

Dawid Wilczyński

PEDAGOGIUM WSNS

ORCID 0009-0007-9788-8753

DOI: <https://doi.org/10.35464/1642-672X.PS.2025.3.10>

Głębokie nauczanie w służbie edukacji: jak sztuczna inteligencja przeobraża procesy dydaktyczne

Deep Learning in the Service of Education: How Artificial Intelligence is Transforming Teaching Processes

ABSTRACT: Artificial Intelligence (AI) is one of the fastest-developing technologies, already significantly impacting many fields, including education. Rather than asking broad questions about how AI might influence the future of education, it's worth focusing on how it is currently changing educational processes. Today's implemented technologies not only support teaching but also redefine its foundations. Applications of AI, such as deep learning and adaptive systems, have begun to introduce a new quality in the teaching process. Personalized education has become a tangible achievement thanks to recommendation systems that adjust content to the individual needs of students based on the analysis of their performance and preferences. AI-integrated analytical tools help teachers identify knowledge gaps, allowing for more precise pedagogical interventions. This article discusses examples of deep learning applications in education, including tools for automatic grading of written work and recommendation systems that tailor educational content to students' individual needs. It also addresses the challenges that educational institutions face in applying AI, focusing mainly on the ethical issues of such solutions.

KEYWORDS: artificial intelligence (AI), deep learning, didactics, education, personalization, ethics.

STRESZCZENIE: Sztuczna inteligencja (SI) jest jedną z najszybciej rozwijających się technologii, która już teraz znacząco wpływa na wiele dziedzin życia, w tym także edukację. W przeciwieństwie do bardziej ogólnych pytań o to, jak SI może wpłynąć na przyszłość edukacji, warto skupić się na tym, jak faktycznie już zaczęła zmieniać procesy edukacyjne. Obecnie wdrażane technologie nie tylko wspierają dydaktykę, ale również

redefiniują jej fundamenty. Zastosowania SI, takie jak głębokie nauczanie (deep learning) oraz systemy adaptacyjne, zaczęły wprowadzać nową jakość w procesie nauczania. Personalizacja edukacji stała się realnym osiągnięciem dzięki systemom rekomendacyjnym, które dostosowują treści do indywidualnych potrzeb ucznia na podstawie analizy jego wyników i preferencji. Zintegrowane z SI narzędzia analityczne pomagają nauczycielom identyfikować luki w wiedzy uczniów, co umożliwia bardziej precyzyjne interwencje pedagogiczne. W artykule omówiono przykłady zastosowań głębokiego nauczania w edukacji, w tym narzędzia do automatycznego oceniania prac pisemnych, a także systemy rekomendacyjne, które dostosowują treści edukacyjne do indywidualnych potrzeb uczniów. Jednocześnie zwracając uwagę na wyzwania, przed którymi stoją instytucje edukacyjne wiążące się z zastosowaniem SI – skoncentrowanymi głównie na kwestiach etycznych takiego rozwiązania.

SŁOWA KLUCZOWE: sztuczna inteligencja (SI), głębokie nauczanie, dydaktyka, edukacja, personalizacja, etyka.

Wprowadzenie

Pięćdziesiąt lat temu człowiek po raz pierwszy wylądował na księżycu. Przedmiotowe wydarzenie zostało zdefiniowane jako ogromny skok technologiczny dla cywilizacji, gdyż od tamtej pamiętnej chwili ludzie zaczęli kolonizować kosmos. Miejsce tak odległe i nieosiągalne. Współcześnie powyższe wydarzenie nie wydaje się nam czymś nadzwyczajnym. Obecnie nasza technologia jest na jeszcze bardziej zaawansowanym poziomie, który pięćdziesiąt lat temu wydawał się czymś niemożliwym. Nasz współczesny świat coraz bardziej wykorzystuje narzędzia w postaci sztucznej inteligencji, która w znaczący sposób zmienia nasze myślenie o współczesnej edukacji. Rewolucja technologiczna odbywa się na naszych oczach. Jednak należy zauważyć, że ludzie o sztucznej inteligencji myśleli dużo wcześniej, zanim Neil Armstrong 20 lipca 1969 r. jako pierwszy człowiek zostawił ślad ludzkiej stopy na księżycu.

