



Złożenie pracy online:  
2025-02-27 23:06:14  
Kod pracy:  
21062/46405/CloudA

Łukasz Górnicki  
(nr albumu: 26870 )

Praca magisterska

## **Wpływ sztucznej inteligencji na rozwój dzieci i młodzieży**

## **The impact of artificial intelligence on the development of children and adolescents**

Wydział: Wyższa Szkoła Biznesu - National-Louis University

Kierunek: Psychologia

Specjalność: psychologia kliniczna i osobowości

Promotor: dr n. med. Bartłomiej Tarkowski

Dziękuję za wsparcie mojej żonie Aldonie, rodzicom, rodzinie, przyjaciołom i współpracownikom, którzy odciążali mnie w obowiązkach, abym mógł znaleźć czas na dokończenie studiów i napisanie pracy magisterskiej. Dziękuję również mojemu promotowowi Panu dr n. med. Bartłomiejowi Tarkowskiemu za okazaną pomoc.



## **Streszczenie**

Celem pracy jest zbadanie, jak interakcja z narzędziami opartymi na algorytmach sztucznej inteligencji kształtuje rozwój dzieci i młodzieży, ze szczególnym uwzględnieniem ich zdolności poznawczych, emocji oraz relacji społecznych.

## **Słowa kluczowe**

Sztuczna Inteligencja, AI, Rozwój dzieci, Rozwój młodzieży, Relacje społeczne, Zdolności poznawcze



## **Abstract**

The aim of the work is to examine how interaction with tools based on artificial intelligence algorithms shapes the development of children and adolescents, with particular emphasis on their cognitive abilities, emotions and social relations.

## **Keywords**

Artificial Intelligence, AI, Child development, Adolescent development, Social relations, Cognitive abilities



## Spis treści

Wstęp .....	4
<b>Rozdział 1. Sztuczna inteligencja – podstawowe pojęcia i zastosowania.....</b>	<b>8</b>
1.1 Definicja i historia sztucznej inteligencji.....	9
1.2 Kluczowe technologie w AI .....	12
1.2.1 Uczenie Maszynowe.....	12
1.2.2 Rodzaje Uczenia Maszynowego.....	14
1.2.3 Sieci Neuronowe i Głębokie Uczenie.....	23
1.2.4 Przetwarzanie Języka Naturalnego w kontekście AI.....	29
1.2.5 Modele Językowe.....	31
1.2.6 Wizja Komputerowa.....	33
1.2.7 Robotyka i AI.....	34
1.2.8 Chmura Obliczeniowa i Big Data.....	36
<b>Rozdział 2. Rozwój dzieci i młodzieży w świetle psychologii i pedagogiki.....</b>	<b>40</b>
2.1 Charakterystyka etapów rozwoju psychofizycznego.....	41
2.2 Rola otoczenia społecznego i technologii w rozwoju młodych ludzi.....	49
2.3. Wybrane teorie psychologiczne związane z uczeniem się i rozwojem.....	77
2.3.1 Teoria behawioralna.....	78
2.3.2 Teoria społecznego uczenia się Alberta Bandury.....	79
2.3.3 Teoria poznawcza Jeana Piageta.....	81
2.3.4 Socjokulturowa teoria Lwa Wygotskiego.....	83
2.3.5 Teoria konstruktywistyczna.....	85



<b>Rozdział 3. Wpływ sztucznej inteligencji na edukację i procesy uczenia się.....</b>	<b>88</b>
3.1 AI w edukacji: narzędzia wspierające naukę.....	90
3.2 Personalizacja nauczania dzięki AI.....	92
3.3 Wyzwania i zagrożenia związane z wykorzystaniem AI w edukacji.....	95
3.4 AI w twórczości i rozwoju umiejętności artystycznych.....	97
<b>Rozdział 4. Sztuczna inteligencja a zdrowie psychiczne dzieci i młodzieży.....</b>	<b>100</b>
4.1 Ekspozycja na treści generowane przez AI a wpływ na emocje i samopoczucie...101	
4.2 Problem uzależnienia od technologii i ekranów.....	103
4.3 Rola AI w terapii i wsparciu psychologicznym.....	104
<b>Rozdział 5. Wpływ AI na relacje społeczne dzieci i młodzieży.....</b>	<b>114</b>
5.1 Media społecznościowe i algorytmy – kształtowanie relacji rówieśniczych.....	115
5.2 Wirtualne przyjaźnie i interakcje z AI .....	116
5.3 Problemy etyczne i społeczne wynikające z korzystania z AI.....	124
<b>Rozdział 6. Zagrożenia i szanse wynikające z rozwoju AI.....</b>	<b>127</b>
6.1 Manipulacja i dezinformacja w sieci.....	128
6.2 Cyberbezpieczeństwo i prywatność danych dzieci i młodzieży.....	134
6.3 Możliwości pozytywnego wykorzystania AI w rozwoju młodych ludzi.....	139
<b>Rozdział 7. Metodologia badań własnych.....</b>	<b>147</b>
7.1 Problem i hipotezy badawcze.....	147
7.2 Charakterystyka zastosowanych metod.....	149
7.2.1 Kwestionariusz Dobrobytu cyfrowego.....	150
7.2.2 Skala Lęku Społecznego Leibowitza (LSAS).....	151
7.2.3 Test pamięci roboczej.....	152
7.3 Charakterystyka badanej grupy.....	153



<b>7.4 Procedura badania.....</b>	<b>159</b>
<b>7.5 Analiza zgromadzonego materiału z przeprowadzonych badań.....</b>	<b>160</b>
<b>7.6 Wnioski z przeprowadzanych badań.....</b>	<b>190</b>
<b>7.7 Ograniczenia badań własnych.....</b>	<b>194</b>
<b>Podsumowanie.....</b>	<b>197</b>
<b>Bibliografia.....</b>	<b>200</b>
<b>Spis tabel.....</b>	<b>234</b>
<b>Spis wykresów.....</b>	<b>235</b>
<b>Załączniki.....</b>	<b>236</b>



## Wstęp

Współczesny świat ulega dynamicznym zmianom, a rozwój technologii i wzrost powszechności narzędzi cyfrowych staje się nieodłącznym elementem codziennego życia. Wpływ komputeryzacji na różne dziedziny życia jest niezaprzeczalny w tym również rozwój, wychowanie i edukację dzieci oraz młodzieży. Postęp technologiczny, zwłaszcza w dziedzinie sztucznej inteligencji (ang. Artificial Intelligence, AI), w coraz większym stopniu kształtuje środowisko, w którym dorastają współczesne pokolenia. Mimo, że jeszcze niedawno AI była traktowana jako futurystyczna wizja, obecnie ma wpływ różne cechy naszego funkcjonowania – od medycyny, przez rynek pracy, aż po edukację (Russell & Norvig, 2022, s.19-35). Jej rozwój jest napędzany przez postępy w dziedzinach takich jak uczenie maszynowe, przetwarzanie języka naturalnego czy wizja komputerowa (Goodfellow, Bengio & Courville, 2018). Nowoczesne technologie cyfrowe już we wczesnym etapie rozwoju dziecka widocznie wpływają na sposób, w jaki się komunikuje, kształtuje swoją tożsamość, a także przyswaja wiedzę, wypierając tym samym środki oddziaływania starego nurtu oraz autorytety życia publicznego (Livingstone & Helsper, 2007). Coraz częstszym zjawiskiem jest to, że dziecko, zanim nauczy się mówić, wie, jak obsłużyć aplikację w telefonie, gry interaktywne, platformy socjalne oraz inne programy zbierające i przechowujące informacje o danej osobie, spędzając średnio 42 minuty dziennie korzystając z mediów ekranowych. (Common Sense Media, 2017). Algorytmy potrafią dostosować się do wieku i potrzeb, a nawet dorastać wraz z odbiorcą, dostarczając tym samym dopasowane treści skupiające uwagę użytkownika i modyfikując je w taki sposób, aby uwaga interesanta była skupiona jak najdłużej w aplikacji, w której aktualnie przebywa (Turkle, 2011, s.169-170). Człowiek staje się poniekąd produktem, którego zapłatą za korzystanie z usługi jest czas spędzony w witrynie internetowej, gdzie podawane są treści mające wpłynąć na postrzeganie rzeczywistości przez użytkownika w zaprogramowany przekaz twórców algorytmu (Van Dijck, 2013).

Aplikacje, w tym edukacyjne, wykorzystujące sztuczną inteligencję (AI), stają się coraz popularniejsze wśród dzieci i młodzieży. Dzięki nim dzieci mogą uczyć się w trybie interaktywnym i dostosowanym do swoich indywidualnych potrzeb. AI może dostarczać spersonalizowane treści edukacyjne, analizować postępy uczniów i dostosowywać program nauczania. Coraz częściej, oprócz dzieci i młodzieży AI wspiera również nauczycieli i pedagogów, umożliwiając lepsze dopasowanie treści edukacyjnych do indywidualnych



potrzeb uczniów oraz pomagając w monitorowaniu ich postępów (Selwyn, 2022). Wiele narzędzi cyfrowych pozwala również na bardziej spersonalizowane podejście do edukacji, co może zwiększać efektywność nauki i motywację uczniów. Tego typu algorytmy sprzyjają rozwijaniu umiejętności poznawczych, logicznego myślenia oraz kreatywności (Vygotsky, 1978).

Jednakże wraz z licznymi pozytywnymi zastosowaniami, pojawiają się także wyzwania i potencjalne zagrożenia związane z nadmiernym wpływem technologii na rozwój psychiczny oraz społeczny młodych. Z jednej strony AI może pomóc dzieciom w rozwijaniu umiejętności cyfrowych oraz przygotować je do funkcjonowania w zglobalizowanym i zautomatyzowanym świecie. Z drugiej strony częste i intensywne korzystanie z technologii cyfrowych może prowadzić do problemów związanych z koncentracją uwagi, osłabieniem zdolności do myślenia krytycznego, a także ograniczeniem interakcji międzyludzkich (Christakis & Moreno, 2009; Kowaluk-Romanek, 2019). Dzieci, które zbyt wcześnie i zbyt intensywnie wchodzi w kontakt z technologiami cyfrowymi, mogą doświadczać problemów z nawiązywaniem relacji społecznych, trudności w komunikacji interpersonalnej, a także wykazywać tendencje do izolacji i osamotnienia, co w przyszłości może przełożyć się na zaburzenia psychiczno-społeczne, a także na zwiększoną podatność na depresję lub podejmowanie prób samobójczych. Szczególnie podatne na tego typu prawdopodobieństwa będą dzieci od najmłodszych lat zastępujące interakcje społeczne kontaktami z technologią (Livingstone & Helsper, 2007).

Dlatego istnieje wiele dylematów związanych z rolą społeczeństwa, odpowiedzialnością rodziców oraz instytucji edukacyjnych w kształtowaniu właściwych postaw wobec sztucznej inteligencji, które powinny we właściwy i etyczny sposób kształtować i nadzorować dostęp dzieci i młodzieży, aby jej wpływ był jak najbardziej korzystny, a ryzyko ograniczone (Christakis & Moreno, 2009). Wprowadzenie AI do edukacji i życia codziennego dzieci powinno być bowiem ściśle kontrolowane i regulowane, aby uniknąć długofalowych konsekwencji oraz ewentualnych negatywnych skutków.

Kolejną istotną sprawą jest bezpieczeństwo online. AI może pomagać w monitorowaniu zachowań online i wykrywaniu potencjalnych zagrożeń, co pozwala rodzicom i opiekunom na zapewnienie bezpiecznego środowiska online. Jest to szczególnie ważne w dobie, gdy młodzi ludzie spędzają coraz więcej czasu z inteligentnymi urządzeniami i aplikacjami (Twenge, 2017). Sztuczna inteligencja może ostrzegać przed kontaktami z nieodpowiednimi treściami



lub osobami, co zwiększa ochronę dzieci w cyfrowym świecie. Algorytmy AI są również skuteczne w wykrywaniu cyberprzemocy czy prób oszustw, analizując wzorce zachowań użytkowników w sieci (Shamiulla, 2019).

Dodatkowo zaawansowane technologie pozwalają na tworzenie filtrów treści, które chronią młodzież przed dostępem do szkodliwych materiałów. Współczesne aplikacje edukacyjne wspierane przez AI uczą młodych ludzi zasad bezpiecznego korzystania z Internetu, co przyczynia się do ich świadomego funkcjonowania w środowisku cyfrowym (Livingstone, 2011). Platformy społecznościowe również wykorzystują sztuczną inteligencję do usuwania toksycznych treści i promowania pozytywnych interakcji. Personalizowane porady dostarczane przez systemy AI pomagają użytkownikom w rozpoznawaniu potencjalnych zagrożeń, takich jak phishing czy manipulacja w sieci (Gillespie, 2018; Zhou, 2021).

Narzędzia te wspierają również budowanie zdrowych nawyków cyfrowych, takich jak ograniczanie czasu spędzanego przed ekranem. Mimo to należy pamiętać, że sztuczna inteligencja, choć niezwykle pomocna, nie zastąpi roli rodziców i opiekunów w edukacji młodzieży na temat bezpiecznego korzystania z technologii (Turkle, 2011). Szczególnie w erze komercjalizacji usług cyfrowych, gdzie każdego użytkownika stara się zmonetyzować poprzez wyświetlanie treści sponsorowanych, co znacznie utrudnia wprowadzenie idei, algorytmów ograniczających spędzanie czasu przed ekranem.

Niniejsza praca ma na celu zbadanie, jak interakcja z narzędziami opartymi o algorytmy sztucznej inteligencji kształtują rozwój dzieci i młodzieży. Cele szczegółowe pracy obejmują analizę wpływu sztucznej inteligencji na różne płaszczyzny funkcjonowania młodzieży. Po pierwsze, skoncentrowano się na ocenie jej oddziaływania na zdolności poznawcze, takie jak koncentracja, pamięć robocza czy umiejętność rozwiązywania problemów. Po drugie, podjęto się analizy wpływu AI na emocje młodych ludzi, w tym poziom stresu, satysfakcję oraz poczucie własnej wartości. Po trzecie, zbadano, w jaki sposób technologie AI kształtują relacje społeczne młodzieży zarówno w przestrzeni wirtualnej, jak i w codziennych kontaktach w świecie realnym. Szczególną uwagę poświęci się możliwym długoterminowym konsekwencjom wynikającym z wczesnej interakcji z zaawansowanymi technologiami. Przedstawione w pracy analizy oraz wnioski mają na celu nie tylko ukazanie wpływu AI na rozwój młodych ludzi, ale także wypracowanie wskazówek, jak kształtować odpowiedzialne podejście do tej technologii. Może to stać się istotnym wsparciem dla rodziców, nauczycieli oraz decydentów, którzy mają wpływ na przyszłość cyfrowego pokolenia szczególnie w tak



ważnych dziedzinach jak edukacja, zdrowie psychiczne, rozwój emocjonalny oraz zdolność do nawiązywania relacji społecznych.

W pracy sformułowano także podstawowe hipotezy badawcze, które poddano weryfikacji:

- **H1:** Korzystanie z technologii opartych na AI ma istotny wpływ na zdolności poznawcze młodzieży, zwiększając ich efektywność w zadaniach wymagających analizy i przetwarzania informacji.
- **H2:** Sztuczna inteligencja w środowisku cyfrowym wpływa na poziom emocji u dzieci i młodzieży, zarówno pozytywnie (np. poprzez redukcję stresu dzięki aplikacjom wspierającym), jak i negatywnie (np. poprzez uzależnienie od urządzeń).
- **H3:** Wykorzystanie AI w komunikacji cyfrowej modyfikuje sposób budowania relacji społecznych wśród młodych ludzi, wpływając na ich zdolność do nawiązywania i utrzymywania kontaktów w rzeczywistości offline.

W oparciu o powyższe hipotezy sformułowano pytania badawcze:

1. W jaki sposób AI wpływa na koncentrację i pamięć roboczą u dzieci i młodzieży?
2. Czy korzystanie z AI wspomaga rozwój emocjonalny młodych użytkowników, czy raczej prowadzi do zwiększenia poziomu stresu?
3. Jakie zmiany w interakcjach społecznych młodzieży wynikają z wykorzystania AI w komunikacji i mediach społecznościowych?

Do przeprowadzenia analizy zaplanowano wykorzystanie następujących narzędzi badawczych:

- Kwestionariusza Dobrobytu Cyfrowego opracowanego na potrzeby niniejszej pracy.
- Skali Lęku Społecznego Leibowitza (The Leibowitz Social Anxiety Scale – LSAS).
- Testu pamięci roboczej, stworzonego na potrzeby niniejszej analizy.

Praca ma na celu nie tylko zrozumienie wpływu AI na różne ujęcia rozwoju młodych ludzi, ale także wskazanie potencjalnych wyzwań i zagrożeń związanych z rosnącą obecnością sztucznej inteligencji w ich codziennym życiu.

## Rozdział 1. Sztuczna inteligencja – podstawowe pojęcia i zastosowania

Pierwszy rozdział pracy jest poświęcony przedstawieniu podstawowych pojęć związanych z tematem, takich jak definicje sztucznej inteligencji, jej obecne zastosowania w życiu codziennym, edukacji oraz formy, w jakich może być wykorzystywana przez dzieci i młodzież. Początki sztucznej inteligencji sięgają połowy XX wieku, kiedy to Alan Turing zadał pytanie: "Czy maszyny mogą myśleć?" i zaproponował słynny test Turinga jako sposób oceny inteligencji maszyn (Turing, 1950). W kolejnych dekadach AI przeszła przez różne fazy rozwoju, od entuzjazmu po tzw. "zimy AI", czyli okresy spowolnienia badań i inwestycji. Jednak w ostatnich latach obserwujemy gwałtowny wzrost zainteresowania uczeniem maszynowym, głównie dzięki dostępności dużych zbiorów danych oraz zwiększonej mocy obliczeniowej (Nilsson, 2010).

Współczesne zastosowania sztucznej inteligencji są niezwykle szerokie i różnorodne. W medycynie algorytmy pomagają w diagnozowaniu chorób poprzez analizę obrazów medycznych z precyzją przewyższającą ludzkich specjalistów (Esteva, 2017). W sektorze finansowym jest wykorzystywana do analizy ryzyka, wykrywania oszustw oraz automatyzacji procesów decyzyjnych (Lakhchini, 2022). W przemyśle wspomaga optymalizację procesów produkcyjnych, zarządzanie łańcuchem dostaw oraz przewidywanie awarii maszyn (Lee, Bagheri, & Kao, 2015).

Jednocześnie rozwój AI stawia przed nami wiele wyzwań i rodzi liczne pytania etyczne. Kwestie takie jak prywatność danych, bezpieczeństwo systemów autonomicznych, uprzedzenia algorytmiczne czy wpływ na rynek pracy są przedmiotem intensywnych debat (Floridi, 2018). W miarę jak sztuczna inteligencja staje się coraz bardziej integralną częścią naszego życia, konieczne jest zrozumienie jej podstawowych pojęć oraz świadome podejście do jej wdrażania i regulacji.

