wsparcie, oraz gdy jej użycie nie jest osadzone w świadomym projektowaniu dydaktycznym. Celem artykułu nie jest ocena technologii jako takiej, lecz identyfikacja warunków, w których jej wykorzystanie wspiera lub osłabia proces uczenia się. Artykuł integruje wyniki badań z perspektywy psychologii poznawczej, koncentrując się na mechanizmach odciążenia poznawczego, samoregulacji uczenia się oraz warunkach ich efektywnej implementacji dydaktycznej.

W niniejszym artykule przyjęto ramę analityczną zakładającą, że wpływ generatywnej sztucznej inteligencji na proces uczenia się ma charakter pośredni i wielopoziomowy. Oddziaływanie to przebiega poprzez mechanizmy poznawcze (odciążenie poznawcze i obciążenie zewnętrzne), które wpływają na procesy samoregulacji uczenia się i metapoznania. Ostateczny efekt edukacyjny jest moderowany przez uwarunkowania dydaktyczne. Przyjęcie takiej perspektywy pozwala zintegrować rozproszone i często sprzeczne wyniki badań empirycznych oraz wyjaśnić, dlaczego te same narzędzia AI mogą prowadzić zarówno do pogłębienia, jak i spłycenia uczenia się. Na podstawie tej analizy zaproponowany zostanie model teoretyczny porządkujący wskazane zależności i wyjaśniający warunki skutecznego wykorzystania GenAI w procesie uczenia się.

2.METODA

Artykuł ma charakter narracyjnego przeglądu literatury. Przeszukiwanie literatury przeprowadzono w bazach Scopus, Web of Science, EBSCO, PubMed, ResearchGate oraz Google Scholar. Zastosowano kombinacje słów kluczowych obejmujące m.in. generative AI, ChatGPT, artificial intelligence in education, self-regulated learning, cognitive offloading, cognitive load, metacognition, instructional design oraz learning outcomes, a także ich polskie odpowiedniki. Do analizy włączono publikacje z lat 2016–2026, ze szczególnym uwzględnieniem publikacji powstałych po roku 2022. Kryterium czasu publikacji wynikało głównie z wdrożenia do użytku publicznego w listopadzie 2022 pierwszego dużego modelu językowego – ChatGPT. Uwzględniono artykuły empiryczne, przeglądy systematyczne oraz metaanalizy. Kryterium włączenia stanowiło bezpośrednie odniesienie do wpływu narzędzi AI na proces uczenia się lub jego mechanizmy. Wykluczono publikacje o charakterze wyłącznie technicznym oraz teksty nierecenzowane, z wyjątkiem wyraźnie oznaczonych preprintów dotyczących badań empirycznych. Łącznie uwzględniono 58 publikacji, z których 35 stanowi bezpośrednio analizowane badania empiryczne, przeglądy systematyczne i metaanalizy, a pozostałe 23 tworzą podstawę teoretyczną i wyznaczają kontekst badawczy.

W procesie przygotowania artykułu wykorzystano narzędzia generatywnej sztucznej inteligencji w ograniczonym zakresie, obejmującym redakcję językową i porządkowanie struktury tekstu. Narzędzia te nie były wykorzystywane do generowania treści merytorycznych ani interpretacji wyników badań.

3. AI GENERATYWNA A AI KLASYCZNA – ROZRÓŻNIENIE POJĘCIOWE

Uporządkowanie terminologii jest istotne, ponieważ pod pojęciem „sztuczna inteligencja w edukacji" kryją się technologie o zasadniczo różnym charakterze, mechanizmach działania i konsekwencjach dla procesów poznawczych uczącego się.

Samą sztuczną inteligencję można rozumieć jako szeroką dziedzinę, w obrębie której wyróżnia się systemy o różnym zakresie i sposobie działania. Ze względu na zakres kompetencji odróżnia się sztuczną inteligencję wąską (ang. *artificial narrow intelligence,* ANI), wyspecjalizowaną w ściśle określonych zadaniach, od hipotetycznej sztucznej inteligencji ogólnej (ang. *artificial general intelligence*, AGI), zdolnej do elastycznego rozwiązywania problemów w sposób porównywalny z człowiekiem (Russell i Norvig, 2021; Wooldridge, 2021). Wszystkie stosowane obecnie rozwiązania, w tym narzędzia edukacyjne oparte na generatywnej AI, należą do kategorii AI wąskiej. Ze względu na sposób działania systemy AI można podzielić na systemy regułowe oraz systemy uczące się z danych, wykorzystujące metody uczenia maszynowego (Russell i Norvig, 2021). Uczenie głębokie, oparte na wielowarstwowych sieciach neuronowych, stanowi podzbiór uczenia maszynowego (Goodfellow i in., 2016), natomiast duże modele językowe (LLM), stanowiące podstawę większości współczesnych systemów generatywnej AI, są wyspecjalizowaną klasą modeli głębokiego uczenia opartych na architekturze transformera (Vaswani i in., 2017; Bommasani i in., 2021).

W tej klasyfikacji zarówno klasyczne edukacyjne zastosowania AI, jak i narzędzia generatywnej AI należą do kategorii sztucznej inteligencji wąskiej (ANI), jednak różnią się mechanizmem działania. Klasyczne systemy AI zazwyczaj klasyfikują, przewidują lub rekomendują na podstawie wcześniej wyuczonych wzorców bądź reguł, natomiast generatywna AI tworzy nowe treści poprzez modelowanie rozkładów statystycznych języka, obrazu lub innych danych (Bommasani i in., 2021; Feuerriegel i in., 2024). Odmienność ta może prowadzić do różnych konsekwencji dla procesów poznawczych osoby uczącej się.

© 2026 Author(s). CC BY 4.0

Klasyczna sztuczna inteligencja jest stosowana w edukacji od kilku dekad. Jej najbardziej typowe zastosowania obejmują systemy adaptacyjnego uczenia się oraz narzędzia automatycznego oceniania. Z perspektywy psychologii poznawczej ich rola ma charakter przede wszystkim ewaluacyjny i regulacyjny. Systemy te diagnozują poziom wiedzy ucznia i dostosowują trudność materiału do jego potrzeb, jednak w ramach z góry zaprogramowanych ścieżek. Uczeń pozostaje autorem własnych odpowiedzi, a AI nie współtworzy treści w sposób generatywny.

Generatywna sztuczna inteligencja (GenAI), oparta na dużych modelach językowych (LLM), zmienia układ relacji między uczniem a systemem w sposób jakościowy. Oleśniewicz i Kostka (2026) opisują tę różnicę jako przejście od automatyzacji do współtworzenia wiedzy. Z perspektywy psychologii poznawczej może to oznaczać przesunięcie części wysiłku poznawczego z ucznia na system. Odwołując się do dyskusji nad dystrybucją sprawczości (agency) między uczniem a systemem AI (Holmes i in., 2019), autorzy wskazują na zacieranie granicy między „uczeniem się z maszyną" a „uczeniem przez maszynę". To właśnie ta granica – oraz warunki, w jakich jest utrzymywana lub przekraczana – stanowią centralny problem niniejszego artykułu.

4. MECHANIZMY POZNAWCZE

Z perspektywy proponowanego modelu mechanizmy poznawcze stanowią pierwszy poziom pośredniczący między interakcją uczącego się z narzędziami GenAI a efektami uczenia się. Na tym poziomie dochodzi do bezpośredniej modyfikacji alokacji zasobów poznawczych, która następnie wpływa na procesy samoregulacji uczenia się. Zrozumienie wpływu generatywnej sztucznej inteligencji na uczenie się wymaga odwołania się do dwóch podstawowych mechanizmów poznawczych: odciążenia poznawczego oraz obciążenia zewnętrznego. Mechanizmy te oddziałują na procesy samoregulacji uczenia się i metapoznania, które stanowią kolejny poziom analizy i pełnią funkcję regulacyjną wobec przebiegu uczenia się. Procesy te nie występują niezależnie, lecz wzajemnie się warunkują i wspólnie określają, czy interakcja uczącego się z narzędziami AI prowadzi do rzeczywistego przyrostu kompetencji, czy jedynie stwarza jego pozory.

4.1 Odciążenie poznawcze

Odciążenie poznawcze (ang. *cognitive offloading*) oznacza przekazywanie zadań umysłowych na zewnętrzne narzędzia lub nośniki w celu odciążenia pamięci roboczej (Risko i Gilbert, 2016). Zjawisko to ma charakter funkcjonalny i w wielu sytuacjach jest adaptacyjny. Notowanie na komputerze, używanie kalkulatora czy wyszukiwanie informacji w Internecie to jego codzienne przykłady. Problem może pojawić się wówczas, gdy uczący się w znacznym stopniu deleguje na narzędzia AI zadania wymagające aktywnego rozumowania, analizy i syntezy, ponieważ to właśnie wykonywanie tych operacji, a nie bierna ekspozycja na ich wyniki, stanowi jeden z kluczowych warunków budowania trwałych reprezentacji wiedzy w pamięci długotrwałej (por. Fiorella i Mayer, 2015; Nęcka i in., 2020).