W 1955 roku John McCarthy z Dartmouth przekonał Marviną Minsky¹, Claude’a Shannona i Nathaniela Rochester’a, aby pomogli mu w zgromadzeniu amerykańskich naukowców zainteresowanych teorią automatów, sieciami neuronowymi i badaniami inteligencji. W 1956 r. zorganizowali oni dwumiesięczne warsztaty, w których uczestniczyło 10 osób, w tym: Allen Newell i Herbert Simon z Carnegie Tech², Trenchard More z Princeton, Arthur Samuel z IBM oraz Ray Solomonoff i Oliver Selfridge z MIT. W zaproszeniu na przedmiotowe warsztaty możemy przeczytać:

„Proponujemy, aby latem 1956 w Dartmouth College w mieście Hanover w stanie New Hampshire przeprowadzić dwumiesięczne warsztaty z zakresu

¹ Marvin Minsky wraz z Deanem Edwardem w 1950 r. zbudowali komputer, będący pierwszą sztuczną siecią neuronową. Komputer ten nazywał się SNARC (Stochastic Neural Analog Reinforcement Computer).

² Carnegie Tech obecnie funkcjonuje pod nazwą Carnegie Mellon University (CMU).

badania nad sztuczną inteligencją³, z udziałem 10 osób. Badania mają być prowadzone w oparciu o przypuszczenie, że każdy aspekt uczenia się lub jakąkolwiek inną cechę inteligencji można w zasadzie opisać na tyle dokładnie, że możliwe będzie stworzenie maszyny, która tę cechę zasymuluje. Podejmiemy próby określenia, jak można zmusić maszynę do używania i rozumienia języka, tworzenia abstrakcji i pojęć, rozwiązywania problemów zarezerwowanych dotychczas dla ludzi i samodoskonalenia się. Mamy nadzieję, że dla przynajmniej kilku z tych problemów możliwe jest uczynienie znacznego postępu, jeżeli zajmie się tym starannie dobrana grupa naukowców, współpracujących w ciągu lata” [Russell, Norving, 2023, s. 36].

Człowiek od dawna poszukiwał rozwiązania, które pozwoli na stworzenie maszyny, która w znaczącym stopniu zasymuluje ludzką inteligencję i usprawni procesy poznawcze człowieka, a nawet będzie z nim konkurować w analizie rzeczywistości.

Sztuczna inteligencja prowadzi do transformacji wielu sektorów, a jednym z najważniejszych obszarów jej zastosowania jest właśnie edukacja.

Wincenty Okoń, polski pedagog i teoretyk wychowania, zdefiniował dydaktykę jako naukę o nauczaniu i uczeniu się, która „zajmuje się badaniem procesów związanych z przekazywaniem i przyswajaniem wiedzy, umiejętności oraz kształtowaniem postaw” [Okoń, 2001, s. 96]. Obejmuje ona zarówno teoretyczne rozważania na temat procesu dydaktycznego, jak i praktyczne rozwiązania, które mają na celu optymalizację nauczania. Zgodnie z przytoczoną definicją Okonia, dydaktyka powinna badać także warunki, w jakich zachodzi nauczanie oraz poszukiwać najlepszych metod i środków, które mogą ten proces wspierać [Okoń 1995, s. 12].

Ten sam autor definiuje nauczanie jako „świadomie organizowaną działalność nauczyciela, która ma na celu nie tylko przekazywanie uczniom wiedzy i umiejętności, ale także kształtowanie ich samodzielności myślenia, zdolności do rozwiązywania problemów oraz motywacji do samodoskonalenia” [Okoń, 2001, s. 136]. Aspekt rozwiązywania problemów w nauczaniu u Okonia odnosi się do kształtowania zdolności uczniów do samodzielnego radzenia sobie z trudnościami poprzez logiczne myślenie, analizę sytuacji oraz wybór adekwatnych metod działania. Autor wskazuje, że nauczyciel powinien tworzyć sytuacje dydaktyczne, które pobudzają uczniów do aktywności intelektualnej i poszukiwania rozwiązań problemowych [Okoń, 1987, s. 65].