Celem tego rozdziału jest przedstawienie fundamentalnych koncepcji związanych z sztuczną inteligencją oraz omówienie jej głównych zastosowań. Rozpocniemy od definicji AI i jej historii, następnie omówimy kluczowe pojęcia, takie jak uczenie maszynowe, sieci neuronowe czy przetwarzanie języka naturalnego. Przedstawione zostaną różne podejścia do uczenia



maszynowego, takie jak uczenie nadzorowane, nienadzorowane i przez wzmocnienie, z podkreśleniem ich zalet, ograniczeń i obszarów zastosowań.

Przyjrzymy się również praktycznym zastosowaniom w różnych sektorach gospodarki i życia codziennego, podkreślając zarówno korzyści, jak i potencjalne ryzyka (Russell & Norvig, 2022; Goodfellow, Bengio, & Courville, 2016). Poprzez dogłębną analizę tematu, pragnę dostarczyć kompleksowego spojrzenia na sztuczną inteligencję – jej możliwości, ograniczenia oraz wpływ na współczesny świat. Mam nadzieję, że lektura tego rozdziału przyczyni się do lepszego zrozumienia potencjału AI i pozwoli na bardziej świadome uczestnictwo w dyskusji na temat przyszłości w rozwoju dzieci i młodzieży.

### 1.1 Definicja i historia sztucznej inteligencji

Sztuczna inteligencja (ang. Artificial Intelligence, AI) jest interdyscyplinarną dziedziną nauki i technologii, która zajmuje się tworzeniem systemów zdolnych do wykonywania zadań wymagających inteligencji ludzkiej. Obejmuje to zdolności takie jak uczenie się, rozumowanie, rozwiązywanie problemów, percepcja, rozumienie języka naturalnego oraz podejmowanie decyzji (Nilsson, 1998). Istotą AI jest zdolność maszyn do naśladowania procesów myślowych człowieka lub wykonywania czynności wymagających ludzkiego intelektu.

Jedna z powszechnie akceptowanych definicji AI została zaproponowana przez Johna McCarthy'ego (2007, s. 2), jednego z pionierów tej dziedziny, według niego jest to "nauka i inżynieria tworzenia inteligentnych maszyn, zwłaszcza inteligentnych programów komputerowych. Jest to związane z podobnym zadaniem używania komputerów do zrozumienia ludzkiej inteligencji, ale AI nie musi ograniczać się do metod, które są biologicznie obserwowalne "

Russell i Norvig (2022 s. 20-23) proponują cztery różne podejścia do definiowania sztucznej inteligencji. Pierwsze z nich to systemy myślące jak ludzie, które skupiają się na procesach myślowych i kognitywnych, próbując odwzorować sposób, w jaki ludzie myślą. Drugie podejście dotyczy systemów działających jak ludzie, czyli tworzenia maszyn, które zachowują się podobnie do ludzi, naśladując ludzkie zachowania w różnych sytuacjach. Trzecie podejście obejmuje systemy myślące racjonalnie, które dążą do logicznego myślenia i wnioskowania, opierając się na zasadach racjonalności i logiki formalnej. Wreszcie, czwarte podejście to systemy działające racjonalnie, polegające na projektowaniu agentów, którzy



działają w sposób racjonalny w celu osiągnięcia swoich celów, optymalizując swoje działania zgodnie z określonymi kryteriami efektywności.

McCorduck (2004, s.23-30) twierdzi, że korzenie sztucznej inteligencji sięgają starożytności, gdzie filozofowie tacy jak Arystoteles zastanawiali się nad naturą myślenia i logiki. Jednak formalne narodziny AI jako dziedziny naukowej datuje się na konferencję w Dartmouth College w 1956 roku, zorganizowaną przez Johna McCarthy'ego, Marviną Minsky'ego, Nathanaela Rochesterą i Claude'a Shannona. To właśnie na tej konferencji po raz pierwszy użyto terminu "sztuczna inteligencja" (Russell & Norvig, 2022). W początkowych latach badacze byli pełni optymizmu, powstały wtedy pierwsze programy zdolne do rozwiązywania problemów matematycznych i logicznych. Jednym z pierwszych sukcesów było opracowanie programów grających w szachy oraz systemów dowodzenia twierdzeń matematycznych takich jak Logic Theorist (Newell & Simon, 1956) oraz General Problem Solver (GPS) (Newell & Simon, 1961). W 1966 roku Joseph Weizenbaum stworzył program ELIZA, symulujący rozmowę z psychoterapeutą, co było przykładem przetwarzania języka naturalnego (Weizenbaum, 1966). Optymizm lat 60-tych ustąpił miejsca sceptycyzmowi w latach 70-tych, kiedy okazało się, że wiele obietnic AI jest trudnych do zrealizowania z powodu ograniczeń technologicznych i braku wystarczającej mocy obliczeniowej. Raport Lighthilla z 1973 roku w Wielkiej Brytanii krytykował postępy w AI, co doprowadziło do zmniejszenia finansowania badań i spadku zainteresowania tą dziedziną. W latach 80-tych nastąpił renesans AI dzięki rozwojowi systemów eksperckich, bazujących na regułach i bazach wiedzy, które wykorzystywały wiedzę specjalistów do rozwiązywania konkretnych problemów. System MYCIN, opracowany przez Edwarda Shortliffe'a, był w stanie diagnozować infekcje bakteryjne i sugerować terapie (Shortliffe, 1976). Rządy i korporacje zaczęły inwestować w AI, widząc w niej potencjał komercyjny. Z początkiem lat 90-tych systemy eksperckie zaczęły tracić na popularności z powodu kosztów utrzymania i ograniczeń funkcjonalnych. To doprowadziło do kolejnego spadku zainteresowania AI. Jednak w tym samym czasie rozwijało się uczenie maszynowe (machine learning), które zaczęło zyskiwać na znaczeniu dzięki algorytmom takim jak drzewa decyzyjne, sieci neuronowe i metody statystyczne (Mitchell, 1997). Początek XXI wieku przyniósł przełom w AI dzięki uczeniu głębokiemu, które wykorzystuje wielowarstwowe sieci neuronowe do analizy złożonych danych. W 2012 roku sieć AlexNet wygrała konkurs ImageNet, osiągając niespotykaną wcześniej dokładność w rozpoznawaniu obrazów (Krizhevsky, Sutskever, & Hinton, 2012). To wydarzenie zainspirowało dalsze badania i zastosowania uczenia głębokiego w różnych dziedzinach.



W kolejnych latach AI osiągnęła kolejne kamienie milowe w 2011 roku system IBM Watson wygrał teleturniej "Jeopardy!", demonstrując zaawansowane przetwarzanie języka naturalnego (Ferrucci, 2010). W 2016 roku Program AlphaGo firmy DeepMind pokonał mistrza świata w grze Go, Lee Sedola, wykorzystując połączenie uczenia głębokiego i uczenia przez wzmacnianie (Silver, 2016). A w roku 2018 GPT (Generative Pre-trained Transformer) zrewolucjonizował przetwarzanie języka naturalnego, umożliwiając generowanie spójnych i koherentnych tekstów (Radford, 2018). Obecnie Sztuczna inteligencja jest integralną częścią wielu technologii, znajduje zastosowanie w wielu dziedzinach, takich jak analiza obrazów (Google Lens, Chat GPT), wirtualni asystenci wykorzystujący AI do interpretacji poleceń głosowych (Siri, Alexa, Google Assistant), algorytmy rekomendujące filmy na podstawie wcześniejszych wyborów (Netflix, Amazon Prime) czy autonomiczne pojazdy takie jak Tesla zdolne do samodzielnej jazdy dzięki zaawansowanym systemom AI (Litman, 2020).

W trakcie swojego rozwoju sztuczna inteligencja przeszła przez różne paradygmaty. Początkowo dominowało podejście symboliczne AI, które opierało się na manipulacji symbolami i regułach logiki. Metoda ta skupiała się na reprezentacji wiedzy w sposób jawny i wykorzystywała formalne systemy logiczne do rozwiązywania problemów. Następnie nastąpił zwrot w kierunku uczenia maszynowego, koncentrującego się na tworzeniu algorytmów zdolnych do uczenia się na podstawie danych. Pozwoliło to systemom na poprawę wydajności poprzez analizę i wykrywanie wzorców w dużych zbiorach danych. Przełomem było uczenie głębokie, które wykorzystuje wielowarstwowe sieci neuronowe do modelowania złożonych wzorców i reprezentacji. Dzięki temu możliwe stało się osiągnięcie znaczących postępów w dziedzinach takich jak rozpoznawanie obrazów, przetwarzanie języka naturalnego czy analiza dźwięku.

Aktualnie sztuczna inteligencja jest często postrzegana nie tylko jako narzędzie techniczne, ale również jako dziedzina o znaczeniu społecznym i etycznym. Pojawiają się dyskusje na temat wpływu AI na rynek pracy, prywatność danych oraz kwestie moralne związane z autonomią maszyn (Brynjolfsson & McAfee, 2015). Te debaty podkreślają konieczność rozważenia szerszych konsekwencji wdrażania AI w społeczeństwie, aby zapewnić, że rozwój technologiczny idzie w parze z poszanowaniem wartości etycznych i interesem publicznym

Historia sztucznej inteligencji to historia ambitnych celów, sukcesów i porażek. Od początkowego optymizmu, przez okresy stagnacji, aż po współczesny rozkwit, AI nieustannie ewoluuje. Dzięki postępom w uczeniu maszynowym i głębokim, AI stała



się elementem nowoczesnej technologii, wpływając na wiele dyscyplin naszego życia. Zrozumienie jej historii i definicji jest kluczowe dla dalszego rozwoju tej dziedziny oraz świadomego korzystania z jej osiągnięć.

## 1.2 Kluczowe technologie w AI

### 1.2.1 Uczenie Maszynowe

Uczenie maszynowe (UM) jest jedną z poddziedzin sztucznej inteligencji, koncentrującą się na opracowywaniu algorytmów i modeli, które umożliwiają systemom komputerowym uczenie się na podstawie danych i doświadczeń, bez potrzeby wyraźnego programowania każdej funkcjonalności do wykonywania konkretnych zadań (Mitchell, 1997). W erze Big Data i rosnącej mocy obliczeniowej, UM stało się nieodzownym narzędziem w analizie danych, przewidywaniu trendów oraz automatyzacji złożonych procesów w różnych sektorach, takich jak medycyna, finanse czy transport (Murphy, 2012). Rozwój uczenia maszynowego przyczynił się do powstania innowacyjnych rozwiązań, takich jak rozpoznawanie mowy i obrazów, systemy rekomendacyjne czy autonomiczne pojazdy. Dzięki zdolności do adaptacji i uczenia się z doświadczenia, systemy oparte na UM mogą przewyższać tradycyjne podejścia programistyczne w zadaniach, które są trudne do sformalizowania za pomocą reguł (Bishop, 2006).

Według klasycznej definicji zaproponowanej przez Toma Mitchella (1997, s. 2-5): "Program komputerowy uczy się z doświadczenia E w odniesieniu do pewnych klas zadań T i miary wydajności P, jeśli jego wydajność w zadaniach z T, mierzona przez P, poprawia się wraz z doświadczeniem E." Ta definicja podkreśla trzy kluczowe komponenty. Doświadczenie (E), przez które rozumiemy zbiór danych lub interakcji, na podstawie których system się uczy. Może to być zbiór oznaczonych przykładów, dane sensoryczne czy informacje zwrotne z otoczenia. Zadania (T) a konkretne problemy lub czynności, które system ma wykonywać. Przykłady obejmują klasyfikację obrazów, przewidywanie wartości liczbowych, rozpoznawanie mowy czy sterowanie robotem. Miarą wydajności (P) będącą kryterium oceny, jak dobrze system wykonuje zadania T. Może to być dokładność klasyfikacji, błąd średniokwadratowy, zysk finansowy czy inna miara dostosowana do specyfiki zadania. Uczenie maszynowe pozwala na tworzenie modeli, które potrafią generalizować, czyli zastosować wiedzę zdobytą na danych treningowych do nowych, niewidzianych wcześniej danych. Jest to możliwe dzięki zdolności algorytmów do wykrywania wzorców i zależności w danych (Bishop, 2006).



Uczenie maszynowe odgrywa kluczową rolę w dzisiejszym świecie z kilku istotnych powodów. Po pierwsze, zapewnia skalowalność, automatyzując analizę i interpretację dużych zbiorów danych, co byłoby niemożliwe do osiągnięcia przez człowieka w rozsądnym czasie. Dzięki temu możliwe jest przetwarzanie ogromnych ilości informacji w sposób efektywny i szybki. Po drugie, charakteryzuje się adaptacyjnością. Systemy uczące się mogą dostosowywać się do zmieniających się warunków i danych w dynamicznych środowiskach. Pozwala to na ciągłe ulepszanie modeli i ich zdolność do reagowania na nowe wyzwania. Dzięki zaawansowanym algorytmom i dużym ilościom danych, modele uczenia maszynowego mogą przewyższać tradycyjne metody w złożonych zadaniach, dostarczając precyzyjnych wyników. To czyni je niezastąpionymi w dziedzinach wymagających wysokiej precyzji i niezawodności. Wreszcie, uczenie maszynowe napędza innowacyjność, umożliwiając tworzenie nowych produktów i usług, takich jak inteligentni asystenci, systemy rekomendacyjne czy diagnostyka medyczna oparta na sztucznej inteligencji. Przyczynia się to do rozwoju technologicznego i poprawy jakości życia.

Przykłady zastosowań uczenia maszynowego są liczne i różnorodne. W rozpoznawaniu obrazów i wideo modele potrafią klasyfikować obiekty na zdjęciach, wykrywać twarze oraz analizować ruch (Krizhevsky, Sutskever & Hinton, 2012). W przetwarzaniu języka naturalnego stosuje się je do tłumaczenia maszynowego, analizy sentymentu czy generowania tekstu (Goldberg, 2017). W prognozowaniu i analizie szeregów czasowych pomagają przewidywać trendy finansowe, zapotrzebowanie na energię oraz zmiany klimatyczne (Box, Jenkins & Reinsel, 2015). Systemy rekomendacyjne oferują personalizowane sugestie produktów, filmów czy muzyki na podstawie wcześniejszych preferencji użytkownika (Ricci, Rokach & Shapira, 2015). W medycynie i biologii wspierają diagnostykę chorób, odkrywanie nowych leków oraz analizę genomu (Esteva, 2017). Pomimo licznych sukcesów, uczenie maszynowe napotyka również na wyzwania. Jakość i dostępność danych są kluczowe, ponieważ modele są tak dobre, jak dane, na których są trenowane. Niedokładne lub stronicze dane mogą prowadzić do błędnych wniosków (Žliobaitė, 2017, s. 2). Problem przeuczenia tzw. overfitting pojawia się, gdy model uczy się szczegółów i szumów w danych treningowych, tracąc zdolność do generalizacji (Goodfellow, Bengio & Courville, 2016). Objaśnialność i interpretowalność stanowią wyzwanie, ponieważ złożone modele, zwłaszcza głębokie sieci neuronowe, są często trudne do zrozumienia, co utrudnia interpretację ich decyzji (Doshi-Velez & Kim, 2017). Ponadto, bezpieczeństwo i etyka stają się coraz ważniejsze, gdyż wykorzystanie

uczenia maszynowego rodzi pytania dotyczące prywatności, uprzedzeń algorytmicznych i potencjalnych nadużyć (Floridi, 2018).

Podsumowując, uczenie maszynowe jest nieodłącznym elementem współczesnej sztucznej inteligencji, dostarczając narzędzi do analizy danych i tworzenia inteligentnych systemów. Jego rozwój ingeruje na wiele czynników życia codziennego i przemysłu, otwierając nowe możliwości, ale także stawiając przed nami wyzwania wymagające świadomego i odpowiedzialnego podejścia.

## 1.2.2 Rodzaje Uczenia Maszynowego

### Uczenie Nadzorowane

Uczenie nadzorowane jest fundamentalnym i szeroko stosowanym podejściem w uczeniu maszynowym. Polega ono na trenowaniu modelu na zbiorze danych zawierającym zarówno dane wejściowe, jak i odpowiadające im poprawne wyjścia, zwane etykietami. Celem tego podejścia jest nauczenie modelu ogólnej reguły łączącej wejścia z wyjściami, aby model mógł przewidywać poprawne wyjścia dla nowych, nieznanymi danych wejściowych (Goodfellow, Bengio & Courville, 2018, s. 141-146).

Proces uczenia nadzorowanego obejmuje kilka etapów. Pierwszym z nich jest zgromadzenie danych treningowych, które składają się z par wejść i odpowiadających im wyjść. Dane te powinny być reprezentatywne dla problemu, który model ma rozwiązać. Następnie wybierany jest odpowiedni algorytm lub architektura modelu, taki jak regresja liniowa, drzewa decyzyjne czy sieci neuronowe (Kotsiantis, 2007). Kolejnym krokiem jest trenowanie modelu poprzez minimalizację funkcji kosztu, która mierzy różnicę między przewidywanymi a rzeczywistymi wyjściami. Optymalizacja jest często przeprowadzana za pomocą algorytmów, takich jak metoda gradientu prostego. Ostatnim etapem jest walidacja i testowanie modelu na zestawach walidacyjnym i testowym, aby sprawdzić jego zdolność do generalizacji na nowe dane (Bishop, 2006, s. 239-240).

Uczenie nadzorowane dzieli się na dwa główne typy problemów: klasyfikację i regresję. W klasyfikacji celem jest przypisanie danych wejściowych do jednej z predefiniowanych kategorii. Przykłady obejmują rozpoznawanie obrazów czy klasyfikację e-maili jako spam lub nie-spam. Uczy się wzorców w danych, takich jak obecność określonych słów czy fraz charakterystycznych dla spamu. Po treningu model może z określonym poziomem dokładności klasyfikować nowe, nieoznaczone e-maile (Duda, Hart & Stork, 2001). Regresja natomiast



skupia się na przewidywaniu ciągłej wartości wyjściowej na podstawie danych wejściowych, na przykład prognozowanie cen nieruchomości czy przewidywanie zużycia energii (Montgomery, Peck & Vining, 2012, s.59).

Wśród popularnych algorytmów stosowanych w uczeniu nadzorowanym znajdują się regresja liniowa i logistyczna, używane odpowiednio w problemach regresji i klasyfikacji binarnej (Hosmer, Lemeshow & Sturdivant, 2013, s. 260-339). Drzewa decyzyjne modelują decyzje i ich możliwe konsekwencje, podczas gdy maszyny wektorów nośnych (SVM) wykorzystują hiperpowierzchnie w przestrzeni wielowymiarowej do separacji danych. Sieci neuronowe, inspirowane biologicznymi sieciami neuronowymi, są zdolne do modelowania złożonych nieliniowych zależności (Goodfellow, Bengio & Courville, 2018).

Uczenie nadzorowane znajduje zastosowanie w wielu dziedzinach. W rozpoznawaniu obrazu służy do klasyfikacji obrazów, detekcji obiektów i rozpoznawania twarzy. W przetwarzaniu języka naturalnego jest wykorzystywane do analizy sentymentu, klasyfikacji tekstu czy rozpoznawania mowy. W sektorze finansowym pomaga w wykrywaniu oszustw, ocenie ryzyka kredytowego oraz prognozowaniu cen akcji. W medycynie wspiera diagnozę chorób na podstawie danych medycznych i analizę obrazów medycznych.