Perspektywę tę wspierają klasyczne badania nad pamięcią transaktywną w środowisku cyfrowym. Sparrow i in. (2011) wykazali, że gdy uczestnicy spodziewali się, iż informacja będzie dostępna w systemie zewnętrznym, zapamiętywali ją istotnie gorzej, przy jednoczesnym lepszym zapamiętywaniu miejsca jej przechowywania. Wskazuje to na przesunięcie reprezentacji poznawczej z treści na dostęp do treści. Choć badanie dotyczyło dostępu do informacji w Internecie, opisany mechanizm można interpretować jako ogólną właściwość odciążenia poznawczego, która znajduje zastosowanie również w kontekście narzędzi generatywnej AI. Mechanizm opisany przez Sparrow i in. (2011), polegający na przesunięciu reprezentacji poznawczej z treści na dostęp do treści, jest bliski założeniom konektywizmu (Downes, 2012; Siemens, 2005), zgodnie z którymi wiedza nie musi być przechowywana wyłącznie w umyśle jednostki, lecz bywa rozproszona w sieci powiązań, a kluczową kompetencją staje się umiejętność dotarcia do informacji i wykorzystania właściwych połączeń. Perspektywa ta, traktowana raczej jako ogólna rama interpretacyjna niż w pełni ugruntowana teoria uczenia się, pozwala osadzić mechanizm odciążenia poznawczego w szerszym kontekście teoretycznym: korzystanie z narzędzi GenAI można wówczas rozumieć nie tylko jako delegowanie pojedynczych operacji, lecz jako przesunięcie części procesu poznawczego do zewnętrznej sieci zasobów. Otwartym pytaniem pozostaje jednak, kiedy takie przesunięcie wspiera uczenie się, a kiedy zaczyna je ograniczać. Wskazówek dostarczają badania nad rozwojowymi uwarunkowaniami odciążenia poznawczego. Sun i in. (2025) wykazali, że tendencja do nadmiernego odciążania poznawczego (ang. *cognitive offloading bias*) jest obecna już u uczniów szkół podstawowych i średnich, choć przybiera odmienne formy w zależności od etapu edukacji: uczniowie szkół podstawowych nadmiernie polegają na pamięci wewnętrznej, a uczniowie szkół średnich na zewnętrznych narzędziach. U młodszych uczniów nasilenie tego zjawiska jest powiązane z dokładnością monitorowania metapoznawczego. Sugeruje to, że skłonność do delegowania operacji poznawczych na narzędzia zewnętrzne kształtuje się wcześnie i jest powiązana z ogólnym poziomem samoregulacji.

Perspektywę uzupełniają badania nad automatyzacją poznawczą. Fabio i in. (2026) wykazali, że stopniowa automatyzacja podstawowych podprocesów poznawczych zmniejsza obciążenie pamięci roboczej i ułatwia rozwiązywanie złożonych problemów. Wyniki te wskazują na istotną różnicę między odciążeniem wynikającym z własnej automatyzacji procesów a odciążeniem osiąganym dzięki zewnętrznym narzędziom – kluczowe jest to, czy uczący się sam wykonał wcześniej wysiłek

© 2026 Author(s). CC BY 4.0

potrzebny do opanowania tych procesów. Empirycznym potwierdzeniem tego mechanizmu są badania Grinschgl i in. (2021), w których wykazano, że decyzja o odciążeniu poznawczym ma charakter subiektywnej kalkulacji kosztów i korzyści: gdy koszty dostępu do narzędzia zewnętrznego wzrastają, uczestnicy rzadziej z niego korzystają i przechodzą na strategie oparte na własnej pamięci.

Powstaje pytanie, dlaczego uczący się decydują się na nadmierne delegowanie operacji poznawczych do narzędzi AI. Seung i Basham (2026) proponują ujęcie odciążenia poznawczego jako procesu decyzyjnego opartego na kalkulacji kosztów i korzyści. Proces ten polega na ocenie wymaganego wysiłku poznawczego i porównaniu go z oczekiwaną korzyścią z wykorzystania narzędzia. Gdy poczucie własnej skuteczności akademickiej jest niskie, a narzędzie postrzegane jako wysoce użyteczne, poziom delegowania operacji poznawczych wzrasta, nawet w odniesieniu do zadań leżących w zasięgu możliwości uczącego się. Autorzy wskazują, że szczególnie podatni na ten mechanizm są uczniowie z trudnościami w uczeniu się. W ich przypadku historia niepowodzeń akademickich sprzyja postrzeganiu AI jako substytutu własnych kompetencji, a nie jako narzędzia wspomagającego. Choć artykuł ma charakter konceptualny i nie dostarcza danych empirycznych, oferuje istotne wyjaśnienie mechanizmu prowadzącego do nadmiernego delegowania operacji poznawczych.

Gerlich (2025), w badaniu z udziałem 666 uczestników o zróżnicowanym wieku i wykształceniu, wykazał ujemną zależność między częstotliwością korzystania z narzędzi AI a poziomem myślenia krytycznego. Analizy mediacyjne wskazały, że istotną rolę w tym związku odgrywa odciążenie poznawcze. Najbardziej podatni na ten efekt byli młodsi użytkownicy, u których odnotowano jednocześnie wyższy poziom zależności od AI oraz niższe wyniki w zakresie myślenia krytycznego. Zbliżone wnioski przynosi systematyczny przegląd Guo i in. (2026), obejmujący 65 badań empirycznych dotyczących wpływu ChatGPT na myślenie krytyczne: AI może wspomagać umiejętności analityczne i ewaluacyjne, gdy jest odpowiednio osadzona w strukturze dydaktycznej, natomiast brak scaffoldingu sprzyja uczeniu się powierzchownemu i nie przekłada się na trwałe dyspozycje krytycznego myślenia. Dodatkowych przesłanek dostarcza randomizowane badanie kontrolowane (RCT) Bastaniego i in. (2025), przeprowadzone wśród blisko 1000 uczniów szkół średnich. Uczniowie mający dostęp do narzędzi AI osiągali istotnie wyższe wyniki podczas rozwiązywania zadań ćwiczeniowych (wzrost o 48% względem grupy kontrolnej), jednak po odebraniu dostępu do AI uzyskiwali wyniki o 17% niższe w teście wykonywanym samodzielnie. W arkuszach samooceny oceniali jednocześnie własne kompetencje wyżej, niż wskazywały na to rzeczywiste wyniki.

Wyniki te sugerują, że odciążenie poznawcze, gdy przyjmuje formę nadmiernego delegowania operacji poznawczych na narzędzia AI, może prowadzić do iluzji uczenia się przy jednoczesnym ograniczeniu rzeczywistego przyrostu kompetencji. Uzupełnia je badanie Baldeo (2026), w którym 58% spośród 1923 dorosłych użytkowników GenAI deklarowało, że AI przejmowała większość operacji poznawczych, a poleganie na promptach korelowało ujemnie z poczuciem pewności we własnym rozumowaniu ($r = -0{,}61$, $p < 0{,}01$); badanie ma jednak charakter opisowy i nie pozwala na wnioskowanie przyczynowe.

Z perspektywy neurokognitywnej istotne są wyniki badania Kosmyny i in. (2025) z MIT Media Lab. Z wykorzystaniem elektroencefalografii (EEG) porównano aktywność mózgu uczestników piszących eseje z pomocą ChatGPT, wyszukiwarki internetowej lub bez wsparcia technologicznego. Wyniki wskazują na systematyczny spadek łączności neuronalnej wraz ze wzrostem poziomu wsparcia zewnętrznego, przy czym najniższą aktywność sieci mózgowych odnotowano u uczestników korzystających z ChatGPT. Po czterech miesiącach regularnego użytkowania AI w tej grupie obserwowano niższe wyniki w zakresie wskaźników neuronalnych, jakości językowej oraz oceny esejów w porównaniu z grupą pracującą samodzielnie. Należy jednak zaznaczyć, że badanie opublikowano jako preprint i nie przeszło pełnej procedury recenzji naukowej, a próba liczyła 54 osoby, co ogranicza możliwość generalizacji wyników. Wyniki innych badań eksperymentalnych potwierdzają, że korzystanie z modeli językowych bez dodatkowych strategii uczenia się może prowadzić do słabszych efektów uczenia się w porównaniu z bardziej aktywnymi formami pracy. Kreijkes i in. (2026) przeprowadzili prerejestrowany eksperyment randomizowany w szkołach średnich w Anglii z udziałem 405 uczniów w wieku 14–15 lat. Uczestnicy zapoznawali się z fragmentami tekstów, pracując z pomocą LLM, samodzielnie sporządzając notatki lub łącząc oba podejścia. Testy rozumienia i retencji przeprowadzono trzy dni po fazie nauki. Zarówno samo notowanie, jak i łączenie go z LLM prowadziło do istotnie lepszych wyników w zakresie rozumienia i zapamiętywania materiału w porównaniu z korzystaniem wyłącznie z modelu językowego. Szczególnie istotny jest paradoks ujawniony przez dane jakościowe: większość uczniów preferowała pracę z LLM i oceniała ją jako bardziej pomocną, jednocześnie doceniając notowanie za sprzyjanie głębszemu zaangażowaniu i wspomaganie pamięci. Wyniki sugerują, że LLM może ułatwiać wstępne rozumienie i podtrzymywać zainteresowanie materiałem, nie zastępuje jednak aktywnych strategii poznawczych, które warunkują trwałe uczenie się.