³ W zaproszeniu po raz pierwszy użyto wyrażenie „sztuczna inteligencja”.

Analizując wyżej przedstawione definicje dotyczące „dydaktyki” i „nauczania”, możemy odnieść nieodzowne wrażenia, że sztuczna inteligencja zgodnie z założeniami McCarthy miała realizować zadania w stosunku do jednostki, które Wincenty Okoń przypisał procesom dydaktycznym oraz nauczania.

Zatem właściwe pytanie nie będzie brzmiało, jak sztuczna inteligencja wpływa na procesy edukacyjne, lecz jak je zaczęła zmieniać.

Analiza danych edukacyjnych i dostosowywanie treści

Podstawą głębokiego uczenia są tzw. sztuczne sieci neuronowe (SNN, Artificial Neural Networks). Jest to pewien rodzaj algorytmów uczenia się maszynowego, inspirowanych strukturą i działaniem biologicznych neuronów w mózgu. Podstawą działania sieci neuronowej jest przetwarzanie informacji poprzez sztuczne neurony, które są połączone warstwami i uczą się na podstawie danych. Proces uczenia się polega na dostosowywaniu wag między neuronami na podstawie danych treningowych, co umożliwia sieci rozpoznawanie wzorców. Co istotne, w wyniku tego procesu sieć „uczy się”, modyfikując wagi połączeń, w celu minimalizacji błędów w swoich prognozach lub decyzjach [Haykin, 2008, s. 156]. Sztuczne sieci neuronowe mogą automatycznie dostosowywać proces nauczania do preferencji i możliwości uczniów, co czyni je kluczowym narzędziem w nowoczesnych systemach edukacyjnych.

Personalizacja nauczania polega na dostosowywaniu treści, metod i tempa nauczania do indywidualnych potrzeb, preferencji oraz umiejętności ucznia. Wincenty Okoń opracowując uniwersalne wymagania stawiane treściom kształcenia, wyróżnił wymagania z punktu widzenia ucznia:

- dostosowanie treści do możliwości ucznia (psychicznych, społecznych, konieczność uwzględnienia faz rozwojowych),
- dostosowanie treści do potrzeb rozwojowych człowieka [Okoń, 1992, s. 112–115].

Należy to rozumieć w ten sposób, że fundamentalną zasadą w odniesieniu do celów dydaktycznych jest odpowiednie dostosowanie treści kształcenia do możliwości i rozwoju ucznia.

Opierając się na psychologii rozwoju człowieka i korzystając z dorobku psychologii różnic indywidualnych, należy podkreślić, że wszyscy ludzie podlegają tej samej uniwersalnej zmianie jako istoty żywe (zgodność rozwoju z prawami natury) i jako istoty społeczne, żyjące pośród innych. Należy jednak zwrócić uwagę, że każdy z nas charakteryzuje się niepowtarzalną, indywidualną logiką rozwoju, związaną z tym, że każdy inaczej postrzega, interpretuje i przeżywa różne sytuacje w swoim życiu, każdy również na swój

sposób definiuje sytuacje, w jakich przychodzi mu podejmować decyzje i działać [Brzezińska, Appelt, Ziółkowska, 2023, s. 33].

Zgodnie z powyższym, rozwój każdego ucznia jest realizowany w indywidualny, niepowtarzalny sposób. Jest to istotny warunek, który w procesie edukacyjnym należy uwzględnić, czyniąc go bardziej efektywnym i angażującym samego ucznia. Wincenty Okoń w pracach podkreśla znaczenie indywidualizacji nauczania oraz potrzebę ciągłego dostosowywania metod dydaktycznych do zmieniających się potrzeb uczniów, co stanowi fundament nowoczesnej pedagogiki.