Zalety uczenia nadzorowanego obejmują wysoką dokładność przewidywań dzięki wykorzystaniu etykietowanych danych oraz interpretowalność niektórych modeli, takich jak drzewa decyzyjne. Jednak metoda ta ma również swoje ograniczenia. Wymaga dużej ilości etykietowanych danych, co może być kosztowne i czasochłonne w pozyskiwaniu i etykietowaniu. Istnieje także ryzyko przeuczenia (overfitting), gdy model uczy się szumu w danych treningowych, co obniża jego zdolność do generalizacji. Ponadto trudność w znalezieniu odpowiedniej równowagi między niedouczeniem a przeuczeniem, znana jako problem bias-variance, stanowi dodatkowe wyzwanie (Geman, Bienenstock & Doursat, 1992).

W ostatnich latach rozwijane są techniki mające na celu zmniejszenie zapotrzebowania na duże zbiory etykietowanych danych. Uczenie przenoszone (transfer learning) polega na wykorzystaniu wiedzy z modeli trenowanych na dużych zbiorach danych do nowych, pokrewnych zadań (Pan & Yang, 2010).

Uczenie nadzorowane stanowi podstawę wielu współczesnych aplikacji uczenia maszynowego. Pomimo swoich ograniczeń, pozostaje kluczową techniką ze względu na efektywność i szerokie



zastosowanie. Rozwój nowych metod i algorytmów w tej dziedzinie nadal przyczynia się do postępów w sztucznej inteligencji.

## Uczenie Nienadzorowane

Uczenie nienadzorowane jest istotnym podejściem w dziedzinie uczenia maszynowego, które różni się od uczenia nadzorowanego brakiem etykiet w danych treningowych. W tym podejściu modele próbują odkrywać ukryte struktury, wzorce i zależności w danych bez dostarczonych docelowych wyjść. Celem jest zrozumienie wewnętrznej struktury danych, co może prowadzić do nowych odkryć i wglądów (Murphy, 2012, s.9-14).

Proces uczenia nienadzorowanego obejmuje kilka etapów. Pierwszym z nich jest przygotowanie danych, które polega na zgromadzeniu i wstępnym przetworzeniu danych wejściowych bez etykiet. Może to obejmować normalizację, usuwanie brakujących wartości czy redukcję szumów. Następnie następuje wybór algorytmu, który najlepiej pasuje do charakterystyki danych i celu analizy. Kolejnym etapem jest trenowanie modelu poprzez zastosowanie wybranego algorytmu do danych w celu odkrycia ukrytych wzorców. Ostatnim krokiem jest analiza wyników, czyli interpretacja i ewaluacja uzyskanych rezultatów, często z wykorzystaniem miar jakości klasteryzacji czy rekonstrukcji danych.

Uczenie nienadzorowane skupia się głównie na następujących typach problemów:

**Klasteryzacja:** Polega na grupowaniu podobnych danych w klastrach, tak aby elementy w tym samym klastrze były do siebie bardziej podobne niż do elementów w innych klastrach (Jain, Murty & Flynn, 1999).

**Redukcja wymiarowości:** Zmniejsza liczbę zmiennych opisujących dane przy zachowaniu jak największej ilości istotnych informacji. Pomaga to w wizualizacji danych i zwiększa efektywność algorytmów (Jolliffe & Cadima, 2016).

**Wykrywanie anomalii:** Identyfikuje nietypowe lub odstające obserwacje w danych, które mogą wskazywać na błędy, oszustwa lub nowe zjawiska (Chandola, Banerjee & Kumar, 2009).

Uczenie nienadzorowane znajduje szerokie zastosowanie w różnych dziedzinach. W segmentacji rynku służy do grupowania klientów według podobieństw w zachowaniach zakupowych lub preferencjach, co umożliwia bardziej efektywne strategie marketingowe (Tsiptsis & Chorianopoulos, 2009, s.39-46). W analizie genetycznej pomaga odkrywać wzorce ekspresji genów i klasyfikować sekwencje DNA w bioinformatyce (Eisen, 1998).



W wykrywaniu oszustw identyfikuje nietypowe transakcje finansowe lub działania sieciowe wskazujące na potencjalne nadużycia (Bolton & Hand, 2002). Rekomendacje produktów w systemach e-commerce korzystają z klasteryzacji do grupowania produktów lub użytkowników na podstawie podobieństw w preferencjach (Linden, Smith & York, 2003). W przetwarzaniu obrazów techniki uczenia nienadzorowanego są wykorzystywane do segmentacji obrazów w celu identyfikacji i klasyfikacji obiektów (Comaniciu & Meer, 2002).

Zaletami uczenia nienadzorowanego są przede wszystkim elastyczność, czyli możliwość zastosowania do różnych typów danych bez potrzeby etykietowania, oraz odkrywanie nowych wzorców, co daje potencjał do ujawnienia nieoczekiwanych struktur i relacji w danych. Jednak metoda ta ma również swoje ograniczenia. Brak weryfikacji utrudnia ocenę jakości wyników bez etykiet referencyjnych. Interpretacja wyników może być trudna i wymaga eksperckiej wiedzy domenowej. Ponadto algorytmy mogą być wrażliwe na parametry, co wpływa na stabilność wyników i wymaga starannego doboru ustawień.

Przykładem zastosowania uczenia nienadzorowanego jest firma streamingowa Netflix lub Amazon Prime chcące polepszyć rekomendacje filmów dla swoich użytkowników. Zamiast pytać użytkowników o ich preferencje (co wymagałoby etykietowania), platforma może zastosować klasteryzację na podstawie historii oglądania. Algorytm grupuje użytkowników o podobnych wzorcach, co pozwala na rekomendowanie filmów popularnych w danym klastrze innym użytkownikom z tej samej grupy. W podobny sposób działa algorytm firmy Target, który po klasteryzacji podpowiadał kobiecie zakupy dla ciężarnych, mimo, że nie wiedziała jeszcze, że jest w ciąży (Winston, 2020, s.219-224).

Aktualne trendy w uczeniu nienadzorowanym obejmują głębokie uczenie nienadzorowane, wykorzystujące głębokie sieci neuronowe do automatycznego odkrywania reprezentacji danych na różnych poziomach abstrakcji (LeCun, Bengio & Hinton, 2015). Modele generatywne, takie jak Generatywne Sieci Adwersyjne (GAN) i Wariacyjne Autoenkodery (VAE), umożliwiają generowanie nowych danych o podobnych właściwościach do danych treningowych (Goodfellow, 2014; Kingma & Welling, 2022). Ponadto uczenie z wzmocnieniem bez nadzoru integruje uczenie nienadzorowane z uczeniem ze wzmocnieniem w celu efektywniejszego eksplorowania przestrzeni stanów (Laskin, Srinivas & Abbeel, 2020).

Podsumowując, uczenie nienadzorowane jest niezastąpione w eksploracji danych i odkrywaniu ukrytych wzorców bez konieczności posiadania etykietowanych zbiorów danych.



Pomimo wyzwań związanych z interpretacją i oceną wyników, pozostaje niezbędnym narzędziem w dziedzinie sztucznej inteligencji, zwłaszcza w warunkach dużych i złożonych zbiorów danych.

## Uczenie półnadzorowane

Uczenie półnadzorowane (ang. semisupervised learning) jest podejściem w uczeniu maszynowym, które łączy elementy uczenia nadzorowanego i nienadzorowanego. Wykorzystuje zarówno dane oznaczone (z etykietami), jak i nieoznaczone (bez etykiet) do trenowania modeli, co pozwala na efektywne wykorzystanie dużych zbiorów danych, w których tylko niewielka część jest oznaczona (Chapelle, Schölkopf & Zien, 2006). W wielu rzeczywistych sytuacjach pozyskiwanie oznaczonych danych jest kosztowne lub czasochłonne, podczas gdy nieoznaczone dane są dostępne w obfitości. Uczenie półnadzorowane wykorzystuje tę dysproporcję, ucząc się struktury danych z nieoznaczonych przykładów i jednocześnie dopasowując się do informacji zawartych w oznaczonych danych (Zhu & Goldberg, 2009).

Proces uczenia półnadzorowanego obejmuje kilka etapów. Pierwszym krokiem jest inicjalizacja modelu, który jest wstępnie trenowany na dostępnych danych oznaczonych. Następnie wykorzystuje dane nieoznaczone, gdzie model odkrywa ukryte struktury i wzorce, co pomaga w poprawie jego zdolności generalizacji. Często stosuje się iteracyjne poprawianie, w którym model jest kolejno aktualizowany na podstawie przewidywań dla nieoznaczonych danych. Ostatecznie przeprowadza się walidację, aby upewnić się, że model nie przeucza się na nieoznaczonych danych i zachowuje dobrą wydajność na zestawie walidacyjnym. Uczenie półnadzorowane znajduje zastosowanie w wielu dziedzinach. W przetwarzaniu języka naturalnego jest wykorzystywane do analizy sentymentu czy klasyfikacji dokumentów, gdzie oznaczanie dużych korpusów tekstu jest kosztowne i czasochłonne (Nigam i in., 2000). W rozpoznawaniu obrazów pomaga w klasyfikacji obrazów medycznych, gdzie etykietowanie wymaga specjalistycznej wiedzy ekspertów. W bioinformatyce służy do analizy danych genetycznych, w których tylko część sekwencji jest funkcjonalnie oznaczona, umożliwiając odkrywanie nowych genów i funkcji. W rozpoznawaniu mowy wspiera transkrypcję dużych zbiorów danych audio, gdzie ręczne oznaczanie jest wyjątkowo pracochłonne (Cheplygina, de Bruijne & Pluim, 2019).

Zaletami uczenia półnadzorowanego są przede wszystkim efektywność danych oraz lepsza generalizacja. Pozwala ono na wykorzystanie dużych zbiorów nieoznaczonych danych, co jest



szczególnie korzystne, gdy oznaczanie jest drogie lub trudne do zrealizowania. Wykorzystanie nieoznaczonych danych może prowadzić do lepszej generalizacji i wyższej dokładności modelu, gdyż model uczy się pełniejszej reprezentacji danych. Jednak metoda ta ma również ograniczenia. Założenia o danych, takie jak zgodność klastrowa czy gładkość funkcji, na których opierają się metody półnadzorowane, nie zawsze są spełnione w praktyce, co może wpływać na skuteczność modelu. Ponadto istnieje ryzyko wprowadzenia błędów; niewłaściwe wykorzystanie nieoznaczonych danych może prowadzić do propagacji błędów i pogorszenia wydajności modelu (Chapelle & in., 2006, s. 57-71).

Aktualne trendy w uczeniu półnadzorowanym obejmują uczenie głębokie półnadzorowane, czyli integrację metod półnadzorowanych z głębokimi sieciami neuronowymi, co pozwala na skalowanie do dużych i złożonych zbiorów danych (Kingma & in., 2014). Uczenie półnadzorowane oparte na konsystencji wykorzystuje perturbacje danych wejściowych i oczekuje spójnych wyników modelu, co poprawia jego stabilność i odporność na zakłócenia (Sajjadi, Javanmardi & Tasdizen, 2016). Metody adversarialne polegają na wykorzystaniu sieci generatywnych do tworzenia sztucznych przykładów, zwiększając różnorodność danych treningowych i poprawiając zdolność modelu do generalizacji (Miyato & in., 2018). Uczenie zgłębiane (deep semi-supervised learning) to rozwój architektur i algorytmów umożliwiających efektywne uczenie się z minimalną ilością oznaczonych danych, co jest szczególnie ważne w obszarach z ograniczonym dostępem do etykietowanych danych (Laine & Aila, 2017).

Podsumowując, uczenie półnadzorowane jest potężnym narzędziem w sytuacjach, gdy dostęp do oznaczonych danych jest ograniczony. Łącząc zalety uczenia nadzorowanego i nienadzorowanego, umożliwia tworzenie modeli o lepszej wydajności i zdolności generalizacji. Pomimo wyzwań związanych z założeniami dotyczącymi danych i potencjalnym ryzykiem błędów, rozwój metod półnadzorowanych jest aktywnym obszarem badań i znajduje coraz szersze zastosowanie w praktyce.

### **Uczenie przez Wzmacnianie**

Uczenie przez wzmacnianie (ang. Reinforcement Learning, RL) jest głównym paradygmatem uczenia maszynowego, obok uczenia nadzorowanego i nienadzorowanego. W tym podejściu agent uczy się optymalnych działań poprzez interakcje ze środowiskiem oraz otrzymywanie nagród lub kar za podjęte decyzje. Celem agenta jest opracowanie polityki działania, która maksymalizuje skumulowaną nagrodę w długim okresie.



Proces uczenia przez wzmacnianie opiera się na pętli interakcji między agentem a środowiskiem. Agent to podmiot podejmujący decyzje, który uczy się poprzez doświadczenie. Środowisko stanowi otoczenie, z którym agent się komunikuje i które reaguje na jego działania. Stan (state) reprezentuje aktualną sytuację agenta w środowisku, a akcja (action) to działanie podjęte przez agenta w danym stanie. Po podjęciu akcji agent otrzymuje nagrodę (reward), która jest wartością zwrotną informującą o jakości podjętego działania. Polityka (policy) to strategia określająca, jakie akcje agent powinien podjąć w określonych stanach, natomiast funkcja wartości (value function) ocenia, jak dobra jest dana sytuacja dla agenta pod kątem przyszłych nagród. Agent obserwuje stan środowiska, podejmuje akcję zgodnie z aktualną polityką, otrzymuje nagrodę i przechodzi do nowego stanu. Na podstawie tej informacji aktualizuje swoją politykę, aby w przyszłości podejmować lepsze decyzje (Sutton & Barto, 2018, s. 475-480).

Istnieje wiele algorytmów uczenia przez wzmacnianie. Q-learning to bezmodelowy algorytm uczący się wartości funkcji Q, która ocenia, jak korzystne jest podjęcie danej akcji w określonym stanie. SARSA jest algorytmem podobnym do Q-learningu, ale aktualizuje wartości Q na podstawie rzeczywiście podjętych akcji, co prowadzi do polityki zachłannej. Metody gradientu polityki optymalizują bezpośrednio politykę agenta poprzez maksymalizację oczekiwanej skumulowanej nagrody. Algorytm aktor-krytyk (actor-critic) łączy metody wartości i polityki, gdzie "aktor" aktualizuje politykę, a "krytyk" ocenia działania poprzez funkcję wartości. Głębokie uczenie przez wzmacnianie wykorzystuje głębokie sieci neuronowe do aproksymacji funkcji wartości lub polityki w środowiskach o wysokiej złożoności (Mnih et al., 2016).

Uczenie przez wzmacnianie znajduje zastosowanie w wielu dziedzinach. W grach komputerowych RL zostało zastosowane do osiągnięcia ponadludzkiego poziomu w grach takich jak Go, szachy czy gry Atari (Silver et al., 2016; Mnih et al., 2016). W robotyce służy do uczenia robotów złożonych zadań, takich jak nawigacja czy manipulacja obiektami, poprzez interakcje z fizycznym środowiskiem (Kober, Bagnell & Peters, 2013). W systemach rekomendacyjnych RL umożliwia personalizację treści i rekomendacje produktów poprzez optymalizację długoterminowego zaangażowania użytkowników (Zhao et al., 2017). W optymalizacji sieci jest wykorzystywane do zarządzania ruchem w sieciach telekomunikacyjnych i energetycznych w celu zwiększenia efektywności (Mao et al., 2016).



W handlu algorytmicznym służy do automatyzacji strategii inwestycyjnych w celu maksymalizacji zysków i minimalizacji ryzyka (Deng et al., 2016).

Zaletami uczenia przez wzmacnianie są adaptacyjność, ponieważ agent uczy się i dostosowuje do zmieniającego się środowiska, oraz autonomiczność, gdyż nie wymaga etykietowanych danych i uczy się poprzez własne doświadczenie. Ponadto RL pozwala na optymalizację długoterminową, skupiając się na maksymalizacji skumulowanej nagrody, a nie tylko na krótkoterminowych korzyściach.

Jednak metoda ta ma również ograniczenia. Wysoka złożoność obliczeniowa sprawia, że proces uczenia może być czasochłonny i wymagać dużych zasobów obliczeniowych. Istnieje też problem eksploracji i eksploatacji, czyli trudność w balansowaniu między odkrywaniem nowych strategii a wykorzystywaniem już znanych. Ponadto brak gwarancji konwergencji oznacza, że w skomplikowanych środowiskach agent może nie osiągnąć optymalnej polityki.

Przykładem zastosowania RL jest autonomiczny samochód (autonomous vehicle - AV) uczący się jazdy w ruchu miejskim. Samochód (agent) podejmuje decyzje, takie jak przyspieszanie, hamowanie czy skręcanie, na podstawie aktualnej sytuacji (stan). Za każdą akcję otrzymuje nagrodę lub karę, np. pozytywną nagrodę za płynne przemieszczanie się zgodnie z przepisami i karę za naruszenia lub kolizje. Poprzez interakcje z środowiskiem agent uczy się polityki jazdy, która maksymalizuje bezpieczeństwo i efektywność przemieszczania się.

Aktualne trendy w uczeniu przez wzmacnianie obejmują głębokie uczenie przez wzmacnianie, czyli integrację głębokich sieci neuronowych z RL, co pozwala na radzenie sobie z dużymi przestrzeniami stanów i akcji. Meta-uczenie polega na uczeniu agentów szybszego uczenia się nowych zadań poprzez wcześniejsze doświadczenia (Finn, Abbeel & Levine, 2017). Uczenie przez wzmacnianie wieloagentowe bada interakcje i kooperację między wieloma agentami uczącymi się jednocześnie (Hernandez-Leal, Kartal & Taylor, 2019). Bezpieczne i etyczne RL skupia się na zapewnieniu, że działania agenta są zgodne z normami bezpieczeństwa i etyki (Garcia & Fernández, 2015). Uczenie hierarchiczne polega na strukturyzacji polityk na różnych poziomach abstrakcji w celu radzenia sobie ze złożonością zadań (Kulkarni et al., 2016).

Podsumowując, uczenie przez wzmacnianie jest potężnym podejściem umożliwiającym agentom autonomiczne uczenie się poprzez doświadczenie. Dzięki zdolności do optymalizacji długoterminowych celów i adaptacji do dynamicznych środowisk, RL znajduje szerokie zastosowanie w różnych dziedzinach, takich jak robotyka, gry czy systemy rekomendacyjne.



Wyzwania związane z efektywnością obliczeniową i stabilnością procesu uczenia nadal są przedmiotem intensywnych badań.

### **Uczenie na Podstawie Transferu (Transfer Learning)**

Uczenie na podstawie transferu, znane również jako transfer learning, jest podejściem w uczeniu maszynowym polegającym na wykorzystaniu wiedzy zdobytej podczas rozwiązywania jednego problemu (zadania źródłowego) do poprawy wydajności uczenia się w innym, pokrewnym problemie (zadaniu docelowym). Jest to szczególnie użyteczne w sytuacjach, gdy dostęp do danych oznaczonych dla zadania docelowego jest ograniczony lub gdy trening modelu od podstaw jest kosztowny pod względem obliczeniowym (Pan & Yang, 2010).