Zebrane wyniki badań wskazują, że odciążenie poznawcze ma charakter nieliniowy. Wniosek ten jest spójny z założeniami teorii obciążenia poznawczego, zgodnie z którymi efekty instrukcyjne zależą od poziomu obciążenia poznawczego i mogą ulegać zmianie lub odwróceniu w zależności od warunków uczenia się (Sweller, 2011). Do pewnego poziomu delegowanie operacji poznawczych może sprzyjać uczeniu się, ponieważ redukuje obciążenie pamięci roboczej. Problemy pojawiają się jednak wtedy, gdy zaczyna ono zastępować aktywne przetwarzanie informacji. W takich warunkach część kluczowych operacji poznawczych zostaje przeniesiona na system, co wiąże się ze spadkiem głębokości przetwarzania oraz pogorszeniem rozumienia. Warto jednak podkreślić, że granica między wsparciem a zastępowaniem procesów poznawczych nie ma charakteru jednoznacznego ani precyzyjnie określonego. Ma ona raczej charakter stopniowy i zależy od kontekstu oraz sposobu wykorzystania narzędzia. W proponowanym modelu można ją traktować jako punkt przejścia, w którym funkcja odciążenia poznawczego zaczyna zmieniać swój charakter, ze wspierającego na zastępujący.

© 2026 Author(s). CC BY 4.0

4.2 Obciążenie zewnętrzne i projektowanie interakcji z generatywną sztuczną inteligencją

W proponowanym modelu obciążenie zewnętrzne (ang. *extraneous cognitive load*) odnosi się do warunków, w jakich przebiega interakcja uczącego się z narzędziami generatywnej sztucznej inteligencji. Nie wynika ono bezpośrednio z trudności materiału, ale raczej z tego, w jaki sposób treść jest przedstawiona i jak zorganizowane jest zadanie (Sweller, 2011). W praktyce oznacza to, że nawet przy tej samej treści uczenie się może przebiegać inaczej, zależnie od tego, jak wygląda praca z narzędziem.

Generatywna sztuczna inteligencja nie działa tu w jeden sposób. W części sytuacji rzeczywiście upraszcza materiał i pomaga uporządkować informacje. Zdarza się jednak, że odpowiedzi są zbyt rozbudowane albo trudne do szybkiego uchwycenia. Wtedy użytkownik musi sam zdecydować, co jest najważniejsze. To wymaga dodatkowego wysiłku poznawczego, który nie zawsze przekłada się na lepsze rozumienie. Taki kierunek interpretacji pojawia się również w badaniach, które pokazują duże zróżnicowanie efektów korzystania z GenAI (Xia i in., 2026).

Jednym z częstszych problemów jest nadmiar dostarczanych informacji. Modele językowe mają tendencję do generowania odpowiedzi bardzo rozbudowanych, często dużo szerszych niż wymaga tego zadanie. W efekcie użytkownik może mieć problem z uchwyceniem informacji najważniejszych. Jeżeli odpowiedź nie ma wyraźnej struktury, pojawia się konieczność jej uporządkowania, co oznacza dodatkowy wysiłek, a to nie zawsze wspiera uczenie się. W tym sensie część zasobów poznawczych jest angażowana poza właściwe przetwarzanie materiału. Podobne wnioski można pośrednio wyprowadzić z badań nad aktywnością neuronalną w trakcie pracy z AI (Kosmyna i in., 2025).

Drugim źródłem obciążenia jest konieczność oceny tego, czy udzielona odpowiedź jest poprawna. Generowane treści nie zawsze są w pełni trafne, więc wymagają weryfikacji. Problem polega na tym, że użytkownicy nie zawsze podejmują ten wysiłek, zwłaszcza gdy korzystają z narzędzia regularnie. W takich sytuacjach kontrola metapoznawcza może słabnąć (Fan i in., 2025).

Nie oznacza to jednak, że wykorzystanie AI zawsze prowadzi do wzrostu obciążenia zewnętrznego. W odpowiednich warunkach może je ograniczać. Pomaga tu między innymi podział informacji na mniejsze części oraz dostosowanie poziomu szczegółowości odpowiedzi do poziomu uczącego się. Ważną rolę odgrywają także wskazówki metapoznawcze, które porządkują sposób pracy z materiałem (Xia i in., 2026; X. Xu i in., 2025). Wskazówki metapoznawcze to dodatkowe, wbudowane w model pytania lub polecenia, które mają zapobiec biernemu przyjęciu wygenerowanej treści poprzez skłonienie uczącego się do refleksji nad własnym uczeniem się i rozumieniem materiału.

Z tego punktu widzenia kluczowe znaczenie ma nie tyle sama technologia, ile sposób jej wykorzystania. Źle zaprojektowana interakcja może zwiększać obciążenie poznawcze i jednocześnie ograniczać realne przetwarzanie informacji. W efekcie uczenie się staje się bardziej powierzchowne. Wskazuje na to eksperyment Kim i Ji (2026), w którym zbadano, jak dwa czynniki projektowania interfejsu AI – sposób prezentowania odpowiedzi (jednorazowy vs. progresywny) i poziom inicjatywy użytkownika przy formułowaniu promptów – wpływają na zachowania eksploracyjne i obciążenie poznawcze. Stopniowe ujawnianie informacji oraz wyższy poziom inicjatywy użytkownika istotnie zwiększały zaangażowanie, postrzegane przyswojenie wiedzy oraz obciążenie generatywne, co sprzyjało głębszej eksploracji materiału. Zaobserwowano przy tym efekt interakcji. Wpływ inicjatywy użytkownika na obciążenie generatywne zależał od zastosowanego sposobu prezentacji odpowiedzi. Wyniki wskazują, że projektowanie interfejsu AI nie jest neutralne poznawczo – sposób prezentowania odpowiedzi i poziom inicjatywy użytkownika przy formułowaniu promptów kształtują poziom obciążenia generatywnego i głębokość eksploracji materiału. Paradoksalny aspekt tej zależności ujawniają badania Stadlera i in. (2024), w których 91 studentów losowo przydzielono do warunków korzystania z ChatGPT lub Google podczas pracy z zagadnieniem socjonaukowym. Studenci korzystający z LLM doświadczali istotnie niższego obciążenia poznawczego we wszystkich trzech wymiarach – zewnętrznym, wewnętrznym i generatywnym – w porównaniu z grupą korzystającą z wyszukiwarki. Redukcja obciążenia wiązała się jednak z gorszą jakością rozumowania i argumentacji w końcowych rekomendacjach. Autorzy interpretują ten wynik przez pryzmat teorii obciążenia poznawczego. Obniżenie obciążenia generatywnego oznacza mniejsze zaangażowanie we wnioskowanie i syntezę, co bezpośrednio ogranicza głębię przetwarzania. Wyniki te sugerują, że celem projektowania dydaktycznego nie powinno być samo obniżenie obciążenia, lecz jego właściwy rozkład, polegający na redukcji obciążenia zewnętrznego przy utrzymaniu lub zwiększeniu obciążenia generatywnego.

W proponowanym modelu obciążenie zewnętrzne pełni funkcję czynnika, który wpływa na kierunek tych efektów. Wysoki poziom utrudnia samoregulację i kontrolę poznawczą, natomiast jego ograniczenie sprzyja bardziej efektywnemu wykorzystaniu zasobów poznawczych (Sweller i in., 1998).

5. SAMOREGULACJA UCZENIA SIĘ I METAPOZNANIE

Kluczowym pytaniem w kontekście wykorzystania generatywnej sztucznej inteligencji jest to, czy uczący się zachowuje kontrolę nad własnym procesem uczenia się. W klasycznych ujęciach samoregulacji podkreśla się, że obejmuje ona planowanie, monitorowanie oraz ocenę własnych działań poznawczych (Pintrich, 2000; Winne i Hadwin, 1998; Zimmerman, 2002). Uczenie się nie sprowadza się więc wyłącznie do przetwarzania informacji, lecz polega na aktywnym zarządzaniu własnym poznaniem, które warunkuje głębokość rozumienia.