Zatem kolejnym pytaniem, które należałoby postawić jest, czy SI, a w szczególności głębokie nauczanie, jest nową metodą dydaktyczną, która uwzględnia zmieniające się potrzeby ucznia, o których pisał Wincenty Okoń?

Co wiemy?

W tradycyjnych modelach edukacji często przyjmuje się jeden, uniwersalny schemat nauczania, który nie zawsze uwzględnia różnorodność uczniów oraz ich indywidualne predyspozycje poznawcze. Natomiast wykorzystanie nowoczesnych technologii, takich jak SSN, pozwala na personalizację nauczania w sposób bardziej dynamiczny i dostosowany do każdego ucznia. Algoritmy te mogą analizować dane uczniów, takie jak postępy w nauce, preferencje stylu uczenia się, tempo pracy, a następnie na ich podstawie modyfikować ścieżki edukacyjne w sposób umożliwiający dostosowanie treści edukacyjnych do indywidualnych potrzeb i możliwości ucznia.

Systemy oparte na sztucznych sieciach neuronowych są zdolne do przetwarzania ogromnych ilości danych, takich jak wyniki testów, interakcje z materiałami edukacyjnymi, czas spędzony na poszczególnych zadaniach, a nawet aktywność ucznia w systemach e-learningowych. Dane te są następnie analizowane przez sieć neuronową, która identyfikuje wzorce związane z tempem przyswajania wiedzy przez ucznia, jego mocnymi i słabymi stronami oraz preferencjami dotyczącymi stylu nauki [Goodfellow, Bengio, Courville, 2016, s. 122–123]. Analizując dane dotyczące efektów nauczania, można dostosować treści kształcenia do poszczególnych uczniów, ich zdolności poznawczych i ich obecnego stopnia rozwoju. Przekłada się to na wzrost jakościowy procesu kształcenia. Nauczanie polega na zapamiętaniu i zrozumieniu przez uczniów treści podawanych przez nauczyciela. Jeżeli uczeń zapamiętał, ale nie zrozumiał materiału, istnieje duże prawdopodobieństwo, że na dalszych etapach kształcenia mogą wystąpić u niego braki edukacyjne.

Jeżeli utożsamiamy edukację jako rozwój, to powinniśmy go traktować jako przechodzenie od struktury podstawowej do bardziej złożonej. Jednak, aby „owo przejście” się wydarzyło, należy mieć informacje i wiedzę umożliwiające przedmiotową zmianę.

Po analizie danych sieć neuronowa jest w stanie dostosować ścieżkę edukacyjną do indywidualnych potrzeb ucznia. Na przykład, jeśli system zauważy, że uczeń ma trudności z konkretnym zagadnieniem, może zaproponować dodatkowe materiały, bardziej szczegółowe wyjaśnienia, a nawet zadania o zwiększonym poziomie trudności, które mają na celu wzmocnienie zrozumienia danego zagadnienia [Openici, Kerr, 2017], co znacząco wpływa na proces zrozumienia materiału przez ucznia. System tworzy najlepszą przestrzeń do rozwoju dla danego ucznia, uwzględniając jego indywidualny rozwój oraz predyspozycje.

Badania nad adaptacyjnymi systemami edukacyjnymi, takimi jak Knewton i ALEKS, udowodniły, że personalizacja oparta na algorytmach głębokiego uczenia znacząco wpływa na poprawę wyników uczniów, szczególnie w naukach ścisłych. Systemy te analizują duże zbiory danych edukacyjnych w czasie rzeczywistym, aby dostosować treści do indywidualnych potrzeb każdego ucznia, co prowadzi do efektywniejszego uczenia się. Knewton, jako system oparty na sztucznej inteligencji, tworzy zindywidualizowane ścieżki edukacyjne dla uczniów przez analizę ich wyników w czasie rzeczywistym. Platforma ta wykorzystuje technikę rozłożonego wzmocnienia (*spaced reinforcement*), co oznacza, że nowe informacje są wprowadzane stopniowo, a wcześniej zdobyta wiedza jest regularnie powtarzana. Takie podejście, inspirowane badaniami nad pamięcią Hermanna Ebbinghausa, pozwala uczniom na bardziej skuteczne przyswajanie materiału i lepsze zapamiętywanie go w dłuższej perspektywie czasowej.