W tradycyjnym uczeniu maszynowym modele są trenowane od zera dla każdego nowego zadania, co wymaga dużej ilości danych i zasobów obliczeniowych. Uczenie na podstawie transferu przeciwdziała temu poprzez wytrenowanie modelu bazowego na dużym zbiorze danych związanym z zadaniem źródłowym, takim jak np. ImageNet w przypadku sieci neuronowych stosowanych w wizji komputerowej. Następnie wiedza zdobyta przez model bazowy jest przenoszona do zadania docelowego poprzez transfer wag sieci neuronowej lub wykorzystanie wyuczonych reprezentacji cech. Model jest dostrajany (fine-tuning) na danych z zadania docelowego, co pozwala mu na adaptację do specyfiki nowego problemu przy użyciu znacznie mniejszej ilości danych (Yosinski & in., 2014).

Istnieją różne metody transferu wiedzy. Jedną z nich jest ekstrakcja cech, polegająca na wykorzystaniu wyuczonych przez model bazowy cech jako wejścia do prostszego modelu trenowanego na zadaniu docelowym. Inną metodą jest dostrajanie, czyli dalsze trenowanie całego modelu lub jego części na danych z zadania docelowego, często z mniejszą stopą uczenia, aby nie zakłócić wcześniej wyuczonych reprezentacji (). Możliwe jest również uczenie warstwowe, polegające na zamrażaniu początkowych warstw modelu bazowego i trenowaniu tylko ostatnich warstw na zadaniu docelowym, co pozwala na zachowanie ogólnych cech i dostosowanie się do specyfiki nowego zadania (Howard & Ruder, 2018; Long & in., 2015; Donahue & in., 2014).

Zaletami uczenia na podstawie transferu są efektywność danych, ponieważ pozwala na trenowanie modeli z mniejszą ilością oznaczonych danych, oraz oszczędność czasu i zasobów poprzez redukcję czasu treningu i wymagań obliczeniowych. Modele często osiągają



wyższą dokładność dzięki wykorzystaniu wcześniej wyuczonych reprezentacji. Jednak skuteczność transferu zależy od podobieństwa między zadaniem źródłowym a docelowym. Istnieje też ryzyko katastroficznego zapominania, gdy model traci wiedzę z zadania źródłowego podczas dostrajania do zadania docelowego. Dodatkowo, wykorzystanie pretrenowanych modeli może być ograniczone przez ich licencje i prawa autorskie (Torrey & Shavlik, 2010).

Przykładem zastosowania transfer learning jest zadanie klasyfikacji obrazów rentgenowskich w celu wykrycia zapalenia płuc. Z uwagi na ograniczoną dostępność oznaczonych danych, zamiast trenować model od podstaw, można wykorzystać sieć konwolucyjną pretrenowaną na ImageNet. Następnie model jest dostrajany na małym zbiorze danych medycznych, co pozwala na osiągnięcie wysokiej dokładności klasyfikacji (Viana, 2018).

Aktualne trendy w tej dziedzinie obejmują uczenie meta, gdzie modele uczą się, jak szybciej uczyć się nowych zadań, co zwiększa efektywność transferu wiedzy. Duże modele językowe, takie jak GPT-3, są wykorzystywane do różnych zadań z minimalnym dostrajaniem. Pretrenowanie modeli na nieoznaczonych danych w uczeniu bez nadzoru zwiększa ich zdolność do generalizacji i transferu. Ponadto, transfer learning w edge computing polega na adaptacji modeli do urządzeń o ograniczonej mocy obliczeniowej, takich jak smartfony czy IoT (Internet of Things) (Wang & in., 2019).

Podsumowując, uczenie na podstawie transferu jest potężnym narzędziem w uczeniu maszynowym, umożliwiającym efektywne wykorzystanie istniejącej wiedzy do rozwiązywania nowych problemów. Dzięki temu podejściu możliwe jest tworzenie modeli o wysokiej wydajności przy mniejszej ilości danych i zasobów. Pomimo pewnych ograniczeń, transfer learning pozostaje aktywnym obszarem badań i znajduje szerokie zastosowanie w praktyce.

### 1.2.3 Sieci Neuronowe i Głębokie Uczenie

Sieci neuronowe są inspirowane biologicznymi sieciami neuronowymi i stanowią podstawę głębokiego uczenia, które wykorzystuje wielowarstwowe sieci do modelowania złożonych zależności. Konwolucyjne Sieci Neuronowe lub inaczej zwane splotowe sieci neuronowe (CNN, ang. Convolutional Neural Network) to specjalny rodzaj sieci neuronowych zaprojektowanych z myślą o przetwarzaniu danych o strukturze siatki, takich jak obrazy. Dzięki przełomowym osiągnięciom w dziedzinie widzenia komputerowego, CNN stały się podstawowym narzędziem w takich zadaniach jak klasyfikacja obrazów, detekcja obiektów i segmentacja semantyczna. Ich zastosowanie w przetwarzaniu danych wizualnych,



dźwiękowych czy sekwencyjnych uczyniło je ważnym elementem współczesnej sztucznej inteligencji (LeCun, Bengio & Hinton, 2015).

CNN różnią się od tradycyjnych, w pełni połączonych sieci neuronowych dzięki zastosowaniu warstw konwolucyjnych i podpróbkowania. Warstwy konwolucyjne wykorzystują operację konwolucji do ekstrakcji lokalnych cech z danych wejściowych, takich jak krawędzie czy tekstury, używając filtrów przesuwających się po danych. Warstwy podpróbkowania, np. maksymalne podpróbkowanie (Max Pooling), zmniejszają wymiarowość danych, redukując liczbę parametrów i pomagając kontrolować przeuczenie. W końcowych etapach sieci znajdują się warstwy w pełni połączone, które integrują wyekstrahowane cechy i dokonują klasyfikacji lub regresji. Kluczowymi cechami CNN są sparowana łączność oraz dzielenie parametrów. Dzięki sparowanej łączności każdy neuron w warstwie konwolucyjnej jest połączony jedynie z niewielkim obszarem poprzedniej warstwy, co znacznie zmniejsza liczbę parametrów. Dzielenie parametrów pozwala na stosowanie tych samych filtrów w całym obrazie, umożliwiając wykrywanie tych samych cech w różnych jego częściach, co dodatkowo redukuje liczbę wymaganych parametrów (Goodfellow, Bengio & Courville, 2018, s.330-372).

CNN znalazły zastosowanie w szerokim zakresie dziedzin. W klasyfikacji obrazów umożliwiają identyfikację obiektów na zdjęciach (Krizhevsky, Sutskever i Hinton, 2012). W detekcji obiektów lokalizują i identyfikują obiekty w obrazach, korzystając z zaawansowanych algorytmów takich jak Faster R-CNN (Ren & in., 2015). Segmentacja obrazów, przypisująca etykiety do każdego piksela w obrazie, jest wykorzystywana w analizie medycznej czy autonomicznych pojazdach (Long, Shelhamer & Darrell, 2015). Ponadto CNN stosuje się w przetwarzaniu sygnałów, takich jak analiza dźwięków czy fal EEG (Bashivan, Rish, Yeasin & Codella, 2016).

Zaletami CNN są efektywność przetwarzania oraz możliwość automatycznej ekstrakcji cech. Dzięki sparowanej łączności i dzieleniu parametrów CNN są bardziej wydajne obliczeniowo niż tradycyjne sieci neuronowe. Automatyczna ekstrakcja cech eliminuje konieczność ręcznego definiowania atrybutów, co upraszcza proces uczenia modelu. Jednakże CNN mają również swoje ograniczenia. Do skutecznego treningu wymagają dużych zbiorów danych, co może stanowić wyzwanie w niektórych dziedzinach. Trudności interpretacyjne utrudniają zrozumienie, jakie cechy są wykorzystywane przez sieć do podejmowania decyzji. Ponadto sieci te są wrażliwe na zakłócenia w danych wejściowych, co czyni je podatnymi na ataki typu adversarial (Szegedy & in., 2014).



Przełomem w zastosowaniu CNN było opracowanie sieci AlexNet, która wygrała konkurs ImageNet Large Scale Visual Recognition Challenge (ILSVRC) w 2012 roku. AlexNet składała się z ośmiu warstw i zrewolucjonizowała klasyfikację obrazów, osiągając znacznie lepsze wyniki niż wcześniejsze metody (Krizhevsky, Sutskever & Hinton, 2012).

Obecnie rozwój CNN koncentruje się na głębokich architekturach, takich jak ResNet, które dzięki setkom warstw i mechanizmom skip connections pozwalają na skuteczny trening nawet bardzo złożonych sieci. CNN znajdują również zastosowanie w przetwarzaniu języka naturalnego, analizując sekwencje tekstowe w zadaniach takich jak klasyfikacja sentymentu. Dodatkowo, badania nad efektywnością obliczeniową prowadzą do opracowywania modeli lekkich, które mogą działać na urządzeniach mobilnych. W uwarunkowaniach uczenia transferowego pretrenowane modele CNN są dostosowywane do specyficznych zadań z mniejszymi zbiorami danych, co czyni je bardziej uniwersalnymi (Goodfellow, Bengio & Courville, 2018).

Podsumowując, Splotowe Sieci Neuronowe zrewolucjonizowały dziedzinę widzenia komputerowego, umożliwiając automatyczną ekstrakcję złożonych cech z danych wizualnych. Dzięki swojej efektywności i skuteczności CNN stały się standardowym narzędziem w wielu aplikacjach przemysłowych i badawczych. Pomimo pewnych ograniczeń, ciągły rozwój i innowacje w architekturach CNN nadal poszerzają ich możliwości i zastosowania.

Następnym modelem są Rekurencyjne Sieci Neuronowe (RNN, ang. Recurrent Neural Networks) są specjalną klasą sieci neuronowych zaprojektowaną do przetwarzania danych sekwencyjnych, takich jak tekst, mowa, sygnały czasowe czy serie czasowe finansowe. Ich kluczową cechą jest zdolność do modelowania zależności czasowych i sekwencyjnych dzięki wbudowanej pamięci wewnętrznej, która umożliwia uwzględnianie kontekstu historycznego podczas przetwarzania danych.

Podstawowa idea działania RNN opiera się na pętli w ich strukturze, która pozwala na przekazywanie informacji z jednego kroku czasowego do kolejnego. Oznacza to, że sieć przetwarza dane sekwencyjnie, aktualizując swój stan wewnętrzny przy każdym kroku. Matematycznie, aktualizacja stanu ukrytego odbywa się poprzez połączenie informacji z bieżącego wejścia z poprzednim stanem ukrytym, przy użyciu odpowiednich wag i funkcji aktywacji (Goodfellow, Bengio & Courville, 2018). Dzięki temu RNN mogą zapamiętywać i wykorzystywać informacje z wcześniejszych kroków w sekwencji.

Jedną z cech RNN jest dzielenie wag, co oznacza, że te same parametry są stosowane na każdym kroku czasowym. Redukuje to liczbę parametrów, pozwalając sieci generalizować działanie na sekwencjach o różnej długości. Jednakże standardowe RNN mają ograniczenia w modelowaniu długoterminowych zależności z powodu problemów z zanikiem lub eksplozją gradientów podczas treningu, co znacząco utrudnia efektywne uczenie (Bengio, Simard & Frasconi, 1994).

Aby przezwyciężyć te problemy, wprowadzono ulepszone architektury RNN, takie jak LSTM (Long Short-Term Memory) i GRU (Gated Recurrent Unit). LSTM, zaproponowane przez Hochreitera i Schmidhubera (1997), zawierają jednostki pamięci oraz mechanizmy bramek (wejścia, wyjścia i zapominania), które pozwalają na kontrolowanie przepływu informacji i przechowywanie długoterminowych zależności. GRU, będące uproszczoną wersją LSTM, osiągają podobną funkcjonalność przy mniejszej liczbie parametrów.

RNN znajdują szerokie zastosowanie w różnych dziedzinach. W przetwarzaniu języka naturalnego (PJN) są wykorzystywane w modelach językowych, tłumaczeniu maszynowym, analizie sentymentu czy generowaniu tekstu (Mikolov & in., 2010). W rozpoznawaniu mowy umożliwiają przetwarzanie sekwencji dźwiękowych i konwersję mowy na tekst (Graves, Mohamed & Hinton, 2013). W prognozowaniu szeregów czasowych wspomagają analizę danych finansowych, meteorologicznych czy sensorowych, umożliwiając przewidywanie przyszłych wartości (Connor, Martin & Atlas, 1994). RNN są również wykorzystywane w generowaniu muzyki i sztuki, gdzie potrafią tworzyć nowe kompozycje na podstawie wcześniej poznanych wzorców sekwencyjnych (Briot, Hadjeres & Pachet, 2017).

RNN mają wiele zalet, w tym naturalną zdolność do modelowania zależności sekwencyjnych oraz elastyczność w przetwarzaniu sekwencji o zmiennej długości. Jednakże ich ograniczenia, takie jak problemy z treningiem wynikające z zanikania gradientów oraz większe wymagania obliczeniowe, sprawiają, że nie zawsze są idealnym rozwiązaniem. W odpowiedzi na te wyzwania rozwijane są alternatywne podejścia, takie jak sieci dwukierunkowe (Bidirectional RNN), które przetwarzają dane w obu kierunkach, wykorzystując informacje zarówno z przeszłości, jak i przyszłości (Schuster, Paliwal, 1997). Mechanizmy uwagi (attention mechanisms), zaproponowane przez Bahdanau, Cho i Bengio (2015), poprawiają zdolność modeli do skupiania się na elementach sekwencji, zwiększając ich skuteczność w złożonych zadaniach.



W ostatnich latach pojawiły się też transformery, które zastąpiły RNN w wielu zastosowaniach dzięki efektywnemu modelowaniu zależności sekwencyjnych bez użycia rekurencji. Pomimo tego, RNN oraz ich ulepszone wersje, takie jak LSTM i GRU, pozostają istotnymi narzędziami w dziedzinach wymagających przetwarzania danych sekwencyjnych (Vaswani & in., 2017).

Przykładem praktycznego zastosowania RNN jest tłumaczenie maszynowe w architekturze kodera-dekoder (encoder-decoder). Koder przetwarza sekwencję wejściową, kodując ją w stanie ukrytym, a dekodery generuje sekwencję wyjściową na podstawie tego stanu (Sutskever, Vinyals & Le, 2014). Dzięki takim zastosowaniom RNN odegrały kluczową rolę w rozwoju nowoczesnych metod przetwarzania danych sekwencyjnych, choć ich miejsce coraz częściej zajmują nowocześniejsze architektury.

Z kolei Sieci Transformatorowe (ang. Transformer Networks) to nowoczesna architektura sieci neuronowych zaproponowana przez Vaswaniego i współpracowników w 2017 roku, która zrewolucjonizowała przetwarzanie języka naturalnego (PJN) oraz inne dziedziny związane z danymi sekwencyjnymi. W odróżnieniu od tradycyjnych rekurencyjnych sieci neuronowych (RNN), transformatory umożliwiają równoległe przetwarzanie danych sekwencyjnych, co znacząco zwiększa efektywność obliczeniową i pozwala na trenowanie większych modeli na znacznie większych zbiorach danych.

Kluczowym elementem architektury transformatora jest mechanizm uwagi (ang. attention mechanism), który pozwala modelowi skupić się na najbardziej istotnych częściach sekwencji wejściowej podczas generowania wyjścia. Mechanizm ten działa na zasadzie oceniania ważności każdego elementu w położeniu pozostałych elementów sekwencji. Self-attention, czyli mechanizm samouwagi, umożliwia modelowi analizowanie powiązań między słowami w tej samej sekwencji, natomiast multi-head attention pozwala na równoczesne uwzględnienie różnych danych, co zwiększa zdolność modelu do uchwycenia bardziej złożonych relacji.

Transformatory eliminują rekurencję, charakterystyczną dla RNN, co umożliwia równoległe przetwarzanie wszystkich elementów sekwencji jednocześnie. Dzięki temu znacząco przyspieszają trening i inferencję, a także efektywniej wykorzystują możliwości współczesnych procesorów graficznych (GPU). Ponieważ jednak transformatory nie mają wbudowanego pojęcia kolejności elementów, wprowadzane są kody pozycyjne (ang. positional encoding), które dostarczają informacji o kolejności danych w sekwencji, umożliwiając modelowi rozumienie struktury sekwencji.



Zastosowania sieci transformatorowych obejmują różnorodne zadania. W przetwarzaniu języka naturalnego są wykorzystywane w tłumaczeniu maszynowym, odpowiadaniu na pytania, analizie sentymentu czy streszczaniu tekstów. Modele takie jak BERT (Devlin & in., 2019) czy GPT (Radford & in., 2019) bazują na architekturze transformatorowej i są pretrenowane na ogromnych zbiorach tekstowych, co pozwala na ich późniejsze dostosowanie do specyficznych zadań. Poza PJN transformatory znajdują zastosowanie w widzeniu komputerowym, gdzie modele takie jak Vision Transformer (ViT) adaptują tę architekturę do zadań związanych z przetwarzaniem obrazów (Dosovitskiy & in., 2021). Dodatkowo, systemy multimodalne łączące tekst, obrazy i dźwięki również korzystają z transformatorów do integracji informacji z różnych źródeł (Lu & in., 2019).

Sieci transformatorowe mają wiele zalet, które sprawiają, że stały się przełomowym rozwiązaniem w sztucznej inteligencji. Dzięki równoległemu przetwarzaniu danych transformatory są skalowalne i mogą obsługiwać bardzo duże modele oraz ogromne zbiory danych. Mechanizm uwagi umożliwia im uchwycenie długodystansowych zależności w danych sekwencyjnych, co pozwala na bardziej precyzyjne modelowanie skomplikowanych struktur językowych i innych danych. Niemniej jednak architektura ta ma również swoje ograniczenia. Mechanizm uwagi charakteryzuje się kwadratową złożonością względem długości sekwencji, co utrudnia przetwarzanie bardzo długich sekwencji. Ponadto transformatory wymagają dużych zasobów obliczeniowych i pamięciowych, co może stanowić barierę w ich zastosowaniu w mniej zasobnych środowiskach. Dość istotnym ograniczeniem jest brak wbudowanej hierarchii, co może utrudniać modelowanie złożonych struktur danych, takich jak składnia języka naturalnego.

Przykładem sukcesu transformatorów jest model BERT (Bidirectional Encoder Representations from Transformers), który wykorzystuje dwukierunkową analizę kontekstową w celu pretrenowania reprezentacji językowych. Model ten osiągnął znakomite wyniki w wielu zadaniach PJN, takich jak odpowiadanie na pytania czy analiza sentymentu (Devlin & in., 2019). Innym przykładem jest Vision Transformer (ViT), który zaadaptował architekturę transformatorów do widzenia komputerowego, osiągając konkurencyjne wyniki w klasyfikacji obrazów (Dosovitskiy i in., 2021).