© 2026 Author(s). CC BY 4.0

Wprowadzenie narzędzi generatywnej AI zmienia warunki, w których ten proces zachodzi. Przegląd Xia i in. (2026), obejmujący 73 badania empiryczne, wskazuje, że systemy te mogą wspierać wszystkie fazy samoregulacji. Na etapie planowania pomagają w formułowaniu celów i wyszukiwaniu informacji, w trakcie działania wspierają strategie rozwiązywania problemów, a w fazie refleksji dostarczają informacji zwrotnej i ułatwiają samoocenę. W literaturze podkreśla się przy tym, że skuteczna informacja zwrotna powinna wykraczać poza ocenę bieżącego wykonania i wspierać dalsze uczenie się. Podejścia skoncentrowane na uczniu (ang. learner-centered feedback) akcentują rozwój samoregulacji oraz poczucia sprawstwa (AlGhamdi i in., 2026).

Jednocześnie sposób korzystania z AI przez uczących się nie jest jednorodny, lecz przyjmuje odmienne wzorce. Różnice te dotyczą przede wszystkim stopnia angażowania procesów samoregulacji oraz sposobu włączania narzędzia w przebieg uczenia się. Amzalag (2026), badając profesjonalistów z różnych branż korzystających z GenAI do uczenia się, wykazał, że kluczowym predyktorem pogłębionego i refleksyjnego uczenia się z AI jest nie tyle motywacja do nauki ani przynależność zawodowa, ile to, jak użytkownik postrzega przydatność narzędzia. Gdy AI jest postrzegana jako wysoce przydatna, użytkownicy częściej włączają ją w szerszy proces uczenia się, który jest zintegrowany z planowaniem działań, monitorowaniem postępów i refleksją nad wynikami. W przeciwnym razie narzędzie funkcjonuje głównie na poziomie operacyjnym, jako wsparcie wykonania pojedynczych zadań.

Samoregulacja nie jest przy tym procesem stałym. Badania wskazują, że ma ona charakter silnie kontekstowy i zmienia się w zależności od warunków uczenia się (Panadero i in., 2025). Co więcej, jej przebieg jest dynamiczny, strategie ulegają modyfikacjom w czasie, a ich jakość zależy przede wszystkim od poziomu aktywnego zaangażowania poznawczego. Sama obecność narzędzia nie jest kluczowa. Cristea i in. (2025), analizując dane aktywności studentów z 41 kursów w systemach LMS, wykazali, że konsekwentne stosowanie strategii głębokiego uczenia się dawało lepsze efekty niż strategie powierzchowne lub niespójne – nawet jeśli te ostatnie obejmowały epizody głębokiego przetwarzania. Liczy się więc nie samo pojawienie się samoregulacji, lecz jej regularność. Złożoność tego obrazu ujawnia randomizowane badanie kontrolowane Fütterera i in. (2026) przeprowadzone na próbie 371 uczniów szkół średnich (klasy 7–9). Autorzy porównali dwa typy interwencji opartych na CustomGPT – ukierunkowaną na komponent motywacyjny (poczucie użyteczności nauki) i ukierunkowaną na strategie poznawcze – z grupą kontrolną korzystającą ze standardowego ChatGPT. Wyniki wskazują, że interwencja motywacyjna korzystnie różnicowała się od strategicznej pod względem rozwoju poczucia użyteczności, jednak żaden z warunków interwencji nie wykazał istotnych statystycznie przewag nad grupą kontrolną w zakresie wysiłku, strategii elaboracyjnych ani wiedzy przedmiotowej. Jednocześnie uczniowie angażujący się w bardziej znaczące interakcje z GPT wykazywali bardziej stabilne zainteresowanie niż uczestnicy grupy kontrolnej. Autorzy konkludują, że GenAI może wspomagać motywacyjne aspekty SRL w pewnych warunkach, jednak skuteczne wspieranie strategii poznawczych wymaga dalszego rozwoju narzędzi i podejść interwencyjnych.

Ta zmienność sprawia, że efekty wykorzystania AI nie są jednoznaczne. Funkcje, które mogą wspierać samoregulację, w określonych warunkach prowadzą również do jej osłabienia. Fan i in. (2025), w randomizowanym eksperymencie z udziałem 117 studentów, opisali zjawisko „metapoznawczego lenistwa". Studenci intensywnie korzystający z ChatGPT rzadziej angażowali się w procesy ewaluacji własnego uczenia się – delegując te komponenty na system – mimo porównywalnego poziomu motywacji. Jednocześnie nie odnotowano u nich wyższych wyników w zakresie przyrostu wiedzy ani jej transferu w porównaniu z pozostałymi grupami. W takiej sytuacji narzędzie przestaje pełnić funkcję wspierającą i zaczyna zastępować kluczowe komponenty procesu regulacyjnego.

W praktyce oznacza to, że znaczenie ma nie tylko dostęp do narzędzia, ale również charakter generowanego przez nie wsparcia. Badania nad systemami automatycznej ewaluacji pisania pokazują, że gdy informacja zwrotna jest ogólna lub nieprecyzyjna, uczniowie postrzegają ją jako mało użyteczną i domagają się głębszego, bardziej spersonalizowanego wsparcia – co sugeruje, że płytki feedback nie angażuje procesów analizy własnych błędów (Wilson i in., 2024). Takie działania nie prowadzą do trwałego uczenia się.

Jednocześnie wyniki badań pokazują, że efekt ten można ograniczyć. X. Xu i in. (2025) wykazali, że wprowadzenie monitów metapoznawczych, czyli pytań towarzyszących pracy z AI, na przykład „Czy potrafię wyjaśnić ten koncept własnymi słowami?", prowadziło do poprawy wszystkich mierzonych komponentów samoregulacji, podczas gdy w grupie kontrolnej obserwowano odwrotny trend. Z kolei badania AlGhamdi i in. (2026) wskazują, że sposób projektowania interakcji z systemem, w szczególności struktura promptów oraz organizacja zadań, wpływa na charakter generowanego wsparcia, w tym jakość i funkcję informacji zwrotnej.

Zebrane ustalenia prowadzą do wniosku, że wpływ generatywnej AI na samoregulację nie ma charakteru bezpośredniego. To samo narzędzie może zarówno wspierać procesy regulacyjne, jak i je zastępować. Kluczowe znaczenie ma to, czy uczący się pozostaje aktywnym podmiotem monitorującym własne uczenie się, czy też część tej funkcji zostaje przeniesiona na system.

© 2026 Author(s). CC BY 4.0

6. UWARUNKOWANIA DYDAKTYCZNE JAKO MODERATOR EFEKTÓW WYKORZYSTANIA GENAI

W proponowanym modelu kluczowe znaczenie mają uwarunkowania dydaktyczne, ponieważ to one określają, w jaki sposób wykorzystanie generatywnej sztucznej inteligencji wpływa na procesy poznawcze i regulacyjne uczącego się. Sama obecność technologii nie przesądza o efektach edukacyjnych. Istotne jest to, w jakich warunkach i w jaki sposób jest ona używana. Od tych warunków zależy, czy odciążenie poznawcze wspiera uczenie się, czy prowadzi do jego spłycenia. Zgodnie z koncepcją uczenia się generatywnego, trwałe zrozumienie wymaga aktywnego przetwarzania informacji, obejmującego m.in. organizowanie, integrowanie oraz generowanie własnych wyjaśnień (Fiorella i Mayer, 2015). Ograniczenie tych procesów – na przykład poprzez zastępowanie ich gotowymi odpowiedziami – prowadzi do spadku jakości uczenia się.

Analiza przedstawionych badań pozwala wyróżnić trzy powiązane wymiary, które porządkują sposób rozumienia wpływu GenAI. Chodzi o to, w jakim stopniu narzędzie zastępuje lub wspiera operacje poznawcze, jak wygląda poziom regulacji metapoznawczej oraz w jaki sposób zorganizowana jest sama interakcja z systemem.

Pierwszy z tych wymiarów dotyczy charakteru odciążenia poznawczego. Problemy pojawiają się przede wszystkim wtedy, gdy narzędzie przejmuje operacje wymagające aktywnego uczestnictwa użytkownika. Bastani i in. (2025) pokazali, że nieograniczony dostęp do AI, przy braku struktury wymuszającej samodzielne rozumowanie, może poprawiać wyniki, a jednocześnie pogarszać rozumienie konceptualne. X. Xu i in. (2025) wskazują z kolei, że znaczenie ma nie tyle częstotliwość korzystania z AI, ile to, czy towarzyszy jej aktywna refleksja metapoznawcza. W quasi-eksperymencie z udziałem 68 studentów wykazali, że studenci bez wsparcia metapoznawczego wykazywali spadek samoregulacji w środowisku GenAI, natomiast wprowadzenie monitów metapoznawczych ten efekt odwracało. Częste użycie narzędzia nie musi więc obniżać jakości uczenia się, o ile towarzyszy mu aktywne przetwarzanie informacji i refleksja nad własnym procesem uczenia się. Dualny charakter AI w edukacji – jej jednoczesny potencjał wzmacniający i ryzyko erozji kompetencji poznawczych – jest coraz częściej opisywany w literaturze jako paradoks poznawczy (Jose i in., 2025). Warto też uwzględnić różnice indywidualne. Seung i Basham (2026) wskazują, że wśród czynników motywacyjnych kształtujących decyzje o delegowaniu operacji poznawczych na AI istotną rolę odgrywa poczucie własnej skuteczności – uczniowie z niższym self-efficacy są bardziej narażeni na nadmierny offloading, co zwiększa ryzyko zastępowania kompetencji przez narzędzie.