Zastosowanie modeli matematycznych, takich jak krzywe zapominania i krzywe wzmacniania umiejętności, pozwala na śledzenie zmian w poziomie wiedzy ucznia i dostosowanie ścieżki nauki, aby skupić się na obszarach, które wymagają powtórzenia lub wzmocnienia. Jak wynika z badań, uczniowie korzystający z Knewton lepiej radzą sobie z nauką przedmiotów ścisłych, takich jak matematyka i nauki przyrodnicze, co jest efektem zindywidualizowanego podejścia do procesu uczenia się⁴, ⁵. Badania nad adaptacyjnymi systemami edukacyjnymi wykazały, że takie podejście przynosi wymierne korzyści

⁴ <https://blogs.ubc.ca/etec511dlgl/files/2013/10/Knewton-Adaptive-Learning-Whitepaper.pdf>

⁵ <https://d3.harvard.edu/platform-digit/submission/knewton-personalizes-learning-with-the-power-of-ai/>

w postaci poprawy wyników uczniów. Systemy takie jak Knewton wykorzystują big data oraz algorytmy sztucznej inteligencji, aby lepiej zrozumieć indywidualne potrzeby uczniów i dostarczać im treści edukacyjne, które są dostosowane do ich aktualnego poziomu wiedzy i umiejętności. Według badań, uczniowie korzystający z tych systemów osiągają lepsze wyniki w nauce, są bardziej zaangażowani, a ich poziom frustracji spada dzięki lepszemu dopasowaniu materiałów edukacyjnych⁶.

Automatyczne systemy oceny prac pisemnych oparte na sztucznej inteligencji (SI) są zbudowane na zaawansowanych technologiach, takich jak przetwarzanie języka naturalnego (ang. Natural Language Processing, NLP) oraz uczenie maszynowe (ang. Machine Learning, ML). Te technologie umożliwiają maszynom analizowanie i interpretowanie tekstu, co pozwala im oceniać prace pisemne według określonych kryteriów. Systemy automatycznej oceny prac pisemnych potrafią zidentyfikować poprawność gramatyczną, analizując składnię zdania, poprawność użycia znaków interpunkcyjnych oraz zgodność gramatyczną, np. relację między podmiotem a orzeczeniem. Technologia NLP (przetwarzanie języka naturalnego) rozpoznaje błędy składniowe i gramatyczne, takie jak niezgodność podmiotu z orzeczeniem lub nieprawidłowe formy czasownika [Attali, Burstein, 2006a].

Algorytmy sztucznej inteligencji oceniają również zgodność treści z tematem, analizując jakość argumentacji i logiczną spójność wypowiedzi. Przez porównanie pracy ucznia z wcześniej zaprogramowanymi wzorcami argumentacyjnymi, system może określić, czy wyrażone myśli są spójne i czy argumentacja jest logiczna [Attali, Burstein, 2006, s. 1–18; Zhang, Kauffman, 2016, s. 45–55].

Należy zwrócić uwagę, że omawiane narzędzie pozwala na bardziej spersonalizowane nauczanie, gdyż systemy SI mogą dostosować indywidualną informację zwrotną w postaci mocnych i słabych stron do każdej pracy. Tak zindywidualizowane podejście do prac ucznia pozwala na odpowiednie reakcje w metody nauczania w kontekście popełnianych błędów przez uczniów, a tym samym na lepsze ich zrozumienie. Analiza przez systemy SI skupia się na kontekście szczegółowym błędu, którego przyczyną mogą być braki ucznia w przedmiotowym obszarze bądź ograniczenia wynikające z poziomu rozwoju. Również trzeba podkreślić obiektywność maszyny w ocenianiu, co eliminuje subiektywność ocen (co często powoduje poczucie niesprawiedliwości wśród uczniów).