Obecne trendy w badaniach nad transformatorami obejmują optymalizację mechanizmu uwagi, w tym badania nad jego liniową złożonością, co mogłoby umożliwić przetwarzanie bardzo długich sekwencji (Katharopoulos & in., 2020). W dziedzinie widzenia komputerowego trwają



prace nad dalszą adaptacją transformatorów, czego efektem są modele takie jak ViT. W systemach multimodalnych badania koncentrują się na integracji informacji z różnych źródeł w jednolitych modelach (Lu & in., 2019). Ponadto rośnie zainteresowanie efektywnością energetyczną transformatorów, co ma na celu zmniejszenie kosztów obliczeniowych i ekologicznych związanych z ich trenowaniem i użytkowaniem.

Podsumowując, sieci transformatorowe wyznaczyły nowy standard w przetwarzaniu danych sekwencyjnych, znacząco przyczyniając się do postępu w dziedzinie sztucznej inteligencji. Ich wszechstronność i zdolność do efektywnego modelowania skomplikowanych relacji w danych czynią je niezastąpionym narzędziem w wielu zastosowaniach, od przetwarzania języka naturalnego, przez widzenie komputerowe, aż po systemy multimodalne. Pomimo wyzwań związanych z ich złożonością obliczeniową, transformatory wciąż pozostają ważnym obszarem badań i innowacji w AI.

#### **1.2.4 Przetwarzanie Języka Naturalnego w Kontekście Sztucznej Inteligencji**

Przetwarzanie Języka Naturalnego (PJNI) to kluczowa dziedzina sztucznej inteligencji, której celem jest umożliwienie maszynom rozumienia, interpretacji i generowania języka ludzkiego w sposób zbliżony do człowieka. Łącząc lingwistykę, informatykę oraz uczenie maszynowe, PJNI rewolucjonizuje sposób, w jaki komunikujemy się z komputerami oraz przetwarzamy informacje tekstowe. Jego znaczenie w sztucznej inteligencji rośnie wraz z postępem technologicznym, umożliwiając bardziej naturalną interakcję człowiek-maszyna i coraz bardziej zaawansowane analizy językowe (Jurafsky & Martin, 2023).

W etiologii sztucznej inteligencji, PJNI odgrywa nieodzowną rolę w interakcji między ludźmi a urządzeniami. Dzięki postępom w uczeniu maszynowym, zwłaszcza w głębokim uczeniu i sieciach neuronowych, modele PJNI osiągnęły imponujące wyniki w rozumieniu i generowaniu języka naturalnego (Young et al., 2018). Architektury takie jak sieci transformatorowe umożliwiły zaawansowane analizy semantyki, kontekstu i emocji w tekście (Vaswani et al., 2017). Technologie te przyczyniają się do coraz lepszego zrozumienia ludzkiego języka przez maszyny i otwierają nowe możliwości zastosowań.

Przetwarzanie Języka Naturalnego znajduje zastosowanie w wielu dziedzinach życia. Asystenci głosowi, tacy jak Siri, Alexa czy Google Assistant, wykorzystują PJNI do interpretacji poleceń i generowania odpowiedzi, umożliwiając naturalną komunikację z urządzeniami (Hoy, 2018). Tłumaczenie maszynowe, wspierane modelami sztucznej inteligencji, takimi jak Neural

Machine Translation, pozwala na automatyczne tłumaczenie tekstów z wysoką dokładnością (Wu et al., 2016). Firmy korzystają z analizy sentymentu, aby badać opinie klientów w mediach społecznościowych, co pomaga w zrozumieniu potrzeb rynku i przewidywaniu zachowań konsumenckich (Medhat, Hassan, & Korashy, 2014). Modele językowe, takie jak GPT-3, zdolne do generowania spójnych tekstów na podstawie dostarczonych danych, znajdują zastosowanie w tworzeniu treści, odpowiadaniu na pytania czy podsumowywaniu tekstów (Brown et al., 2020).

Pomimo znacznych osiągnięć, PJN napotyka także na istotne wyzwania. Maszyny wciąż mają trudności z interpretacją kontekstu i pragmatyki, zwłaszcza w przypadku sarkazmu, ironii czy idiomów, co ogranicza jakość interakcji z użytkownikami (Cambria & White, 2014). Modele językowe często odzwierciedlają uprzedzenia zawarte w danych treningowych, co rodzi problemy etyczne i wymaga opracowania metod eliminacji tych uprzedzeń (Bender et al., 2021). Wielojęzyczność i różnorodność językowa stanowią kolejne wyzwanie – efektywne tworzenie modeli dla mniej popularnych języków wciąż jest trudne (Conneau et al., 2020). Ochrona prywatności danych językowych to kolejny obszar, w którym należy zapewnić bezpieczeństwo i anonimowość przetwarzanych informacji (Hirschberg & Manning, 2015).

Przyszłość PJN w sztucznej inteligencji zapowiada się obiecująco. Integracja PJN z innymi dziedzinami, takimi jak wizja komputerowa czy uczenie przez wzmacnianie, prowadzi do powstania systemów multimodalnych zdolnych do bardziej kompleksowego rozumienia otaczającego świata (Lu et al., 2019). Jednocześnie rozwijane są techniki objaśnialnej sztucznej inteligencji, dążące do tworzenia modeli, które nie tylko są skuteczne, ale także bardziej zrozumiałe dla człowieka (Doshi-Velez & Kim, 2017).

Podsumowując, Przetwarzanie Języka Naturalnego jest integralną częścią sztucznej inteligencji, umożliwiającą maszynom bardziej naturalną i efektywną komunikację z ludźmi. Postępy w tej dziedzinie, łączące zaawansowane techniki lingwistyczne z metodami sztucznej inteligencji, przyczyniają się do rozwoju innowacyjnych systemów, które zmieniają nasze codzienne życie. Kontynuacja badań nad PJN umożliwi jeszcze lepsze zrozumienie języka przez maszyny, rozwiązanie istniejących wyzwań oraz otwarcie nowych możliwości zastosowań w przyszłości.



### 1.2.5 Modele Językowe

Modele językowe odgrywają kluczową rolę w sztucznej inteligencji, szczególnie w dziedzinie przetwarzania języka naturalnego (PJN). Umożliwiają one maszynom zrozumienie, interpretację oraz generowanie języka naturalnego, co prowadzi do powstania zaawansowanych systemów wspierających komunikację człowiek-maszyna. Współczesne modele językowe wykorzystują różne techniki i architektury, aby skutecznie modelować złożoność języka i oferować wszechstronne możliwości.

N-gramowe modele językowe to klasyczne, statystyczne podejście, które przewiduje kolejne słowo w sekwencji na podstawie  $n-1$  poprzednich słów. Stanowią podstawę wielu aplikacji, takich jak autouzupełnianie czy korekta pisowni (Manning & Schütze, 1999). Z kolei Word2Vec, opracowany przez Mikolova i współpracowników, reprezentuje słowa jako wektory w przestrzeni ciągłej, zachowując ich semantyczne relacje, co umożliwia wykonywanie operacji semantycznych, takich jak analogie słowne (Mikolov et al., 2013). Podobnym podejściem jest GloVe (Global Vectors for Word Representation), które łączy zalety modeli globalnych i lokalnych poprzez analizę macierzy współwystępowania słów (Pennington, Socher, & Manning, 2014).

Przełom w PJN nastąpił wraz z wprowadzeniem modeli opartych na architekturze transformatorowej. BERT (Bidirectional Encoder Representations from Transformers) to dwukierunkowy model językowy pretrenowany na dużych korpusach tekstowych, który uwzględnia kontekst z obu stron słowa, oferując znaczną poprawę w zadaniach związanych ze zrozumieniem tekstu (Devlin et al., 2019). Z kolei GPT (Generative Pre-trained Transformer) koncentruje się na generowaniu spójnych tekstów w sposób jednokierunkowy, co czyni go szczególnie skutecznym w tworzeniu treści i odpowiadaniu na pytania (Radford et al., 2018; Brown et al., 2020).

Udoskonaleniem BERT-a jest RoBERTa, które osiąga lepsze wyniki dzięki większej ilości danych i wydłużonemu procesowi pretrenowania. XLNet łączy zalety autoregresji i autoenkodowania, eliminując ograniczenia związane z maskowaniem tokenów w BERT, a ALBERT oferuje lżejszą i bardziej efektywną wersję BERT-a poprzez redukcję liczby parametrów (Liu et al., 2019). Uniwersalnym podejściem jest T5 (Text-to-Text Transfer Transformer), który traktuje wszystkie zadania PJN jako konwersję tekstu na tekst, co upraszcza różnorodne aplikacje, takie jak tłumaczenie czy podsumowywanie. BART łączy



dwukierunkowe kodowanie BERT-a z autoregresyjnym dekodowaniem GPT, oferując zaawansowane możliwości generowania i rekonstrukcji tekstów (Lewis et al., 2020).

Modele takie jak ELECTRA wprowadzają innowacyjne sposoby pretrenowania poprzez wykrywanie zamienionych tokenów, co czyni proces bardziej efektywnym niż tradycyjne maskowanie (Clark et al., 2020). Transformer-XL rozszerza architekturę transformera o mechanizm pamięci rekurencyjnej, co umożliwia modelowanie bardzo długich sekwencji (Dai et al., 2019). Z kolei ERNIE, opracowany przez Baidu, integruje wiedzę o świecie podczas pretrenowania, co prowadzi do lepszego zrozumienia semantyki tekstu (Sun et al., 2019).

Wielojęzyczne modele, takie jak mBERT i XLM-R, umożliwiają obsługę wielu języków jednocześnie, co jest szczególnie istotne w otocze globalnych zastosowań (Conneau et al., 2020). LaMDA (Language Model for Dialogue Applications) od Google koncentruje się na prowadzeniu naturalnych i kontekstowych rozmów, a PaLM (Pathways Language Model) wykorzystuje zaawansowaną architekturę Pathways do skalowania modeli i ich zastosowań w różnych zadaniach (Chowdhery et al., 2022).

Najnowsze modele, takie jak GPT-4, kontynuują rozwój generatywnych technologii, oferując jeszcze lepsze zrozumienie kontekstu i zdolność generowania tekstów (OpenAI, 2023). Megatron-Turing NLG, opracowany przez NVIDIA i Microsoft, jest w czołówce największych modeli językowych, składającym się z 530 miliardów parametrów, co pozwala na efektywne przetwarzanie ogromnych zbiorów danych (Smith et al., 2022). Otwarte modele, takie jak GPT-Neo i GPT-J, zapewniają społeczności badawczej dostęp do zaawansowanych technologii bez ograniczeń komercyjnych (Black et al., 2021). Na pograniczu PJN i wizji komputerowej znajduje się DALL·E, który generuje obrazy na podstawie opisów tekstowych, wykorzystując mechanizmy językowe do tworzenia wielomodalnych treści (Ramesh et al., 2021).

Podsumowując, rozwój modeli językowych znacznie poszerzył możliwości przetwarzania języka naturalnego i innych dziedzin sztucznej inteligencji. Od klasycznych modeli n-gramowych po nowoczesne architektury transformatorowe, modele te są podstawą wielu innowacji, które zmieniają sposób, w jaki maszyny rozumieją i komunikują się za pomocą języka. Ich przyszłość wiąże się z dalszym rozwojem efektywności, skalowalności oraz zastosowań w różnorodnych dziedzinach, w tym multimodalnych systemach łączących tekst, obraz i dźwięk.



## 1.2.6 Wizja Komputerowa

Wizja komputerowa, znana jako Computer Vision, to jedna z dziedzin sztucznej inteligencji, której celem jest umożliwienie maszynom interpretacji i zrozumienia informacji wizualnych z otaczającego świata. Dzięki połączeniu wiedzy z zakresu informatyki, matematyki, fizyki i biologii, wizja komputerowa pozwala na analizę obrazów i wideo w sposób zbliżony do ludzkiego postrzegania, wspierając rozwój technologii w wielu dziedzinach życia (Szeliski, 2010).

Wizja komputerowa obejmuje szeroki zakres zagadnień, w tym rozpoznawanie obiektów, gdzie maszyny identyfikują i klasyfikują elementy na obrazach (Krizhevsky, Sutskever, & Hinton, 2012). Kolejnym obszarem jest detekcja obiektów, czyli lokalizowanie i identyfikowanie obiektów w obrazach, co znajduje zastosowanie w systemach nadzoru czy autonomicznych pojazdach (Ren, 2015). Segmentacja obrazów pozwala na podział obrazu na regiony o podobnych cechach, umożliwiając szczegółową analizę sceny. Z kolei śledzenie obiektów polega na monitorowaniu ruchu elementów w sekwencjach wideo, co jest wykorzystywane w bezpieczeństwie oraz analizie sportowej (Yilmaz, Javed, & Shah, 2006). Wizja komputerowa zajmuje się także rekonstrukcją 3D, czyli odwzorowaniem trójwymiarowej struktury sceny na podstawie obrazów 2D (Hartley & Zisserman, 2003).

Postęp w wizji komputerowej jest ściśle związany z rozwojem uczenia maszynowego i głębokiego uczenia. Istotnym narzędziem są konwolucyjne sieci neuronowe (CNN), które przetwarzają dane wizualne, ucząc się lokalnych cech, takich jak krawędzie czy tekstury (LeCun, Bengio, & Hinton, 2015). Sieci generatywne adversarialne (GAN) umożliwiają generowanie realistycznych obrazów poprzez rywalizację generatora i dyskryminatora (Goodfellow et al., 2014). Wykorzystanie transfer learningu pozwala na stosowanie modeli pretrenowanych na dużych zbiorach danych, co znacznie przyspiesza rozwój aplikacji wizji komputerowej. Dodatkowo, detektory kluczowych punktów, takie jak SIFT czy SURF, umożliwiają analizę charakterystycznych punktów w obrazach, co znajduje zastosowanie w mapowaniu czy analizie obrazów satelitarnych (Lowe, 2004).

Zastosowania wizji komputerowej są niezwykle różnorodne. W autonomicznych pojazdach systemy wizyjne umożliwiają rozpoznawanie znaków drogowych, nawigację oraz wykrywanie przeszkód (Chen et al., 2015). W medycynie analiza obrazów takich jak MRI czy CT wspiera diagnozowanie chorób oraz planowanie leczenia (Litjens et al., 2017). W przemyśle wizja komputerowa znajduje zastosowanie w kontroli jakości produktów i automatyzacji procesów



produkcyjnych. Technologie rozpoznawania twarzy oraz monitorowania zachowań są szeroko wykorzystywane w systemach bezpieczeństwa i nadzoru (Zheng et al., 2016). Ponadto, wizja komputerowa bardzo ważna w rozszerzonej i wirtualnej rzeczywistości, gdzie integracja danych wizualnych z rzeczywistym światem tworzy immersyjne doświadczenia (Azuma, 1997).

Pomimo znaczących postępów, wizja komputerowa napotyka na liczne wyzwania. Złożoność obrazów, wynikająca z różnorodności scen, oświetlenia czy zakłóceń, utrudnia opracowanie uniwersalnych modeli. Skuteczne algorytmy wymagają ogromnych zbiorów oznaczonych danych, których pozyskanie jest kosztowne i czasochłonne. Modele głębokiego uczenia, często traktowane jako "czarne skrzynki", wymagają metod zwiększających ich objaśnialność, co jest szczególnie istotne w krytycznych aplikacjach, takich jak medycyna (Samek et al., 2017). Dodatkowo, modele wizji komputerowej mogą być podatne na ataki typu adversarial, gdzie drobne modyfikacje obrazu prowadzą do błędnych decyzji (Szegedy et al., 2014).

Przyszłość wizji komputerowej wiąże się z dalszym rozwojem algorytmów głębokiego uczenia oraz integracją z innymi modalnościami, takimi jak analiza dźwięku czy tekstu. Nowe obszary zastosowań, takie jak robotyka czy analiza emocji, otwierają możliwości dla bardziej kompleksowego wykorzystania technologii. Jednocześnie badania nad transparentnością i objaśnialnością modeli będą kluczowe dla budowy zaufania i szerokiej akceptacji wizji komputerowej w społeczeństwie.

Wizja komputerowa jest dynamicznie rozwijającą się dziedziną, która zmienia sposób, w jaki maszyny postrzegają i interpretują świat. Dzięki zaawansowanym algorytmom i rosnącym możliwościom obliczeniowym, technologia ta znajduje zastosowanie w różnych sektorach, otwierając nowe możliwości w nauce, przemyśle i codziennym życiu.

### 1.2.7 Robotyka i AI

Integracja robotyki ze sztuczną inteligencją prowadzi do tworzenia autonomicznych systemów zdolnych do wykonywania złożonych zadań w dynamicznych i nieprzewidywalnych środowiskach. Połączenie tych dwóch dziedzin pozwala na wyposażenie robotów w zdolności percepcyjne, decyzyjne i adaptacyjne, znacząco rozszerzając ich zastosowanie w przemyśle, medycynie, eksploracji kosmosu i innych obszarach (Siciliano & Khatib, 2016).

Robotyka koncentruje się na tworzeniu maszyn, które mogą działać autonomicznie lub półautonomicznie. Z kolei AI w robotyce odnosi się do implementacji algorytmów



umożliwiających robotom uczenie się, podejmowanie decyzji i interakcję z otoczeniem w sposób inteligentny. Kluczowe obszary integracji obejmują percepcję, czyli zdolność robotów do odbierania i interpretowania danych sensorycznych; planowanie i podejmowanie decyzji, co pozwala na adaptację do zmieniających się warunków; uczenie maszynowe, które umożliwia robotom naukę z doświadczenia; oraz interakcję człowiek-robot, zapewniającą naturalną komunikację między ludźmi a maszynami (Russell & Norvig, 2022).

Metody i techniki stosowane w robotyce z wykorzystaniem AI obejmują między innymi uczenie przez wzmocnienie, które pozwala robotom na naukę złożonych zadań bez konieczności wyraźnego programowania (Kormushev, Calinon, & Caldwell, 2013). Głębokie uczenie znajduje zastosowanie w percepcji robotycznej, umożliwiając robotom analizę danych wizualnych i rozpoznawanie obiektów. Algorytmy planowania ruchu, takie jak A\* czy RRT, są wykorzystywane do optymalizacji ścieżek, a zaawansowane metody przetwarzania języka naturalnego i rozpoznawania gestów wspierają interakcję między człowiekiem a robotem (LeCun, Bengio, & Hinton, 2015).

Zastosowania robotyki z AI są niezwykle szerokie. W przemyśle roboty zwiększają efektywność procesów produkcyjnych poprzez automatyzację montażu, pakowania i kontroli jakości (Bogue, 2022). W medycynie wspomagają chirurgów, zapewniając precyzję i minimalizując inwazyjność, a także wspierają pacjentów w rehabilitacji (Yang et al., 2017). W eksploracji kosmosu i środowisk niedostępnych roboty autonomiczne są nieocenione w badaniach planet czy głębin oceanicznych (Matthies et al., 2007). W transporcie i logistyce roboty optymalizują zarządzanie magazynami, sortowanie towarów i nawigację autonomicznych pojazdów. W edukacji i rozrywce roboty stają się interaktywnymi narzędziami do nauki i zabawy, angażując użytkowników w innowacyjne sposoby (Mubin et al., 2013).