Drugi wymiar odnosi się do poziomu regulacji metapoznawczej. Dostępne wyniki wskazują, że brak monitorowania własnego uczenia się sprzyja powierzchownemu przetwarzaniu informacji. Fan i in. (2025) wykazali, że intensywne korzystanie z ChatGPT, przy braku mechanizmów refleksji, ogranicza zaangażowanie w procesy ewaluacji własnego uczenia się; efektu tego nie obserwowano natomiast dla planowania ani monitorowania. Jednocześnie badania X. Xu i in. (2025) pokazują, że efekt ten można odwrócić. Wprowadzenie monitów metapoznawczych prowadziło do wzrostu samoregulacji. Sugeruje to, że znaczenie ma nie samo narzędzie, lecz to, czy wspiera ono refleksję nad przebiegiem uczenia się.

Trzeci wymiar dotyczy struktury interakcji z narzędziem oraz związanego z nią obciążenia zewnętrznego. Źle zaprojektowane środowisko pracy z AI może zwiększać obciążenie poznawcze. Wpływ mają tu m.in. konieczność weryfikacji informacji, obsługa interfejsu czy decyzje dotyczące sposobu użycia narzędzia (Martin i in., 2025; Tankelevitch i in., 2024). Z drugiej strony odpowiednio zaprojektowana interakcja może ten efekt ograniczyć. Li i in. (2025) pokazali, że zastosowanie podejścia opartego na progresywnym promptowaniu wspomaganym przez GenAI (GenAI-PP) – obejmującego cztery etapy: formułowanie promptu, dyskusję z AI, weryfikację odpowiedzi i refleksję – obniżało obciążenie zewnętrzne i sprzyjało efektywnemu przetwarzaniu informacji w porównaniu z konwencjonalnym promptowaniem.

Wyniki te sugerują, że warunki sprzyjające efektywnemu uczeniu się nie są prostym przeciwieństwem warunków ryzyka, lecz raczej ich odmienną konfiguracją. Oznacza to, że kluczowe znaczenie ma sposób organizacji pracy z AI, w szczególności stopień jej strukturyzacji oraz obecność elementów refleksyjnych, które pozwalają utrzymać zaangażowanie poznawcze i wspierają proces uczenia się. Podobne wnioski przedstawiają Lim i in. (2025), wskazując, że skuteczne wykorzystanie GenAI wymaga integracji narzędzia ze wszystkimi fazami samoregulacji, a nie wyłącznie z fazą wykonania. Przegląd Guan i in. (2025) sugeruje natomiast, że chatboty najczęściej wspierają właśnie fazę wykonania, co czyni fazy planowania i refleksji szczególnie istotnymi punktami interwencji dydaktycznej. Obserwację tę potwierdzają wyniki metaanalizy J. Xu i in. (2026), obejmującej 35 badań empirycznych z lat 2013–2025. Autorzy wykazali, że wsparcie AI w zakresie SRL daje umiarkowany ogólny efekt ($g = 0{,}507$), jednak jego rozkład jest wyraźnie nierównomierny: najsilniejszy w fazie wykonania ($g = 0{,}574$), słabszy w fazie planowania ($g = 0{,}401$) i pośredni w fazie refleksji ($g = 0{,}464$). Różnica ta tłumaczy, dlaczego AI może podwyższać bieżące wyniki zadaniowe, nie przekładając się w równym stopniu na długoterminowe efekty uczenia się – faza planowania i refleksji, decydujące o trwałości zmian, pozostają niedostatecznie aktywowane. Wnioski te uzupełniają wyniki Feng (2025), które pokazują, że adaptacyjna informacja zwrotna może jednocześnie redukować obciążenie poznawcze i poprawiać efekty uczenia się. Badania nad informacją zwrotną wskazują przy tym, że jej skuteczność zależy nie tylko od przekazywanych treści, lecz przede wszystkim od tego, czy wspiera ona procesy samoregulacji uczącego się (Hattie i Timperley, 2007).

Zestawienie tych trzech wymiarów prowadzi do wniosku, że wpływ GenAI na uczenie się nie wynika z pojedynczego czynnika, lecz z ich współwystępowania. Negatywne efekty pojawiają się najczęściej wtedy, gdy dochodzi do jednoczesnego zastąpienia wysiłku poznawczego, braku regulacji metapoznawczej oraz wysokiego obciążenia zewnętrznego. Z kolei efekty

© 2026 Author(s). CC BY 4.0

pozytywne są bardziej prawdopodobne wtedy, gdy narzędzie wspiera przetwarzanie, proces uczenia się pozostaje regulowany, a interakcja z AI jest odpowiednio ustrukturyzowana.

W analizowanych badaniach pojawia się sugestia, że odciążenie poznawcze nie ma charakteru liniowego, lecz zmienia swoją funkcję w zależności od intensywności wsparcia. Można to ująć jako istnienie progu, po którego przekroczeniu odciążenie przestaje wspierać przetwarzanie informacji, a zaczyna zastępować kluczowe operacje poznawcze. Próg ten nie ma stałej wartości i zależy od kontekstu. Istotne znaczenie mają między innymi poziom kompetencji uczącego się, złożoność zadania oraz sposób organizacji pracy z narzędziem. W efekcie ta sama forma wsparcia może prowadzić do odmiennych rezultatów w zależności od warunków. W tym ujęciu próg odciążenia należy rozumieć jako punkt przejścia między wsparciem a zastępowaniem procesów poznawczych, a nie jako jednoznacznie określoną granicę.

7. MODEL TEORETYCZNY WPŁYWU GENAI NA UCZENIE SIĘ

Opisane mechanizmy – odciążenie poznawcze, obciążenie zewnętrzne, samoregulacja i uwarunkowania dydaktyczne – tworzą razem układ, którego działanie można ująć w postaci modelu. Na podstawie przedstawionych analiz zaproponowano model teoretyczny integrujący wpływ generatywnej sztucznej inteligencji na proces uczenia się (rys. 1). Model ten porządkuje zależności między mechanizmami poznawczymi, procesami samoregulacji uczenia się oraz uwarunkowaniami dydaktycznymi, wskazując na ich nieliniowy i warunkowy charakter.

Rysunek 1 ***Nieliniowy model wpływu generatywnej sztucznej inteligencji na proces uczenia się***