⁶ <https://d3.harvard.edu/platform-digit/submission/knewton-personalizes-learning-with-the-power-of-ai/>

Wprowadzenie sztucznej inteligencji do systemów edukacyjnych, w tym automatycznych systemów oceny prac pisemnych, niesie ze sobą liczne korzyści, ale należy pamiętać o wyzwaniach etycznych i technologicznych. Wymagają odpowiedzialnego podejścia, szczególnie jeśli chodzi o etykę i przygotowanie nauczycieli do pracy z tymi narzędziami. Etyczne wyzwania związane z SI w edukacji koncentrują się w obrębie dwóch ważnych aspektów: biasie algorytmicznym⁷ oraz ochronie danych uczniów.

Algorytmy głębokiego uczenia są podatne na uprzedzenia wynikające z jakości danych szkoleniowych, które nie odzwierciedlają różnorodności demograficznej uczniów. Algorytmy oceny mogą więc niesprawiedliwie oceniać uczniów z grup mniejszościowych lub o odmiennym tle kulturowym. Tego rodzaju problemy wynikają z ograniczeń w różnorodności danych, które mogą nie obejmować pełnego przekroju stylów pisania lub różnych poziomów językowych uczniów. Badania pokazują, że algorytmy mogą preferować styl pisania typowy dla konkretnej grupy etnicznej lub społecznej, co może skutkować niższymi ocenami dla uczniów z innych środowisk, a w konsekwencji prowadzić do nierówności w ocenianiu, co z kolei wpływa na poczucie sprawiedliwości i równości w edukacji [Caliskan, Bryson, Narayanan, 2017, s. 183–186].

Wobec powyższego może dochodzić do sytuacji, w której subiektywizm oceniania zostanie utrzymany w algorytmach SI, co dalej będzie pogłębiało poczucie niesprawiedliwości wśród uczniów, a to wpływa na ich stosunek do edukacji i satysfakcji z osiągniętych rezultatów.

Korzystanie z zaawansowanych technologii zawsze wiąże się z ryzykiem ujawnienia danych osobowych. Zbieranie i przetwarzanie danych osobowych uczniów w celu trenowania modeli SI rodzi poważne obawy dotyczące prywatności i bezpieczeństwa, zwłaszcza w przypadku analizy językowej lub monitorowania ich zachowań. Wiąże się to z ryzykiem naruszeń prywatności [Williamson, 2020, s. 1451–1468]. Takie zasoby danych mogą być interesujące dla aktorów zagrożenia⁸, aby zdobyć i wykorzystać je w celu uzyskania korzyści majątkowych lub w sposób nieetyczny. Wiele instytucji edukacyjnych nie ma wystarczających procedur ochrony danych, co może prowadzić do nieautoryzowanego dostępu lub nadużyć. Wymagałoby to wdrożenia odpowiednich standardów bezpieczeństwa czy norm, jak dla przykładu norma ISO 27001, dotycząca zarządzania bezpieczeństwem informacji. Jednak implementacja od-

⁷ Bias (uprzedzenia) – problem systematycznych uprzedzeń wynikających z danych treningowych, architektury modelu lub sposobu jego działania.

⁸ Aktor zagrożenia w kontekście bezpieczeństwa to osoby lub grupy, które mogą stwarzać ryzyko dla systemów, danych lub procesów.

powiednich procedur oraz procesów wymagałaby zatrudnienia dedykowanych osób bądź zespołów, zajmujących się bezpieczeństwem, a tym samym wiązałyby się z większymi kosztami, na które zwyczajnie placówki edukacyjne nie są przygotowane.