Pomimo licznych sukcesów, robotyka z AI napotyka wyzwania, takie jak zapewnienie bezpieczeństwa w interakcji z ludźmi, co wymaga zaawansowanych systemów detekcji kolizji i przewidywania zachowań (Haddadin, Albu-Schäffer, & Hirzinger, 2009). Pojawiają się także problemy etyczne związane z zastępowaniem ludzi w pracy czy odpowiedzialnością za decyzje podejmowane przez autonomiczne systemy (Lin, Abney, & Bekey, 2011). Dynamiczne środowiska, w których działają roboty, wymagają zaawansowanych algorytmów adaptacyjnych, a brak jednolitych standardów utrudnia interoperacyjność i rozwój technologii (Alami et al., 2008).

Przyszłość robotyki i AI obejmuje rozwój robotów socjalnych zdolnych do rozumienia emocji i nawiązywania relacji z ludźmi (Breazeal, 2003), wykorzystanie nano- i mikrorobotów w medycynie (Li, 2009) oraz połączenie robotów z Internetem Rzeczy (IoT), co umożliwi tworzenie inteligentnych, połączonych systemów (Ray, 2018). Technologie, takie jak samoskładające się i modułarne roboty, oraz uczenie przez demonstrację, w którym roboty uczą się poprzez obserwację działań człowieka, również stanowią obiecujące kierunki rozwoju (Rus, 2015).

Integracja robotyki z AI otwiera nowe możliwości, przyczyniając się do postępu technologicznego w wielu sektorach. Pomimo wyzwań związanych z etyką, bezpieczeństwem i adaptacją, potencjał tej dziedziny obiecuje znaczące korzyści dla społeczeństwa, o ile rozwój tych technologii będzie odpowiednio ukierunkowany i zarządzany.

### 1.2.8 Chmura Obliczeniowa i Big Data

Chmura obliczeniowa i Big Data odgrywają fundamentalną rolę w rozwoju sztucznej inteligencji (AI) oraz uczenia maszynowego. Połączenie tych dwóch technologii umożliwia przechowywanie, przetwarzanie i analizowanie ogromnych zbiorów danych, które są kluczowe dla trenowania zaawansowanych modeli AI. Chmura obliczeniowa zapewnia dostęp do skalowalnych i elastycznych zasobów obliczeniowych przez Internet, a Big Data pozwala na przetwarzanie danych zbyt dużych, złożonych lub dynamicznych, by obsługiwać je tradycyjnymi metodami (Klipa, 2022).

Chmura obliczeniowa to model usług informatycznych, który umożliwia dostęp do takich zasobów, jak serwery, bazy danych czy oprogramowanie, bez konieczności zarządzania infrastrukturą. Charakteryzuje się elastycznością, skalowalnością oraz modelem płatności za rzeczywiste użycie zasobów. Wyróżnia się trzy główne modele usług: IaaS, zapewniające podstawową infrastrukturę obliczeniową; PaaS, oferujące środowiska do tworzenia i wdrażania aplikacji; oraz SaaS, umożliwiające korzystanie z oprogramowania przez Internet (Mell & Grance, 2011).

Big Data odnosi się do zbiorów danych o dużej objętości, różnorodności i szybkości napływu (tzw. 3V). Dodatkowe cechy to wartość, którą można uzyskać z analizy danych, oraz wiarygodność, określająca jakość i precyzję danych. Big Data wymagają zaawansowanych technologii przetwarzania, takich jak Hadoop czy Spark, które pozwalają na efektywne



przechowywanie i analizowanie informacji w czasie rzeczywistym (IBM, 2021; Tabakov, 2014).

Połączenie chmury obliczeniowej i Big Data umożliwia liczne zastosowania. W dziedzinie sztucznej inteligencji i uczenia maszynowego te technologie pozwalają na trenowanie modeli do rozpoznawania obrazów, przetwarzania języka naturalnego oraz analizy predykcyjnej (Deng & Li, 2013; Young et al., 2018). W medycynie wspierają analizę obrazów medycznych, personalizację terapii i odkrywanie nowych leków (Raghupathi & Raghupathi, 2014). W handlu pomagają w analizie zachowań konsumentów, segmentacji rynku i personalizacji ofert, a w IoT przetwarzają dane generowane przez urządzenia do monitorowania systemów i zarządzania zasobami (Xu, He, & Li, 2014; Fan, Lau, & Zhao, 2015).

Jednakże rozwój tych technologii wiąże się z wyzwaniami. Bezpieczeństwo i ochrona prywatności danych w chmurze rodzą obawy dotyczące zgodności z regulacjami prawnymi, co wymaga stosowania zaawansowanych metod szyfrowania. Skalowalność systemów Big Data zależy od efektywnego zarządzania zasobami obliczeniowymi, a różnorodność i heterogeniczność danych utrudniają ich integrację. Ponadto zarządzanie infrastrukturą chmurową wymaga specjalistycznej wiedzy (Chen, 2014).

Przyszłość chmury obliczeniowej i Big Data jest obiecująca. Rozwój przetwarzania brzegowego (edge computing) zmniejsza opóźnienia, umożliwiając lokalne przetwarzanie danych (Shi & Dustdar, 2016). Integracja z technologiami 5G przyspiesza analizę w czasie rzeczywistym (Nencioni, 2023), a kwantowe systemy obliczeniowe mogą zrewolucjonizować możliwości przetwarzania danych i trenowania modeli AI (Preskill, 2018). Ponadto dostępność sztucznej inteligencji jako usługi (AIaaS) ułatwia wdrażanie inteligentnych funkcji w aplikacjach.

Chmura obliczeniowa i Big Data stanowią fundament dla rozwoju nowoczesnych aplikacji sztucznej inteligencji. Dostarczają niezbędnej infrastruktury i narzędzi do przechowywania, przetwarzania i analizowania ogromnych ilości danych. Wyzwania związane z bezpieczeństwem, skalowalnością i zarządzaniem wymagają dalszych badań i innowacji. Integracja z innymi technologiami, takimi jak IoT, 5G czy komputery kwantowe, otwiera nowe perspektywy dla rozwoju AI.

Podsumowując kluczowe technologie w AI, takie jak uczenie maszynowe, głębokie uczenie, PjN czy wizja komputerowa, rewolucjonizują różne sektory gospodarki. Zrozumienie



tych technologii jest kluczowe dla dalszego rozwoju innowacyjnych rozwiązań i świadomego wdrażania AI w praktyce. Uczenie maszynowe stanowi fundament AI, umożliwiając systemom komputerowym uczenie się na podstawie danych i doświadczeń bez wyraźnego programowania. W ramach tej dziedziny wyróżniono różne podejścia, takie jak uczenie nadzorowane, nienadzorowane, półnadzorowane oraz uczenie na podstawie transferu. Każde z nich oferuje unikalne metody rozwiązywania złożonych problemów i przyczynia się do rozwoju inteligentnych systemów zdolnych do generalizacji i adaptacji.

Uczenie przez wzmacnianie podkreślono jako kluczową technikę, w której agenci uczą się optymalnych strategii działania poprzez interakcję z otoczeniem i otrzymywanie nagród za podjęte akcje. Ta metoda znalazła zastosowanie w robotyce, grach komputerowych oraz systemach autonomicznych, gdzie zdolność do podejmowania decyzji w dynamicznych środowiskach jest niezbędna.

Przetwarzanie Języka Naturalnego (PJN) umożliwia maszynom rozumienie, interpretację i generowanie języka ludzkiego. Dzięki zaawansowanym modelom językowym, takim jak BERT czy GPT, PJN osiągnęło znaczące postępy w interpretacji kontekstu, semantyki oraz emocji w tekście. Zastosowania PJN obejmują asystentów głosowych, tłumaczenie maszynowe, analizę sentymentu oraz chatboty, co rewolucjonizuje interakcję człowiek-maszyna.

Wizja komputerowa pozwala maszynom na interpretację i analizę danych wizualnych. Techniki takie jak konwolucyjne sieci neuronowe (CNN) umożliwiają rozpoznawanie obiektów, detekcję i segmentację obrazów, co ma kluczowe znaczenie w autonomicznych pojazdach, medycynie, przemyśle oraz systemach bezpieczeństwa.

Robotyka i AI integrują zdolności percepcyjne, decyzyjne i adaptacyjne, tworząc inteligentne maszyny zdolne do działania w dynamicznych i nieprzewidywalnych środowiskach. Połączenie robotyki z AI prowadzi do innowacji w przemyśle, medycynie, eksploracji kosmosu oraz interakcji człowiek-robot, wpływających na współczesne życie.

Chmura obliczeniowa i Big Data dostarczają niezbędnej infrastruktury i narzędzi do przechowywania, przetwarzania i analizy ogromnych zbiorów danych. Umożliwiają skalowalne trenowanie modeli AI oraz dostęp do potężnych zasobów obliczeniowych na żądanie, co jest istotne dla rozwoju zaawansowanych aplikacji w różnych sektorach, takich jak medycyna, finanse czy transport.



Podsumowując, kluczowe technologie w AI wzajemnie się uzupełniają, tworząc ekosystem, który napędza innowacje i umożliwia rozwiązywanie złożonych problemów. Wyzwania związane z objaśnialnością, etyką, skalowalnością i bezpieczeństwem wymagają dalszych badań oraz współpracy interdyscyplinarnej. Przyszłość sztucznej inteligencji zależy od naszej zdolności do integracji tych technologii w sposób odpowiedzialny i korzystny dla całego społeczeństwa.



## Rozdział 2. Rozwój dzieci i młodzieży w świetle psychologii i pedagogiki

Rozwój dzieci i młodzieży jest jednym z najważniejszych obszarów badawczych w psychologii i pedagogice, ponieważ okres ten stanowi fundament dla kształtowania osobowości, umiejętności społecznych i intelektualnych. Psychologia rozwoju oraz pedagogika podkreślają, że rozwój dzieci i młodzieży jest procesem dynamicznym, wielowymiarowym i zależnym od interakcji czynników biologicznych, społecznych i środowiskowych (Santrock, 2018). Zarówno teoria, jak i praktyka edukacyjna koncentrują się na wspieraniu tych procesów w sposób dostosowany do indywidualnych potrzeb dzieci.

Z perspektywy psychologicznej, rozwój dziecka można analizować przez pryzmat etapów życia, opisanych między innymi przez teorię psychospołeczną Erika Eriksona, która podkreśla znaczenie rozwiązywania konfliktów rozwojowych dla zdrowego funkcjonowania społecznego i emocjonalnego (Erikson, 1993). Natomiast w pedagogice zwraca się uwagę na rolę środowiska edukacyjnego w stymulowaniu rozwoju, zgodnie z założeniami teorii społecznego konstruktywizmu Lwa Wygotskiego, który podkreśla znaczenie interakcji społecznych i wsparcia nauczyciela w procesie uczenia się (Vygotsky, 1978).

Współczesne badania w psychologii rozwoju zwracają również uwagę na neuroplastyczność mózgu, która pozwala na adaptację i uczenie się przez całe życie, ale jest szczególnie intensywna w okresie dzieciństwa i adolescencji (Kolb & Gibb, 2011). Zrozumienie tych procesów pozwala na projektowanie skutecznych interwencji edukacyjnych i terapeutycznych, które wspierają optymalny rozwój.

Pedagogika natomiast podkreśla konieczność holistycznego podejścia do edukacji, uwzględniającego nie tylko rozwój poznawczy, ale także emocjonalny, społeczny i moralny. Badania pokazują, że środowiska edukacyjne oparte na relacjach, współpracy i wzajemnym szacunku mają pozytywny wpływ na rozwój dzieci i młodzieży (Bronfenbrenner, 1979).

Rozdział ten omawia kluczowe teorie i badania związane z rozwojem dzieci i młodzieży, podkreślając ich znaczenie dla praktyki edukacyjnej i wychowawczej.



## 2.1 Charakterystyka etapów rozwoju psychofizycznego

Rozwój psychofizyczny człowieka to dynamiczny proces, który przebiega w kilku etapach, determinowanych zarówno przez czynniki biologiczne, jak i środowiskowe. Każdy etap rozwoju charakteryzuje się specyficznymi osiągnięciami, wyzwaniem oraz potrzebami, które mają istotny wpływ na dalsze funkcjonowanie jednostki. W psychologii i pedagogice podkreśla się, że zrozumienie tych etapów jest kluczowe dla projektowania działań wychowawczych i edukacyjnych (Santrock, 2018).

### Wczesne dzieciństwo (0–3 lata)

Wczesne dzieciństwo to jeden z najbardziej dynamicznych okresów w rozwoju człowieka, charakteryzujący się intensywnymi zmianami biologicznymi, poznawczymi i emocjonalnymi. Jest to czas, w którym dziecko zdobywa podstawowe umiejętności niezbędne do dalszego funkcjonowania w świecie. Kluczową rolę odgrywa tu interakcja między genetycznymi predyspozycjami a wpływami środowiskowymi, takimi jak relacje z opiekunami, doświadczenia oraz warunki środowiskowe (Berger, 2018).

Pierwsze trzy lata życia są okresem intensywnego wzrostu i dojrzewania organizmu dziecka. Już w pierwszych miesiącach życia noworodek wykazuje szereg wrodzonych odruchów, takich jak ssanie, chwytanie czy odruch Moro, które pełnią kluczową rolę w przetrwaniu oraz adaptacji do otoczenia (Berger, 2018). W miarę upływu czasu odruchy te stopniowo zastępowane są bardziej świadomymi i złożonymi działaniami, co stanowi fundament dla rozwoju motorycznego.

Rozwój motoryczny w tym okresie można podzielić na dwa główne cechy: motorykę dużą i małą. Motoryka duża obejmuje rozwój umiejętności takich jak obracanie się, siadanie, raczkowanie i chodzenie. Z kolei motoryka mała odnosi się do precyzyjnych ruchów dłoni i palców, które umożliwiają manipulowanie przedmiotami (Santrock, 2018). Umiejętność chwytania, początkowo nieprecyzyjna, z czasem staje się coraz bardziej zaawansowana, co pozwala dziecku na eksplorację otoczenia i interakcję z nim.

Mózg dziecka w tym okresie rozwija się niezwykle intensywnie. Proces neuroplastyczności, czyli zdolności mózgu do tworzenia nowych połączeń neuronowych, osiąga swoje maksimum w pierwszych latach życia. Badania pokazują, że odpowiednia stymulacja w tym czasie

ma kluczowe znaczenie dla rozwoju funkcji poznawczych, emocjonalnych i społecznych (Kolb & Gibb, 2011).

Jean Piaget (1952) opisał rozwój poznawczy dzieci w wieku od 0 do 2 lat jako fazę sensoryczno-motoryczną, w której dziecko zdobywa wiedzę o świecie poprzez zmysły i działania motoryczne. Współczesne badania pokazują jednak, że rozwój poznawczy może być modyfikowany poprzez interakcję z nowymi technologiami. Raport "Toddlers, Tech and Talk" (2024) sugeruje, że odpowiednie wykorzystanie technologii może wspierać rozwój językowy u dzieci poprzez interakcje sensoryczne i komunikację wideo. Z kolei badania Cieszyńskiej (2024) wskazują, że nadmierne korzystanie z mediów elektronicznych może prowadzić do opóźnień w rozwoju mowy oraz zaburzeń uwagi. Pierwsze miesiące życia są okresem, w którym dziecko rozwija podstawowe schematy poznawcze, takie jak rozumienie, że przedmioty istnieją nawet wtedy, gdy są poza zasięgiem wzroku (stałość obiektu) (Piaget, 1952). To odkrycie, zazwyczaj osiągnięte około 8–12 miesiąca życia, stanowi istotny krok w rozwoju poznawczym.

Eksploracja otoczenia jest ważniejszym ze sposobów, w jaki dziecko uczy się o świecie. Manipulowanie przedmiotami, badanie ich kształtu, tekstury i dźwięku pozwala na rozwój umiejętności poznawczych. Dziecko zaczyna rozumieć związki przyczynowo-skutkowe, na przykład że potrząśnięcie grzechotką wydaje dźwięk. W wieku około dwóch lat pojawiają się pierwsze próby symbolicznego myślenia, takie jak naśladowanie działań dorosłych czy zabawy udawane.

Relacje z opiekunami odgrywają kluczową rolę w rozwoju emocjonalnym i społecznym dziecka w pierwszych latach życia. Teoria przywiązania Johna Bowlby'ego (1969) podkreśla, że stabilna i bezpieczna więź z opiekunami stanowi podstawę dla zdrowego rozwoju emocjonalnego. Dzieci, które mają możliwość nawiązania bezpiecznej więzi, są bardziej otwarte na eksplorację otoczenia i lepiej radzą sobie z wyzwaniami emocjonalnymi.

Pierwsze próby komunikacji pojawiają się już w okresie niemowlęcym, gdy dziecko zaczyna reagować na mimikę i intonację głosu opiekunów. Około 6 miesiąca życia niemowlę potrafi rozpoznawać emocje u innych osób, co jest pierwszym krokiem w rozwijaniu empatii. W wieku 1–2 lat dziecko zaczyna rozumieć podstawowe normy społeczne, takie jak współdziałanie z innymi, i nawiązywać pierwsze relacje z rówieśnikami.



Środowisko odgrywa istotną rolę w rozwoju dziecka. Warunki bytowe, jakość relacji z opiekunami oraz dostęp do stymulujących doświadczeń mają znaczący wpływ na rozwój psychofizyczny (Bronfenbrenner, 1979). Dzieci wychowywane w środowiskach bogatych w bodźce, takich jak książki, zabawki edukacyjne czy kontakt z naturą, mają większe szanse na rozwój swoich zdolności poznawczych i społecznych.

Wczesne dzieciństwo to okres intensywnych zmian i zdobywania kluczowych umiejętności, które stanowią fundament dla dalszego rozwoju. Rozwój biologiczny, poznawczy i emocjonalny w tym czasie jest wzajemnie powiązany, a relacje z opiekunami oraz środowisko, w którym dziecko dorasta, odgrywają kluczową rolę w kształtowaniu jego przyszłości.

### **Wiek przedszkolny (3–6 lat)**

Okres przedszkolny (3–6 lat) to czas intensywnego rozwoju dziecka w wielu sferach: poznawczej, społecznej, emocjonalnej i fizycznej. Etap ten ma kluczowe znaczenie dla kształtowania zdolności komunikacyjnych, relacji z innymi oraz budowania fundamentów, na których opierać się będzie dalszy rozwój w wieku szkolnym. Dzieci w wieku przedszkolnym rozwijają wyobraźnię, zdolności poznawcze i manualne, co odgrywa istotną rolę w ich codziennym funkcjonowaniu oraz przyszłych osiągnięciach.

Wiek przedszkolny to czas, w którym dziecko przechodzi przez fazę przedoperacyjną w teorii rozwoju poznawczego Jeana Piageta (1952). Charakterystyczne dla tego etapu są rozwój myślenia symbolicznego, egocentryzm oraz ograniczone rozumienie zasad logiki. Myślenie symboliczne umożliwia dziecku korzystanie z języka, obrazów i symboli do reprezentowania przedmiotów i wydarzeń. Dzięki temu dzieci potrafią wyobrażać sobie sytuacje, które nie mają miejsca w rzeczywistości, co znajduje swoje odzwierciedlenie w zabawie. Zabawy udawane, takie jak "dom" czy "sklep", są nie tylko formą rozrywki, ale również elementem rozwijania kreatywności i umiejętności społecznych.