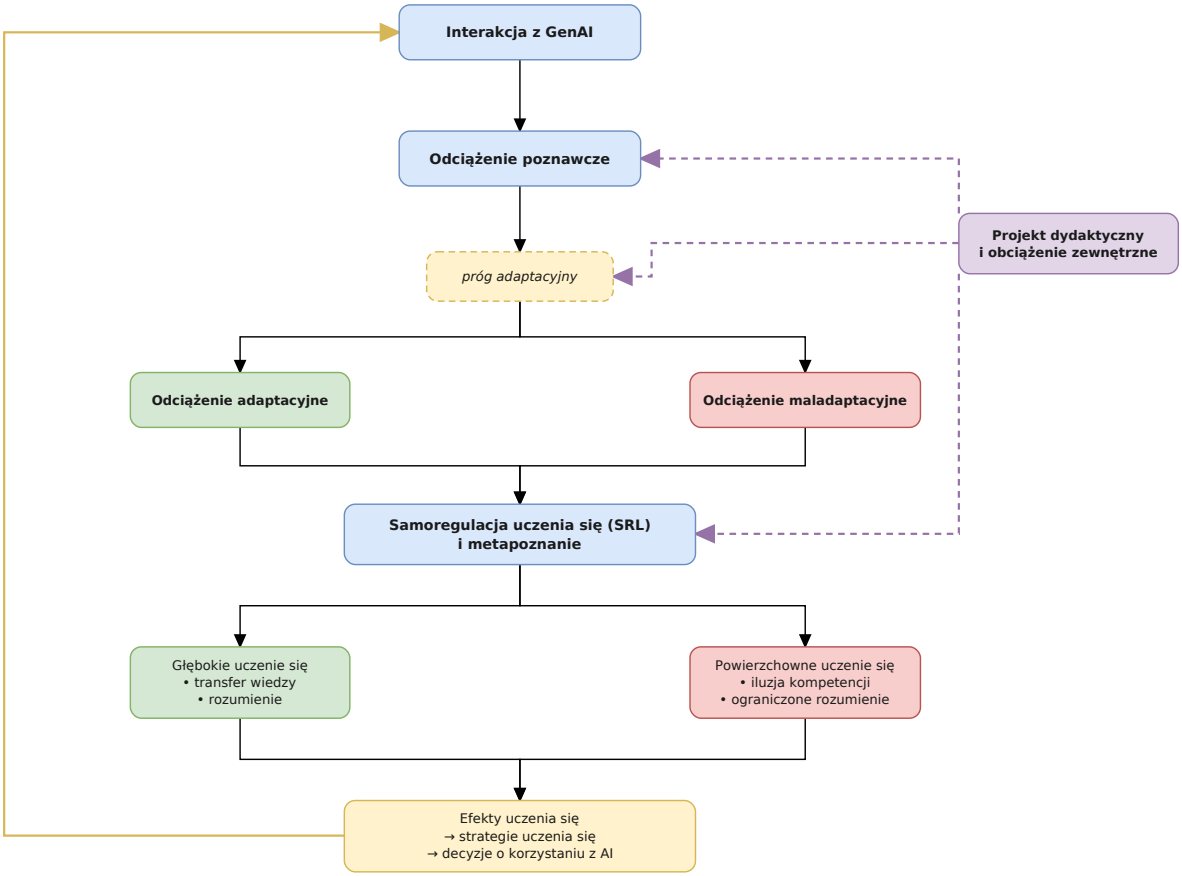

Źródło: *opracowanie własne na podstawie przeglądu literatury.*

© 2026 Author(s). CC BY 4.0

Rysunek 1 przedstawia model w formie schematu przepływu. U góry znajduje się węzeł wejściowy „Interakcja z GenAI", z którego strzałka prowadzi do węzła „Odciążenie poznawcze". Stąd przepływ przechodzi przez węzeł „próg adaptacyjny", który rozdziela schemat na dwie równoległe ścieżki: lewą – „Odciążenie adaptacyjne" i prawą – „Odciążenie maladaptacyjne". Obie ścieżki zbiegają się w węźle centralnym „Samoregulacja uczenia się (SRL) i metapoznanie". Z tego węzła wychodzą dwie strzałki prowadzące odpowiednio do „Głębokiego uczenia się (transfer, rozumienie)" po lewej oraz „Powierzchownego uczenia się (iluzja kompetencji, ograniczone rozumienie)" po prawej. Obie ścieżki łączą się w węźle końcowym „Efekty uczenia się", z którego strzałka sprzężenia zwrotnego wraca lewą stroną do węzła wejściowego. Moderator „Projekt dydaktyczny i obciążenie zewnętrzne" oddziałuje przerywanymi strzałkami na trzy węzły: „Odciążenie poznawcze", „próg adaptacyjny" oraz „Samoregulacja uczenia się i metapoznanie".

Zgodnie z przyjętym ujęciem interakcja uczącego się z narzędziami GenAI wiąże się z odciążeniem poznawczym, którego efekt nie jest stały, lecz zależy od przekroczenia określonego progu adaptacyjnego. Znaczenie tego procesu ujawnia się dopiero w powiązaniu z poziomem samoregulacji i metapoznania, które pośredniczą w jego oddziaływaniu. Jednocześnie ostateczny efekt uczenia się zależy od warunków dydaktycznych, w szczególności od poziomu obciążenia zewnętrznego.

W modelu uwzględniono także sprzężenie zwrotne. Osiągane rezultaty wpływają na sposób, w jaki uczący się korzysta z AI w kolejnych zadaniach, modyfikując strategie pracy z narzędziem.

Proponowane ujęcie wskazuje, że wpływ generatywnej sztucznej inteligencji nie ma charakteru liniowego. Odciążenie poznawcze nie pełni tu jednej, stałej funkcji, lecz może zmieniać swój charakter – od wspierającego do zastępującego – w zależności od poziomu samoregulacji oraz jakości projektowania dydaktycznego.

8. IMPLIKACJE DYDAKTYCZNE WYKORZYSTANIA GENERATYWNEJ SZTUCZNEJ INTELIGENCJI

Przedstawione wyniki sugerują, że znaczenie generatywnej sztucznej inteligencji dla procesu uczenia się nie wynika z samej obecności narzędzia, lecz z tego, w jaki sposób jest ono wykorzystywane. W zależności od przyjętej strategii pracy z AI można obserwować zarówno pogłębione przetwarzanie informacji, jak i jego wyraźne spłycenie (Stadler i in., 2024). W tym sensie projektowanie dydaktyczne sprowadza się do takiego organizowania aktywności, które nie przenosi kluczowych operacji poznawczych na system. Różnice te są dobrze widoczne na poziomie zadań.

W sytuacji, gdy zadanie polega przede wszystkim na wygenerowaniu odpowiedzi, uczący się częściej koncentruje się na uzyskaniu rozwiązania, a nie na jego zrozumieniu. Taki sposób pracy ogranicza głębokość przetwarzania informacji (Bastani i in., 2025). Inaczej wygląda sytuacja, gdy odpowiedź wygenerowana przez AI staje się materiałem do dalszej pracy. Jej analiza, porównanie lub ocena wymagają aktywnego zaangażowania poznawczego. Przykładem może być polecenie, w którym należy zestawić dwie odpowiedzi i wskazać ich mocne oraz słabe strony. W takim przypadku pojawiają się procesy ewaluacyjne, które nie są uruchamiane przy prostym generowaniu tekstu. Znaczenie ma również to, czy w pracy z AI obecny jest komponent refleksyjny. Gdy uczący się ma dostęp do narzędzia generującego gotowe odpowiedzi, istnieje ryzyko przeniesienia części procesów regulacyjnych na system, co skutkuje obniżeniem kontroli metapoznawczej (Fan i in., 2025; Lim i in., 2025). Wprowadzenie elementów refleksji może ten mechanizm odwrócić i sprzyjać wzrostowi samoregulacji (X. Xu i in., 2025). Potwierdzają to między innymi wyniki metaanalizy Wu i Wang (2026), w której środowiska AI z adaptywnym feedbackiem i elementami gamifikacji istotnie wspierały rozwój strategii metapoznawczych u uczniów szkół podstawowych ($g = 0{,}68$). W praktyce oznacza to konieczność włączania zadań, które wymagają odniesienia się do uzyskanej odpowiedzi, na przykład poprzez jej parafrazowanie albo ocenę poprawności.

Znaczenie ma również to, jak w praktyce wygląda sama interakcja z narzędziem. Badania pokazują, że sposób organizacji pracy z AI wpływa zarówno na obciążenie poznawcze, jak i na wybór strategii uczenia się (Kim i Ji, 2026; Tankelevitch i in., 2024). Gdy interakcja jest nieuporządkowana, łatwo o rozproszenie uwagi. W efekcie część zasobów poznawczych jest angażowana w samą obsługę narzędzia, a nie w przetwarzanie treści. Wprowadzenie prostych etapów pracy zmienia tę sytuację. Uczący się łatwiej kontroluje przebieg zadania i rzadziej traci wątek. Dobrym przykładem jest rozwiązanie, w którym najpierw próbuje samodzielnie rozwiązać problem, a dopiero potem sprawdza odpowiedź wygenerowaną przez AI.

Zmienia się przy tym sama rola nauczyciela. Przestaje on być wyłącznie osobą przekazującą wiedzę, a coraz częściej odpowiada za projektowanie środowiska uczenia się. To po jego stronie leży decyzja, które elementy procesu mogą być wspierane przez AI, a które powinny pozostać efektem samodzielnej pracy uczącego się i angażować jego wysiłek poznawczy. Jak podkreśla Celik (2026), w tym kontekście szczególnego znaczenia nabiera wiedza pedagogiczno-technologiczna określana jako Intelligent TPACK. Nie chodzi jedynie o sprawne posługiwanie się narzędziami generatywnej sztucznej inteligencji, ale także o umiejętność oceny, kiedy ich użycie jest zasadne, a kiedy lepiej je ograniczyć lub odroczyć. Takie decyzje pozwalają utrzymać aktywność poznawczą uczniów, zamiast ją zastępować.

W praktyce oznacza to między innymi stosowanie pytań metapoznawczych oraz zadań wymagających sprawdzenia i oceny treści wygenerowanych przez AI, na co zwracają uwagę García-López i Trujillo-Liñán (2025). Jednocześnie percepcja tych narzędzi przez uczących się nie jest jednorodna i zależy od kontekstu. Badania prowadzone poza krajami anglojęzycznymi, takie jak studium Mekheimera (2025) na egipskim uniwersytecie czy przegląd Law (2024) dotyczący wykorzystania GenAI

© 2026 Author(s). CC BY 4.0

w nauczaniu języków, pokazują, że postawy wobec narzędzi GenAI są w większości pozytywne, choć zróżnicowane w zależności od kontekstu kulturowego i instytucjonalnego. Jak wynika z przeanalizowanych badań, to na etapie projektowania zajęć rozstrzyga się, które zadania powinny pozostać po stronie uczącego się, a które mogą być wspierane przez narzędzia AI.