Rozwój sztucznej inteligencji w edukacji jest zjawiskiem, które będzie zyskiwało coraz większe znaczenie we współczesnym świecie. Obecne zastosowania SI, jak adaptacyjne systemy edukacyjne (np. Knewton, ALEKS) i automatyczne narzędzia oceny, mają kluczowy wpływ na personalizację procesu nauczania, pozwalając na dostosowanie tempa i treści edukacyjnych do indywidualnych potrzeb uczniów. Algorytmy głębokiego uczenia umożliwiają systemom zidentyfikowanie mocnych i słabych stron uczniów, co przekłada się na ich lepsze wyniki i zaangażowanie w naukę. Jednak wraz z zaletami personalizacji i efektywności pojawiają się wyzwania, głównie o charakterze etycznym i technologicznym. Bias algorytmiczny i ryzyko naruszenia prywatności to najważniejsze obszary wymagające przemyślnych regulacji i zaangażowania nauczycieli, aby uniknąć zjawiska nierówności oraz ochronić dane osobowe uczniów. W kontekście naszego podejścia do dydaktyki, wykorzystując nasze doświadczenia, należy rozważyć, czy SI – szczególnie głębokie uczenie – stanowi nową metodę dydaktyczną, adaptującą się do zmieniających się potrzeb uczniów i dążącą do realizacji celów edukacyjnych poprzez bardziej spersonalizowane podejście.

Temat SI w edukacji wymaga zatem dalszych badań i wypracowania regulacji, które pozwolą na pełne wykorzystanie jej potencjału w zgodzie z etycznymi normami.

Bibliografia

- Brzezińska A., Appelt K., Ziółkowska B. (2023). *Psychologia rozwoju człowieka*. Gdańsk: Gdańskie Wydawnictwo Pedagogiczne.
- Haykin, S. (2008). *Neural Networks and Learning Machines* (wyd. 3). Pearson Education.
- Okoń W. (1987). *Wprowadzenie do dydaktyki ogólnej*. Warszawa: PWN.
- Okoń W. (1992). *Wprowadzenie do dydaktyki ogólnej*. Warszawa: Wydawnictwo Naukowe PWN.
- Okoń W. (1995). *Zarys dydaktyki ogólnej*. Warszawa: Wydawnictwo Naukowe PWN.
- Okoń, W. (2001). *Nowy słownik pedagogiczny*. Warszawa: Wydawnictwo Naukowe PWN.
- Russell S., Norvig P. (2023). *Sztuczna inteligencja: Nowe spojrzenie*, t. 1 (wyd. 4). Wydawnictwo Helion S.A.
- Williamson B. (2020). Artificial Intelligence in Education: The Learning and Teaching Revolution. *Educational Technology Research and Development*, 68(4), 1451–1468.

Netografia

- Attali Y., Burstein, J. (2006). Automated Essay Scoring With e-rater® V. 2.0. *ETS Research Report Series*, (2), 1–18. <https://doi.org/10.1002/j.2333-8504.2006.tb02178.x> [data pobrania: 20.10.2024].
- Caliskan A., Bryson J.J., Narayanan A. (2017). Semantics Derived Automatically from Language Corpora Contain Human-Like Biases. *Science*, 356(6334), 183–186. <https://doi.org/10.1126/science.aal4230> [data pobrania: 20.10.2024].
- Knewton. (b.d.). *Adaptive Learning Whitepaper*, <https://blogs.ubc.ca/etec511dlg1/files/2013/10/Knewton-Adaptive-Learning-Whitepaper.pdf> [data pobrania: 20.10.2024].
- Knewton. (b.d.). *Personalizes Learning with the Power of AI*, <https://d3.harvard.edu/platform-digit/submission/knewton-personalizes-learning-with-the-power-of-ai/> [data pobrania: 20.10.2024].
- Openici S.A.D., Ker S. (2017). Exploring the Impact of Artificial Intelligence on Teaching and Learning in Higher Education. *Research and Practice in Technology Enhanced Learning*, 12(1), 22–36. <https://doi.org/10.1186/s41039-017-0048-8> [data pobrania: 20.10.2024].
- Zhang J., Kauffman D. (2016). Exploring the Effectiveness of Automated Writing Assessment: A Meta-Analysis. *Computers & Education*, 95, 45–55. <https://doi.org/10.1016/j.compedu.2016.01.002> [data pobrania: 20.10.2024].