Jednocześnie dzieci w tym wieku wykazują egocentryzm poznawczy, czyli tendencję do postrzegania świata wyłącznie z własnej perspektywy. Nie oznacza to jednak braku empatii, ale ograniczenie w rozumieniu, że inni mogą mieć odmienne punkty widzenia. Z czasem, dzięki interakcjom społecznym i odpowiednim doświadczeniom, dzieci zaczynają rozwijać zdolność do uwzględniania perspektywy innych.



Jednym z najbardziej zauważalnych czynników rozwoju w wieku przedszkolnym jest szybki rozwój językowy. W tym okresie dzieci uczą się nowych słów w niezwykle szybkim tempie, a ich zasób słownictwa może wzrosnąć z kilkuset do kilku tysięcy słów (Berger, 2018). Rozwija się również zdolność budowania bardziej złożonych zdań oraz rozumienia reguł gramatycznych. Komunikacja w tym wieku ma zasadniczą rolę w budowaniu relacji społecznych i wyrażaniu emocji. Dzieci uczą się negocjować, prosić o pomoc, wyrażać swoje potrzeby oraz rozwiązywać konflikty za pomocą słów. Język staje się również narzędziem samoregulacji, co pozwala dzieciom na kontrolowanie swoich emocji i zachowań.

W wieku przedszkolnym dzieci intensywnie rozwijają zdolności emocjonalne i społeczne. Zabawa z rówieśnikami jest niezmiernie ważna w uczeniu się norm społecznych, takich jak dzielenie się, współpraca oraz rozwiązywanie konfliktów. W tym czasie dzieci zaczynają rozumieć zasady funkcjonowania grupy i kształtują pierwsze przyjaźnie.

Zgodnie z teorią rozwoju psychospołecznego Erika Eriksona (1993), wiek przedszkolny to etap inicjatywy versus poczucia winy. Dzieci eksperymentują z nowymi aktywnościami, podejmują inicjatywę i uczą się samodzielności. Sukcesy w tych działaniach wzmacniają poczucie własnej wartości, podczas gdy porażki mogą prowadzić do poczucia winy. Ważnym zadaniem opiekunów w tym okresie jest wspieranie dzieci w eksploracji świata, jednocześnie zapewniając im poczucie bezpieczeństwa. Rozwój empatii staje się bardziej zauważalny w wieku przedszkolnym. Dzieci zaczynają rozumieć emocje innych osób i reagować na nie w sposób adekwatny, co sprzyja budowaniu pozytywnych relacji interpersonalnych.

Pod względem fizycznym dzieci w wieku przedszkolnym wykazują znaczące postępy w zakresie koordynacji ruchowej, siły i wytrzymałości. Rozwój motoryki dużej obejmuje takie umiejętności jak bieganie, skakanie, wspinanie się i jazda na rowerze. Z kolei rozwój motoryki małej pozwala na wykonywanie bardziej precyzyjnych czynności, takich jak rysowanie, malowanie, lepienie z plasteliny czy korzystanie z nożyczek (Santrock, 2018). Umiejętności manualne są szczególnie ważne, ponieważ przygotowują dzieci do nauki pisania i innych czynności wymagających precyzji. Równocześnie aktywność fizyczna odgrywa strategiczną rolę w zdrowym rozwoju układu mięśniowego i kostnego oraz wspiera ogólny rozwój dziecka.

Zabawa jest główną formą aktywności dzieci w wieku przedszkolnym. Stanowi ona nie tylko sposób spędzania czasu, ale także element rozwoju poznawczego, społecznego



i emocjonalnego. Zabawy symboliczne, takie jak udawanie, że jest się lekarzem lub nauczycielem, pomagają dzieciom zrozumieć otaczający świat oraz rozwijać umiejętności rozwiązywania problemów. Zabawy grupowe z rówieśnikami sprzyjają natomiast nauce współpracy, dzielenia się i przestrzegania reguł.

Lew Wygotski (1987) zwracał uwagę, że zabawa stymuluje rozwój wyższych funkcji poznawczych, takich jak planowanie i kontrola impulsywności. Wspiera również rozwój wyobraźni, która jest pierwszorzędna w twórczym myśleniu. Wiek przedszkolny to czas dynamicznego rozwoju we wszystkich sferach życia dziecka. Zdolności poznawcze, językowe, emocjonalne i fizyczne rozwijają się równolegle, wzajemnie się uzupełniając. Kluczową rolę odgrywają zabawa, interakcje społeczne oraz wsparcie opiekunów i nauczycieli, którzy mogą kształtować doświadczenia dzieci w sposób sprzyjający ich wszechstronnemu rozwojowi.

### **Wiek szkolny (6–12 lat)**

Wiek szkolny (6–12 lat) to etap intensywnego rozwoju poznawczego, emocjonalnego, społecznego i fizycznego, który przygotowuje dziecko do pełnienia bardziej zaawansowanych ról społecznych oraz rozwijania umiejętności potrzebnych w dorosłym życiu. Dzieci w tym wieku zaczynają postrzegać siebie jako część większej społeczności, a proces edukacyjny staje się centralnym elementem ich codziennego funkcjonowania. To również czas, kiedy kluczową rolę w ich życiu odgrywają rówieśnicy, a środowisko szkolne zaczyna mieć znaczący wpływ na ich rozwój.

W okresie szkolnym rozwój poznawczy wchodzi w fazę operacji konkretnych, zgodnie z teorią Jeana Piageta (1952). Na tym etapie dzieci nabywają zdolność logicznego myślenia, rozumowania oraz rozwiązywania problemów, o ile dotyczą one konkretnych, namacalnych sytuacji. Umiejętności abstrakcyjnego myślenia są na tym etapie jeszcze ograniczone, jednak dzieci zaczynają lepiej rozumieć zasady przyczynowo-skutkowe, klasyfikację oraz hierarchię.

Osiągnięciem w tym wieku jest rozwój zdolności do rozwiązywania problemów matematycznych oraz logicznych. Dzieci uczą się również organizacji czasu, planowania oraz przewidywania konsekwencji swoich działań, co wspiera rozwój umiejętności akademickich. Następną ważną funkcją jest rozwój pamięci, zarówno krótkotrwałej, jak i długotrwałej, który umożliwia efektywniejsze przyswajanie wiedzy w szkole (Berger, 2018).



Dzieci w tym wieku zaczynają także rozwijać umiejętności metapoznawcze, takie jak świadomość własnych procesów myślowych oraz umiejętność monitorowania i regulowania swojego uczenia się. Te zdolności są szczególnie ważne w procesie edukacyjnym, ponieważ pozwalają na bardziej świadome i celowe podejście do nauki.

Wiek szkolny to czas, kiedy dzieci rozwijają swoją tożsamość społeczną oraz uczą się funkcjonowania w grupie rówieśniczej. Relacje z rówieśnikami stają się kluczowym elementem ich życia, a dzieci zaczynają dostrzegać znaczenie współpracy, negocjacji oraz kompromisu w budowaniu relacji (Berger, 2018). Erik Erikson (1993) określił ten okres jako etap "pracowitości versus poczucia niższości", gdzie dzieci zdobywają poczucie kompetencji poprzez uczestnictwo w aktywnościach, które pozwalają im osiągać sukcesy. Udane doświadczenia w tym zakresie wzmacniają ich poczucie własnej wartości, natomiast niepowodzenia mogą prowadzić do poczucia niższości. W tym wieku dzieci zaczynają również rozumieć bardziej złożone normy społeczne oraz rozwijać umiejętności prospołeczne, takie jak empatia, współczucie oraz zdolność do wspierania innych. Znaczenie przyjaźni wzrasta, a dzieci często tworzą trwałe relacje, które stają się dla nich źródłem wsparcia emocjonalnego.

Pod względem emocjonalnym dzieci w wieku szkolnym stają się coraz bardziej samodzielne i zdolne do regulowania swoich emocji. Zaczynają lepiej rozumieć swoje uczucia, a także emocje innych, co wspiera rozwój umiejętności społecznych. Jest to również czas, kiedy dzieci uczą się radzenia sobie z trudnymi emocjami, takimi jak frustracja, złość czy lęk, co stanowi podstawę do rozwijania umiejętności radzenia sobie w sytuacjach stresowych (Santrock, 2018). Rodzina wciąż odgrywa kluczową rolę w życiu dziecka, jednak relacje z rówieśnikami i nauczycielami stają się coraz bardziej istotne. Wzajemne interakcje uczą dzieci, jak budować zaufanie, rozwiązywać konflikty oraz negocjować różnice zdań.

Rozwój fizyczny w wieku szkolnym jest zróżnicowany indywidualnie, jednak ogólnie dzieci doświadczają znaczącego wzrostu masy ciała, wzrostu oraz siły mięśniowej. Dzieci w tym wieku osiągają coraz większą sprawność fizyczną, co pozwala im uczestniczyć w bardziej zaawansowanych aktywnościach ruchowych, takich jak gry zespołowe, taniec czy sztuki walki (Berger, 2018). W tym czasie rozwój motoryki dużej pozwala na większą precyzję w ruchach, co znajduje zastosowanie w sporcie i codziennych aktywnościach. Rozwój motoryki małej umożliwia z kolei wykonywanie bardziej precyzyjnych czynności, takich jak pisanie, rysowanie czy używanie narzędzi. Ważnym elementem w tym okresie jest zachęcanie dzieci



do aktywności fizycznej, ponieważ sprzyja ona zdrowemu rozwojowi układu mięśniowego, kostnego oraz nerwowego.

Środowisko szkolne jest bardzo istotne w rozwoju dzieci w wieku 6–12 lat. Nauczyciele i rówieśnicy stają się dla dziecka wzorcami zachowań, a szkoła staje się miejscem, gdzie dzieci uczą się nie tylko umiejętności akademickich, ale także społecznych i emocjonalnych (Bronfenbrenner, 1979).

Równocześnie rodzina i domowe otoczenie nadal mają znaczący wpływ na rozwój dziecka. Wsparcie rodziców, ich zaangażowanie w proces edukacyjny oraz zapewnienie bezpiecznego środowiska sprzyjają rozwojowi zarówno poznawczemu, jak i emocjonalnemu. Wiek szkolny to okres wszechstronnego rozwoju dziecka, który obejmuje zdolności poznawcze, społeczne, emocjonalne i fizyczne. Każda z tych sfer wzajemnie na siebie oddziałuje, wpływając na całościowe funkcjonowanie dziecka. Elementem tego etapu jest edukacja, która dostarcza dziecku narzędzi do dalszego rozwoju, a także relacje społeczne, które kształtują jego tożsamość i umiejętności interpersonalne.

### **Adolescencja (12–18 lat)**

Adolescencja, czyli okres przejścia z dzieciństwa do dorosłości, jest czasem intensywnych zmian biologicznych, poznawczych, emocjonalnych i społecznych. Jest to etap w życiu człowieka, podczas którego jednostka rozwija swoją tożsamość, kształtuje system wartości i przygotowuje się do pełnienia ról dorosłych w społeczeństwie. Proces dojrzewania w tym okresie jest złożony i różnorodny, a jego przebieg zależy od wielu czynników, takich jak genetyka, środowisko społeczne i kultura (Santrock, 2018).

Adolescencja jest okresem intensywnych zmian biologicznych, które są rezultatem dojrzewania płciowego oraz gwałtownych zmian hormonalnych. U dziewcząt zazwyczaj proces ten rozpoczyna się wcześniej niż u chłopców, a jego głównym wyznacznikiem są takie zmiany, jak rozwój piersi, miesiączka czy zmiany w sylwetce ciała. U chłopców dojrzewanie obejmuje rozwój jąder, powiększenie mięśni, mutację głosu oraz wzrost owłosienia na ciele (Berger, 2018). Zmiany te są kontrolowane przez hormony płciowe, takie jak estrogeny i testosteron, których produkcja intensyfikuje się w okresie dojrzewania. Dojrzewanie fizyczne prowadzi również do gwałtownego wzrostu ciała, znanego jako "skok wzrostu". Mimo że zmiany



te są naturalnym elementem rozwoju, mogą one wywoływać u młodzieży pewne trudności emocjonalne, zwłaszcza jeśli ich przebieg odbiega od normy rówieśniczej.

Pod względem poznawczym młodzież osiąga etap operacji formalnych, zgodnie z teorią Jeana Piageta (1952). Na tym etapie rozwija się zdolność do myślenia abstrakcyjnego, co oznacza, że młodzież potrafi rozważać hipotetyczne scenariusze, planować na przyszłość oraz przewidywać konsekwencje swoich działań. Zdolność ta jest kluczowa dla rozwoju umiejętności rozwiązywania problemów i podejmowania decyzji. Rozwój poznawczy w tym okresie obejmuje także zwiększoną samoświadomość. Młodzież zaczyna zastanawiać się nad sobą, swoimi celami, wartościami oraz miejscem w społeczeństwie. Zwiększona zdolność do introspekcji i refleksji prowadzi często do kryzysów tożsamości, które są naturalnym elementem tego etapu życia. W myśl teorii rozwoju psychospołecznego Erika Eriksona (1993), adolescencja to czas "tożsamości versus pomieszania ról". W tym okresie młodzież stara się odpowiedzieć na pytanie "Kim jestem?" i zbudować stabilną tożsamość.

Adolescencja jest czasem intensywnych wyzwań emocjonalnych. Młodzież dąży do większej autonomii, co często prowadzi do napięć w relacjach z rodzicami i opiekunami. Chęć uniezależnienia się bywa źródłem konfliktów rodzinnych, które jednak mogą być konstruktywne, jeśli są oparte na wzajemnym szacunku i otwartości na dialog.

Zmiany hormonalne mogą również wpływać na wahania nastroju, które są charakterystyczne dla tego etapu życia. Adolescenci są bardziej podatni na stres i presję społeczną, co wynika z potrzeby akceptacji w grupie rówieśniczej. Jednocześnie rozwój zdolności emocjonalnych, takich jak empatia i samoregulacja, pozwala młodzieży na lepsze radzenie sobie z trudnymi emocjami i budowanie zdrowych relacji interpersonalnych (Santrock, 2018).

Relacje z rówieśnikami stają się w okresie adolescencji elementem życia młodzieży. Grupa rówieśnicza pełni rolę wsparcia emocjonalnego, a także pomaga młodzieży w rozwijaniu umiejętności społecznych, takich jak współpraca, negocjacja i radzenie sobie z konfliktami. Przyjaźnie i pierwsze relacje romantyczne mają ogromne znaczenie dla kształtowania tożsamości społecznej młodzieży.

Jednocześnie młodzież zaczyna dostrzegać i analizować normy społeczne oraz role płciowe. Presja rówieśnicza, zarówno pozytywna, jak i negatywna, wpływa na zachowanie i decyzje młodych ludzi. Współczesne badania wskazują, że rola mediów społecznościowych w życiu



młodzieży jest coraz większa i ma istotny wpływ na ich rozwój społeczny, emocjonalny oraz tożsamość (Berger, 2018).

Środowisko rodzinne, szkolne i rówieśnicze jest pierwszoplanowe w procesie rozwoju młodzieży. Rodzice, nauczyciele i inni dorośli pełnią funkcję przewodników i mentorów, wspierając młodzież w ich dążeniu do samodzielności. Ważne jest, aby zapewniać młodym ludziom stabilne, bezpieczne środowisko, które sprzyja eksploracji i rozwojowi. Adolescencja to okres dynamicznych zmian we wszystkich sferach życia młodego człowieka. W tym czasie młodzież zdobywa umiejętności i doświadczenia, które przygotowują ją do dorosłości. Wyzwaniem dla rodziców, nauczycieli i opiekunów jest wspieranie młodzieży w radzeniu sobie z trudnościami oraz tworzenie warunków sprzyjających zdrowemu rozwojowi.

Rozwój psychofizyczny człowieka to proces złożony, w którym każdy etap odgrywa istotną rolę w kształtowaniu osobowości i kompetencji jednostki. Wspieranie tych procesów wymaga zrozumienia specyfiki poszczególnych okresów oraz stosowania odpowiednich strategii wychowawczych i edukacyjnych.

## **2.2 Rola otoczenia społecznego i technologii w rozwoju młodych ludzi**

Rozwój młodych ludzi jest procesem wielowymiarowym, który obejmuje zmiany zachodzące w sferze fizycznej, psychicznej, społecznej i emocjonalnej. Proces ten jest kształtowany przez szereg czynników, zarówno wewnętrznych, takich jak genetyka i temperament, jak i zewnętrznych, takich jak otoczenie społeczne, system edukacji czy dostęp do technologii. Współczesne społeczeństwo charakteryzuje się dynamicznymi zmianami technologicznymi oraz przeobrażeniami w strukturach społecznych, co daje impuls na codzienne doświadczenia młodzieży oraz kształtowanie ich tożsamości. W okoliczności globalizacji, urbanizacji i rozwoju technologicznego młodzi ludzie są coraz bardziej narażeni na nowe wyzwania, ale jednocześnie mają dostęp do narzędzi i możliwości, które mogą wspierać ich rozwój.

Otoczenie społeczne, na które składają się rodzina, rówieśnicy oraz instytucje edukacyjne, odgrywa wiodącą rolę w procesie dorastania. Rodzina jako pierwsze środowisko socjalizacyjne wpływa na sposób, w jaki młodzież postrzega siebie i świat. Relacje rodzinne, w tym styl wychowania, poziom wsparcia emocjonalnego i modelowanie zachowań, mają fundamentalne znaczenie dla kształtowania się wartości, norm i postaw młodych ludzi. Z kolei grupa



rówieśnicza, zwłaszcza w okresie dojrzewania, staje się źródłem wsparcia emocjonalnego, ale także presji społecznej, która może prowadzić zarówno do pozytywnych, jak i negatywnych konsekwencji. Instytucje edukacyjne, takie jak szkoły, również odgrywają istotną rolę w rozwoju młodzieży, oferując przestrzeń do zdobywania wiedzy, rozwijania umiejętności społecznych oraz budowania relacji z rówieśnikami i nauczycielami.

Równocześnie technologia, która stała się nieodłącznym elementem życia współczesnej młodzieży, odgrywa zarówno wspierającą, jak i potencjalnie destrukcyjną rolę w ich rozwoju. Internet, media społecznościowe i aplikacje cyfrowe dostarczają młodym ludziom narzędzi do komunikacji, nauki i rozrywki, umożliwiając rozwój kompetencji cyfrowych oraz poszerzanie horyzontów. Jednak nadmierne korzystanie z technologii wiąże się z ryzykiem uzależnienia, problemami emocjonalnymi, takimi jak depresja czy lęk, oraz trudnościami w nawiązywaniu autentycznych relacji interpersonalnych. Technologia wpływa również na sposób, w jaki młodzież postrzega siebie, ponieważ media społecznościowe często promują nierealistyczne standardy, które mogą negatywnie wpływać na samoocenę.