9. PODSUMOWANIE

Przeprowadzony przegląd prowadzi do wniosków, że wpływ generatywnej sztucznej inteligencji nie ma charakteru jednoznacznego i zależy od wielu czynników, zarówno po stronie uczącego się, jak i nauczającego. Korzystanie z narzędzi generatywnej sztucznej inteligencji może zarówno wpływać pozytywnie na procesy poznawcze, jak i znacząco je spłycać. Negatywne skutki pojawiają się głównie wtedy, kiedy przekroczony zostanie pewien próg odciążenia poznawczego. Dzieje się to w momencie, kiedy narzędzie przejmuje kluczowe operacje poznawcze za użytkownika, a interakcja z nim jest pozbawiona elementów refleksyjnych i metapoznawczych. Efekty pozytywne pojawiają się natomiast wtedy, kiedy narzędzie wspiera odciążenie poznawcze, a nie zastępuje aktywne przetwarzanie informacji.

Przegląd ma jednak kilka istotnych ograniczeń. Obecnie w literaturze dominują badania z krajów anglosaskich, które prowadzone są głównie na poziomie szkolnictwa wyższego. Ogranicza to możliwość generalizacji wyników na inne konteksty kulturowe i poziomy edukacyjne. Większość analizowanych badań ma także charakter krótkoterminowy, co utrudnia ocenę wpływu długoterminowego na wyniki i rozwój procesów poznawczych. Brakuje również badań biorących pod uwagę różnice indywidualne, takie jak wiek, poziom kompetencji i wcześniejsze doświadczenia z technologią, które mogą moderować wpływ AI na uczenie się.

Przyszłe badania powinny koncentrować się na długoterminowych efektach korzystania z GenAI i uwzględniać zróżnicowane grupy wiekowe i kulturowe. Powinny też testować konkretne interwencje dydaktyczne zaprojektowane z myślą o utrzymaniu zaangażowania poznawczego. Szczególnie wartościowe byłyby badania eksperymentalne porównujące różne modele integracji AI z procesem uczenia się, z uwzględnieniem zarówno wyników bezpośrednich, jak i trwałości efektów.

Finansowanie Nie dotyczy.
Konflikt interesów Nie dotyczy.
Podziękowania Nie dotyczy.
Informacja o dostępności danych Nie dotyczy. Artykuł stanowi narracyjny przegląd literatury i nie jest powiązany z odrębnym zbiorem danych.

REFERENCES

AlGhamdi, E. M., Li, Y., Gašević, D., & Chen, G. (2026). Leveraging prompt-based LLMs for automated scoring and feedback generation in higher education. *Computers & Education*, *243*, 105511. https://doi.org/10.1016/j.compedu.2025.105511

Amzalag, M. (2026). When professions meet GenAI: Patterns of self-regulated learning. *Education Sciences*, *16*(3), 416. https://doi.org/10.3390/educsci16030416

Baldeo, S. (2026). Generative artificial intelligence reliance and executive function attenuation: Behavioral evidence of cognitive offload in high-use adults. Publikacja online przed drukiem. *Technology, Mind, and Behavior*. https://doi.org/10.1037/tmb0000191

Bastani, H., Bastani, O., Sungu, A., Ge, H., Kabakcı, Ö., & Mariman, R. (2025). Generative AI without guardrails can harm learning: Evidence from high school mathematics. *Proceedings of the National Academy of Sciences*, *122*(26), Artykuł e2422633122. https://doi.org/10.1073/pnas.2422633122

Bommasani, R., Hudson, D. A., Adeli, E., Altman, R., Arora, S., von Arx, S., Bernstein, M. S., Bohg, J., Bosselut, A., Brunskill, E., Brynjolfsson, E., Buch, S., Card, D., Castellon, R., Chatterji, N., Chen, A., Creel, K., Davis, J. Q., Demszky, D., ... Liang, P. (2021). *On the opportunities and risks of foundation models*. arXiv. https://doi.org/10.48550/arXiv.2108.07258

Celik, I. (2026). Teachers' professional knowledge to prevent students' overreliance on AI: Insight from Intelligent-T-PACK. *Innovations in Education and Teaching International*, 1–6. https://doi.org/10.1080/14703297.2026.2663355

© 2026 Author(s). CC BY 4.0

Cristea, T. S., Heikkinen, S., Snijders, C., Saqr, M., Matzat, U., Conijn, R., & Kleingeld, A. (2025). Dynamics of self-regulated learning: The effectiveness of students' strategies across course periods. *Computers & Education*, *228*, 105233. https://doi.org/10.1016/j.compedu.2025.105233

Cuban, L. (2001). *Oversold and underused: Computers in the classroom*. Harvard University Press.

Downes, S. (2012). *Connectivism and connective knowledge: Essays on meaning and learning networks*. National Research Council Canada.

Fabio, R. A., Picciotto, G., Iamonte, V., Colosimo, E., & Suriano, R. (2026). The role of cumulative automatization in logical problem solving: Differences between younger and older adults. *Psychology and Aging, 41*(3), 387–399. https://doi.org/10.1037/pag0000953

Fan, Y., Tang, L., Le, H., Shen, K., Tan, S., Zhao, Y., Shen, Y., Li, X., & Gašević, D. (2025). Beware of metacognitive laziness: Effects of generative artificial intelligence on learning motivation, processes, and performance. *British Journal of Educational Technology*, *56*(2), 489–530. https://doi.org/10.1111/bjet.13544

Feng, L. (2025). Investigating the effects of artificial intelligence-assisted language learning strategies on cognitive load and learning outcomes: A comparative study. *Journal of Educational Computing Research*, *62*(8), 1741–1774. https://doi.org/10.1177/07356331241268349

Feuerriegel, S., Hartmann, J., Janiesch, C., & Zschech, P. (2024). Generative AI. *Business & Information Systems Engineering*, *66*(1), 111–126. https://doi.org/10.1007/s12599-023-00834-7

Fiorella, L., & Mayer, R. E. (2015). *Learning as a generative activity: Eight learning strategies that promote understanding*. Cambridge University Press.

Fütterer, T., Bardach, L., Kuhn, J., Keller, S. D., & Gerjets, P. (2026). Enhancing school students' self-regulated learning through generative AI support: A randomized controlled trial. *Educational Psychology Review*, *38*, 42. https://doi.org/10.1007/s10648-026-10133-8

García-López, I. M., & Trujillo-Liñán, L. (2025). Ethical and regulatory challenges of generative AI in education: A systematic review. *Frontiers in Education*, *10*, 1565938. https://doi.org/10.3389/feduc.2025.1565938

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

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.

Grinschgl, S., Papenmeier, F., & Meyerhoff, H. S. (2021). Consequences of cognitive offloading: Boosting performance but diminishing memory. *Quarterly Journal of Experimental Psychology*, *74*(9), 1477–1496. https://doi.org/10.1177/17470218211008060

Guan, R., Raković, M., Chen, G., & Gašević, D. (2025). How educational chatbots support self-regulated learning? A systematic review of the literature. *Education and Information Technologies*, *30*(4), 4493–4518. https://doi.org/10.1007/s10639-024-12881-y

Guo, Y., Huang, L., Zhang, C., Li, Q., & Chen, M. (2026). ChatGPT in education: A systematic review of its impact on critical thinking skills and dispositions. *Thinking Skills and Creativity, 60*, 102106. https://doi.org/10.1016/j.tsc.2025.102106

Hattie, J., & Timperley, H. (2007). The power of feedback. *Review of Educational Research*, *77*(1), 81–112. https://doi.org/10.3102/003465430298487

Holmes, W., Bialik, M., & Fadel, C. (2019). *Artificial intelligence in education: Promises and implications for teaching and learning*. Center for Curriculum Redesign.

© 2026 Author(s). CC BY 4.0

Jose, B., Cherian, J., Verghis, A. M., Varghise, S. M., M., S., & Joseph, S. (2025). The cognitive paradox of AI in education: Between enhancement and erosion. *Frontiers in Psychology, 16,* 1550621. https://doi.org/10.3389/fpsyg.2025.1550621

Kim, N., & Ji, Y. G. (2026). Exploratory search with generative AI: An empirical study on the impact of interaction design strategies on information exploration and cognitive load. *International Journal of Human-Computer Studies, 210*, 103771. https://doi.org/10.1016/j.ijhcs.2026.103771

Kleiber, M. (2026). AI w edukacji – zagrożenia i korzyści. *Nauka(1)*, 115–120. https://doi.org/10.24425/nauka.2026.158248

Kmita, J. (2025). Analiza użycia ChatGPT przez studentów Uniwersytetu Gdańskiego. *Teoria i Praktyka Dydaktyki Akademickiej, 4*(3), 13–26.

Kosmyna, N., Hauptmann, E., Yuan, Y. T., Situ, J., Liao, X.-H., Beresnitzky, A. V., Braunstein, I., & Maes, P. (2025). *Your brain on ChatGPT: Accumulation of cognitive debt when using an AI assistant for essay writing task*. arXiv. https://doi.org/10.48550/arXiv.2506.08872

Kreijkes, P., Kewenig, V., Kuvalja, M., Lee, M., Hofman, J. M., Vitello, S., Sellen, A., Rintel, S., Goldstein, D. G., Rothschild, D. M., Tankelevitch, L., & Oates, T. (2026). Effects of LLM use and note-taking on reading comprehension and memory: A randomised experiment in secondary schools. *Computers & Education, 243,* Artykuł 105514. https://doi.org/10.1016/j.compedu.2025.105514

Law, L. (2024). Application of generative artificial intelligence (GenAI) in language teaching and learning: A scoping literature review. *Computers and Education Open, 6,* Artykuł 100174. https://doi.org/10.1016/j.caeo.2024.100174

Li, C.-J., Hwang, G.-J., Chang, C.-Y., & Su, H.-C. (2025). Generative AI-supported progressive prompting for professional training: Effects on learning achievement, critical thinking, and cognitive load. *British Journal of Educational Technology, 56*(6), 2550–2572. https://doi.org/10.1111/bjet.13594

Lim, L.-A., Ainscough, L., Deneen, C., Pacitti, H., Taylor-Griffiths, D., Male, S. A., & Frankland, S. (2025). Transition pedagogy in the age of AI: The role of self-regulated learning. *Student Success, 16*(3), 57–66. https://doi.org/10.63608/ssj.3766

Ładna, A. (red.), Kamiński, K., Rosłaniec, K., Wrońska, A., Błażej, M., Jankiewicz, A., Konopczyński, F., & Nawrot, M. (2025). *Nastolatki: Raport z ogólnopolskiego badania uczniów i rodziców*. NASK.

Martin, A. J., Collie, R. J., Kennett, R., Liu, D., Ginns, P., Sudimantara, L. B., Dewi, E. W., & Rüschenpöhler, L. G. (2025). Integrating generative AI and load reduction instruction to individualize and optimize students' learning. *Learning and Individual Differences, 121,* Artykuł 102723. https://doi.org/10.1016/j.lindif.2025.102723

Mekheimer, M. (2025). Adoption and perceptions of ChatGPT in an EFL classroom: A mixed-methods study at an Egyptian university. *Discover Education, 5*(1), 6. https://doi.org/10.1007/s44217-025-00992-8

Nęcka, E., Orzechowski, J., Szymura, B., & Wichary, S. (2020). *Psychologia poznawcza*. Wydawnictwo Naukowe PWN.

Oleśniewicz, M., & Kostka, K. (2026). Artificial intelligence and the change of traditional paradigms in educational psychology. *Lubelski Rocznik Pedagogiczny, 45*(1), 107–122. https://doi.org/10.17951/lrp.2026.45.1.107-122

Panadero, E., Fernández-Ortube, A., Zamorano, D., Pinedo, L., Sánchez-Iglesias, I., & Barrenetxea-Mínguez, L. (2025). Tracking self-regulated learning in action: How individual differences shape positive and negative regulation across three types of tasks. *Learning and Individual Differences, 124,* Artykuł 102808. https://doi.org/10.1016/j.lindif.2025.102808

Pintrich, P. R. (2000). The role of goal orientation in self-regulated learning. W: M. Boekaerts, P. Pintrich, i M. Zeidner (red.), *Handbook of self-regulation* (ss. 451–502). Academic Press.

Risko, E. F., & Gilbert, S. J. (2016). Cognitive offloading. *Trends in Cognitive Sciences, 20*(9), 676–688. https://doi.org/10.1016/j.tics.2016.07.002

© 2026 Author(s). CC BY 4.0

Russell, S. J., & Norvig, P. (2021). *Artificial intelligence: A modern approach* (4th ed.). Pearson.

Selwyn, N. (2016). *Is technology good for education?* Polity Press.

Seung, Y., & Basham, J. D. (2026). Cognitive offloading in the age of generative AI: What does it mean for students with learning disabilities? *Journal of Special Education Technology*. Publikacja online przed drukiem. https://doi.org/10.1177/07319487261439132

Siemens, G. (2005). Connectivism: A learning theory for the digital age. *International Journal of Instructional Technology and Distance Learning, 2*(1), 3–10.

Sparrow, B., Liu, J., & Wegner, D. M. (2011). Google effects on memory: Cognitive consequences of having information at our fingertips. *Science, 333*(6043), 776–778. https://doi.org/10.1126/science.1207745

Stadler, M., Bannert, M., & Sailer, M. (2024). Cognitive ease at a cost: LLMs reduce mental effort but compromise depth in student scientific inquiry. *Computers in Human Behavior, 160,* Artykuł 108386. https://doi.org/10.1016/j.chb.2024.108386

Sun, J., Wang, Y., Hu, Z., Liu, Y., & Sun, Y. (2025). Cognitive offloading bias in primary and secondary school students and its relationship with metacognitive monitoring. *British Journal of Developmental Psychology, 43,* 645–659. https://doi.org/10.1111/bjdp.12540

Sweller, J. (2011). Cognitive load theory. W: J. P. Mestre i B. H. Ross (red.), *Psychology of learning and motivation* (t. 55, ss. 37–76). Elsevier. https://doi.org/10.1016/B978-0-12-387691-1.00002-8

Sweller, J., van Merriënboer, J. J. G., & Paas, F. G. W. C. (1998). Cognitive architecture and instructional design. *Educational Psychology Review, 10*(3), 251–296. https://doi.org/10.1023/A:1022193728205

Tankelevitch, L., Kewenig, V., Simkute, A., Scott, A. E., Sarkar, A., Sellen, A., & Rintel, S. (2024). The metacognitive demands and opportunities of generative AI. W: *Proceedings of the CHI Conference on Human Factors in Computing Systems* (ss. 1–24). ACM. https://doi.org/10.1145/3613904.3642902

Tytko, K., Roszkowski, M., Malucha, M., Walusiak, Ł., Ryłko, N., & Nurtazina, K. (2023). ChatGPT i przyszłość nauczania: Jak AI zmienia krajobraz edukacyjny. *Edukacja Biologiczna i Środowiskowa, 2*(80). https://doi.org/10.24131/3247.230210

Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. W: *Advances in Neural Information Processing Systems* (t. 30, ss. 5998–6008). Curran Associates.

Wilson, J., Zhang, S., Palermo, C., Cordero, T. C., Zhang, F., Myers, M. C., Potter, A., Eacker, H., & Coles, J. (2024). A latent Dirichlet allocation approach to understanding students' perceptions of automated writing evaluation. *Computers and Education Open, 6,* Artykuł 100194. https://doi.org/10.1016/j.caeo.2024.100194

Winne, P. H., & Hadwin, A. F. (1998). Studying as self-regulated learning. W: D. Hacker, J. Dunlosky, i A. Graesser (red.), *Metacognition in educational theory and practice* (ss. 277–304). Erlbaum.

Wooldridge, M. (2021). *A brief history of artificial intelligence: What it is, where we are, and where we are going.* Flatiron Books.

Wu, H., & Wang, X. (2026). AI-driven gamification and metacognitive strategy development: A study of primary school English vocabulary learning from a self-regulated learning perspective. *Frontiers in Psychology, 17,* Artykuł 1692949. https://doi.org/10.3389/fpsyg.2026.1692949

Xia, Q., Liu, Q., Tlili, A., & Chiu, T. K. F. (2026). A systematic literature review on designing self-regulated learning using generative artificial intelligence and its future research directions. *Computers & Education, 240,* Artykuł 105465. https://doi.org/10.1016/j.compedu.2025.105465

© 2026 Author(s). CC BY 4.0

Xu, J., Luo, Y., Wang, C., Wang, M., & Wu, Y. (2026). AI support in self-regulated learning: A decade of technological evolution and meta-analysis. *British Journal of Educational Technology*, 1–30. https://doi.org/10.1111/bjet.70058

Xu, X., Qiao, L., Cheng, N., Liu, H., & Zhao, W. (2025). Enhancing self-regulated learning and learning experience in generative AI environments: The critical role of metacognitive support. *British Journal of Educational Technology*, *56*(5), 1842–1863. https://doi.org/10.1111/bjet.13599

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

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

© 2026 Author(s). CC BY 4.0