Ten podrozdział analizuje znaczenie otoczenia społecznego i technologii w procesie rozwoju młodych ludzi, przedstawiając zarówno korzyści, jakie mogą przynieść, jak i zagrożenia, które mogą wynikać z ich oddziaływania. Na podstawie aktualnych badań naukowych omówione zostaną kluczowe aspekty wpływu rodziny, rówieśników i edukacji na rozwój młodzieży, a także rola technologii w kształtowaniu ich tożsamości, umiejętności i emocji. Celem jest przedstawienie kompleksowego obrazu czynników, które kształtują współczesną młodzież, oraz zidentyfikowanie obszarów wymagających szczególnej uwagi, aby wspierać ich harmonijny rozwój w szybko zmieniającym się świecie.

## **Rola otoczenia społecznego w rozwoju młodzieży**

### **Wpływ rodziny**

Rodzina stanowi podstawowe i najważniejsze środowisko socjalizacyjne, w którym młodzi ludzie nabywają pierwsze wzorce zachowań, normy społeczne i wartości. Jest to miejsce, gdzie kształtują się fundamenty osobowości dziecka, jego podejście do życia oraz relacje z otoczeniem. Relacje w rodzinie, w tym sposób komunikacji, okazywania wsparcia oraz ustalania granic, mają ogromny wpływ na rozwój emocjonalny, społeczny i poznawczy młodzieży. Badania nad wpływem rodziny na rozwój młodych ludzi wskazują, że styl wychowania przyjęty przez rodziców oraz jakość relacji rodzinnych determinują sposób, w jaki



młodzież radzi sobie z wyzwaniami okresu dorastania oraz kształtuje swoją tożsamość. Styl wychowania, czyli sposób, w jaki rodzice odnoszą się do swoich dzieci, wyznacza ramy dla interakcji w rodzinie. Diana Baumrind (1971) wyróżniła cztery podstawowe style wychowania: autorytatywny, autorytarny, permissywny oraz zaniedbujący. Każdy z tych stylów charakteryzuje się różnym poziomem kontroli i ciepła emocjonalnego, co ma istotny wpływ na rozwój młodzieży.

Styl autorytatywny jest uznawany za najbardziej korzystny dla rozwoju młodych ludzi. Charakteryzuje się wysokim poziomem wsparcia emocjonalnego oraz jasno określonymi granicami. Rodzice autorytatywni zachęcają dzieci do samodzielności, jednocześnie zapewniając im poczucie bezpieczeństwa i wsparcia. Badania Steinberga (2016) pokazują, że dzieci wychowywane w środowisku autorytatywnym wykazują wyższy poziom samooceny, samodyscypliny oraz lepsze wyniki w nauce. Ten styl wychowania sprzyja również rozwijaniu umiejętności społecznych i emocjonalnych, takich jak empatia, asertywność czy zdolność do podejmowania decyzji.

Styl autorytarny, w którym dominuje wysoka kontrola przy jednoczesnym braku ciepła emocjonalnego, może prowadzić do rozwoju zachowań opartych na strachu przed karą lub podporządkowaniu. Dzieci wychowywane w takim środowisku często mają trudności z podejmowaniem samodzielnych decyzji oraz wykazują niższy poziom samooceny (Baumrind, 1971).

Styl permissywny charakteryzuje się dużym poziomem ciepła, ale brakiem jasnych granic i kontroli. Rodzice permissywni są bardzo wyrozumiali, ale nie stawiają wyraźnych oczekiwań wobec dzieci. Może to prowadzić do trudności z samokontrolą, problemów z respektowaniem norm społecznych oraz niższej motywacji do osiągnięcia celów (Maccoby & Martin, 1983).

Styl zaniedbujący jest najbardziej destrukcyjny, ponieważ łączy niski poziom ciepła emocjonalnego z brakiem kontroli. Dzieci wychowywane w takich warunkach często mają trudności z budowaniem relacji, radzeniem sobie z emocjami oraz osiągnięciem sukcesów edukacyjnych i zawodowych (Baumrind, 1971).

Relacje między rodzicami a dziećmi mają kluczowe znaczenie dla kształtowania się osobowości młodzieży. Rodzina, która oferuje stabilne, wspierające środowisko, sprzyja budowaniu poczucia własnej wartości, bezpieczeństwa emocjonalnego oraz zdolności do nawiązywania zdrowych relacji interpersonalnych. Z kolei rodziny dysfunkcyjne, w których

występują konflikty, brak komunikacji lub przemoc, mogą negatywnie wpływać na rozwój młodych ludzi, prowadząc do problemów emocjonalnych, takich jak lęk czy depresja (Bowlby, 1969).

Komunikacja w rodzinie jest niezbędna w procesie dorastania. Rodzice, którzy aktywnie słuchają swoich dzieci, okazują zainteresowanie ich problemami oraz oferują konstruktywne wsparcie, budują relacje oparte na zaufaniu i wzajemnym szacunku. Tego rodzaju relacje pomagają młodzieży radzić sobie z wyzwaniami okresu dojrzewania, takimi jak presja rówieśnicza, stres szkolny czy rozwój tożsamości.

Okres adolescencji to czas intensywnych zmian biologicznych, emocjonalnych i społecznych, które mogą być źródłem stresu i niepewności. W tym czasie rodzina pełni kluczową rolę w zapewnianiu młodzieży wsparcia emocjonalnego i poczucia bezpieczeństwa. Badania pokazują, że młodzi ludzie, którzy mają silne więzi rodzinne, są mniej narażeni na ryzykowne zachowania, takie jak nadużywanie substancji psychoaktywnych czy angażowanie się w przestępczość (Santrock, 2018).

Rodzina odgrywa również istotną rolę w kształtowaniu postaw wobec edukacji i pracy. Rodzice, którzy aktywnie angażują się w proces edukacyjny swoich dzieci, na przykład poprzez monitorowanie ich postępów w nauce czy wspieranie w rozwiązywaniu problemów szkolnych, sprzyjają rozwojowi motywacji wewnętrznej oraz aspiracji zawodowych (Eccles & Roeser, 2011).

Współczesne rodziny stają przed nowymi wyzwaniami, które wynikają z dynamicznych zmian społecznych i technologicznych. Wzrost znaczenia technologii cyfrowych oraz mediów społecznościowych w życiu młodzieży oddziałuje na sposób komunikacji w rodzinie. Coraz częściej rodzice i dzieci spędzają mniej czasu na bezpośrednich interakcjach, co może osłabiać więzi rodzinne (Livingstone & Byrne, 2018). Ponadto, współczesne rodziny często muszą mierzyć się z problemami związanymi z pogodzeniem życia zawodowego i rodzinnego, co może ograniczać ich zdolność do zapewnienia dzieciom odpowiedniego wsparcia emocjonalnego.

Rodzina jest istotnym elementem w procesie socjalizacji i rozwoju młodych ludzi. Styl wychowania, jakość relacji rodzinnych oraz wsparcie emocjonalne oferowane przez rodziców mają istotny wpływ na kształtowanie osobowości, wartości i zachowań młodzieży. Współczesne wyzwania wymagają od rodzin dostosowania się do zmieniających się warunków



społecznych i technologicznych, jednak podstawowe zasady, takie jak budowanie relacji opartych na zaufaniu i wzajemnym szacunku, pozostają niezmiennie.

### **Wpływ rówieśników**

Relacje z rówieśnikami odgrywają kluczową rolę w rozwoju młodzieży, zwłaszcza w okresie adolescencji, kiedy to młodzi ludzie przechodzą przez proces intensywnego kształtowania swojej tożsamości oraz rozwijania umiejętności społecznych i emocjonalnych. W miarę jak młodzież dąży do większej autonomii wobec rodziny, grupa rówieśnicza zaczyna pełnić funkcję ważnego źródła wsparcia emocjonalnego, akceptacji i poczucia przynależności. Relacje te mają zarówno pozytywne, jak i negatywne konsekwencje, które mogą znacząco wpłynąć na rozwój psychospołeczny młodego człowieka.

Grupy rówieśnicze dostarczają młodzieży możliwości eksperymentowania z różnymi rolami społecznymi, co jest szczególnie istotne w poszukiwaniu tożsamości. Jak zauważają Brown i Larson (2009), interakcje z rówieśnikami pozwalają młodzieży na rozwijanie umiejętności interpersonalnych, takich jak negocjacja, współpraca czy rozwiązywanie konfliktów. Poprzez wspólne działania, takie jak zabawa, nauka czy rozmowy, młodzi ludzie uczą się norm społecznych oraz rozwijają zdolność do empatii i zrozumienia punktu widzenia innych. Relacje rówieśnicze wspierają również rozwój samoświadomości, ponieważ młodzież często korzysta z informacji zwrotnych od swoich rówieśników, aby lepiej zrozumieć siebie i swoje miejsce w społeczeństwie.

Głównym z kontekstów relacji z rówieśnikami jest znaczenie grupy jako źródła wsparcia emocjonalnego. Przyjaźnie, które często nabierają szczególnej głębi w okresie adolescencji, dostarczają młodzieży poczucia akceptacji oraz przestrzeni do dzielenia się problemami i doświadczeniami. Relacje te mogą przeciwdziałać poczuciu samotności i izolacji, co jest szczególnie istotne w okresie dojrzewania, kiedy młodzi ludzie często borykają się z różnorodnymi wyzwaniami emocjonalnymi i społecznymi (Santrock, 2018). Badania wykazują, że młodzież, która ma silne relacje z rówieśnikami, lepiej radzi sobie z trudnościami życiowymi, a także wykazuje większe poczucie własnej wartości.

Jednakże relacje rówieśnicze mogą mieć również negatywny wpływ na rozwój młodzieży. Presja rówieśnicza, zwłaszcza w grupach o silnych normach i wymaganiach, może prowadzić do podejmowania ryzykownych zachowań, takich jak używanie substancji psychoaktywnych, angażowanie się w przestępczość czy ryzykowne zachowania seksualne (Henneberger, 2020).



Młodzi ludzie, którzy odczuwają silną potrzebę akceptacji w grupie, mogą być bardziej podatni na negatywne wpływy rówieśników, co może prowadzić do problemów behawioralnych lub trudności w nauce. Ponadto konflikty w relacjach rówieśniczych, takie jak odrzucenie, nękanie czy cyberprzemoc, mogą mieć długotrwałe konsekwencje dla zdrowia psychicznego młodzieży, prowadząc do zwiększonego ryzyka depresji, lęku czy izolacji społecznej (Keles et al., 2020).

Rówieśnicy odgrywają również ważną rolę w procesie kształtowania norm i wartości młodzieży. Wspólne uczestnictwo w działaniach grupowych, takich jak projekty szkolne, aktywności sportowe czy działania społeczne, sprzyja internalizacji pozytywnych wartości, takich jak współpraca, odpowiedzialność i solidarność. Jednak w grupach o negatywnych normach, gdzie dominują zachowania antyspołeczne, młodzież może rozwijać negatywne wzorce postępowania, które mogą utrudniać ich dalszy rozwój (Berger, 2018).

Relacje z rówieśnikami mają również istotne znaczenie w kontekście rozwoju kompetencji komunikacyjnych. Współczesne technologie, takie jak media społecznościowe, odgrywają coraz większą rolę w kształtowaniu relacji rówieśniczych. Dzięki nim młodzież może utrzymywać kontakt z większą liczbą osób i budować różnorodne relacje. Jednak technologia może również wpływać negatywnie, na przykład poprzez promowanie powierzchownych interakcji czy zwiększanie ekspozycji na cyberprzemoc. Dlatego kluczowe jest, aby młodzież rozwijała umiejętności krytycznego myślenia i odpowiedzialnego korzystania z mediów cyfrowych.

Podsumowując, relacje z rówieśnikami są niezwykle istotnym elementem rozwoju społecznego i emocjonalnego młodzieży. Z jednej strony dostarczają młodym ludziom możliwości rozwoju umiejętności interpersonalnych, wsparcia emocjonalnego oraz kształtowania tożsamości. Z drugiej strony mogą stanowić źródło negatywnych wpływów, takich jak presja społeczna czy konflikty. Zrozumienie znaczenia tych relacji oraz wspieranie młodzieży w budowaniu zdrowych interakcji z rówieśnikami jest ważne dla ich harmonijnego rozwoju i dobrostanu.

### **Rola instytucji edukacyjnych**

Szkoła jako instytucja edukacyjna ma ogromny wpływ w życiu młodych ludzi, stanowiąc środowisko, w którym zdobywają wiedzę, rozwijają umiejętności społeczne i kształtują swoje aspiracje na przyszłość. Jest to nie tylko miejsce nauki, ale również przestrzeń, w której młodzież buduje relacje, eksperymentuje z różnymi rolami społecznymi



i rozwija swoją tożsamość. Rola szkoły w rozwoju poznawczym, emocjonalnym i społecznym młodych ludzi jest szeroko opisywana w literaturze, a jej znaczenie podkreślają zarówno psychologia rozwojowa, jak i pedagogika.

Środowisko szkolne ma ogromny wpływ na rozwój poznawczy młodzieży. Szkoła dostarcza struktury i wyzwań, które stymulują procesy myślowe, wspierają rozwój krytycznego myślenia oraz zdolności rozwiązywania problemów. Badania Eccles i Roeser (2011) pokazują, że szkoły, które oferują uczniom wsparcie emocjonalne oraz stymulujące wyzwania akademickie, sprzyjają ich motywacji do nauki oraz osiągnięciu pozytywnych wyników edukacyjnych. W takich środowiskach uczniowie czują się bardziej zaangażowani w proces nauczania, co z kolei przekłada się na lepsze wyniki akademickie i większą satysfakcję z nauki.

Istotną składową środowiska szkolnego są relacje między uczniami a nauczycielami. Nauczyciele odgrywają rolę mentorów, którzy nie tylko przekazują wiedzę, ale również wspierają uczniów w ich rozwoju emocjonalnym i społecznym. Pozytywne relacje z nauczycielami, oparte na wzajemnym szacunku i zaufaniu, mogą znacząco wpłynąć na poczucie własnej wartości uczniów oraz ich motywację do nauki. Nauczyciele, którzy stosują indywidualne podejście do uczniów, uwzględniając ich potrzeby i możliwości, tworzą środowisko sprzyjające rozwojowi. Badania pokazują, że uczniowie, którzy czują się wspierani przez nauczycieli, są bardziej skłonni do podejmowania wyzwań i angażowania się w naukę (Santrock, 2018).

Szkoła jest również miejscem, gdzie młodzież rozwija swoje umiejętności społeczne. Relacje z rówieśnikami, takie jak przyjaźnie czy współpraca w grupach, odgrywają istotną rolę w kształtowaniu kompetencji społecznych, takich jak komunikacja, negocjacja czy empatia. Interakcje z rówieśnikami dostarczają młodzieży możliwości eksperymentowania z różnymi rolami społecznymi oraz uczą, jak radzić sobie z konfliktami czy rozwiązywać problemy w sposób konstruktywny. Wspólne działania, takie jak projekty grupowe czy udział w wydarzeniach szkolnych, sprzyjają budowaniu relacji i wzmacnianiu poczucia przynależności do społeczności szkolnej.

Jednocześnie szkoła pełni funkcję miejsca, gdzie młodzież ma możliwość eksplorowania swoich zainteresowań i talentów. Programy szkolne, zajęcia dodatkowe i inicjatywy społeczne umożliwiają uczniom rozwijanie pasji oraz nabywanie nowych umiejętności. Takie doświadczenia wpływają na kształtowanie aspiracji i poczucia własnej skuteczności, które są kluczowe dla dalszego rozwoju i podejmowania decyzji dotyczących przyszłości. Szkoły,



które oferują szeroką gamę możliwości rozwoju, wspierają uczniów w odkrywaniu i realizowaniu ich potencjału.

Negatywne cechy środowiska szkolnego, takie jak brak wsparcia ze strony nauczycieli, konflikty z rówieśnikami czy wysoka presja akademicka, mogą jednak stanowić wyzwanie dla młodzieży. Problemy takie jak nękanie, cyberprzemoc czy wykluczenie społeczne w środowisku szkolnym mogą negatywnie wpływać na zdrowie psychiczne uczniów, prowadząc do problemów emocjonalnych, takich jak lęk czy depresja (Berger, 2018). Dlatego kluczowe jest, aby szkoły aktywnie działały na rzecz tworzenia środowiska sprzyjającego dobrostanowi uczniów, promując wartości takie jak szacunek, współpraca i wzajemne wsparcie.

Rolą szkoły jest również przygotowanie młodzieży do pełnienia ról społecznych i zawodowych w dorosłym życiu. Szkoły powinny nie tylko przekazywać wiedzę akademicką, ale również rozwijać u uczniów kompetencje miękkie, takie jak umiejętność pracy w zespole, kreatywność czy zdolność adaptacji do zmieniających się warunków. Współczesne podejścia edukacyjne, takie jak edukacja projektowa czy nauczanie oparte na problemach, stawiają nacisk na rozwijanie tych umiejętności, co pozwala młodzieży lepiej przygotować się do wyzwań przyszłości.

Podsumowując, szkoła odgrywa niezwykle istotną rolę w rozwoju poznawczym, społecznym i emocjonalnym młodzieży. Tworzy środowisko, które przekładają się na ich wyniki edukacyjne, relacje społeczne oraz kształtowanie tożsamości i aspiracji. Wspierające i stymulujące środowisko szkolne, które promuje wartości takie jak współpraca, szacunek i rozwój indywidualny, może znacząco przyczynić się do harmonijnego rozwoju młodzieży, przygotowując ich do pełnienia ról w społeczeństwie oraz podejmowania wyzwań w dorosłym życiu.

## **Wpływ technologii na rozwój młodzieży**

### **Pozytywne aspekty technologii**

Technologia, w szczególności Internet, jest centralnym punktem w życiu współczesnej młodzieży, oferując szerokie możliwości dostępu do zasobów informacji oraz narzędzi edukacyjnych. Dzięki niej proces uczenia się staje się bardziej interaktywny i dostępny, umożliwiając młodym ludziom rozwijanie swoich zainteresowań oraz zdobywanie wiedzy poza tradycyjnym systemem edukacji. Internet pozwala na szybkie i łatwe dotarcie do informacji



na różne tematy, co sprzyja samodzielnemu poszerzaniu wiedzy oraz rozwijaniu umiejętności krytycznego myślenia (Livingstone et al., 2018).

Platformy edukacyjne, takie jak Khan Academy, Coursera czy EdX, oferują młodzieży dostęp do kursów i materiałów edukacyjnych tworzonych przez specjalistów z całego świata. Dzięki nim młodzi ludzie mogą uczyć się w swoim tempie, dostosowując tempo i zakres materiału do własnych potrzeb (Means et al., 2013). Tego rodzaju rozwiązania wspierają rozwój samodzielności w nauce, a także umożliwiają zdobywanie wiedzy i umiejętności, które mogą nie być dostępne w lokalnych szkołach.

Wykorzystanie technologii w edukacji daje możliwość rozwijania zainteresowań w sposób indywidualny. Internet dostarcza szerokiego wachlarza zasobów, takich jak filmy instruktażowe, e-booki, artykuły naukowe czy fora tematyczne, które pomagają młodym ludziom zgłębiać różne dziedziny wiedzy. Na przykład młodzież zainteresowana programowaniem może korzystać z platform takich jak Codecademy czy Scratch, które oferują praktyczne ćwiczenia i projekty (OECD, 2019). Takie podejście sprzyja rozwijaniu pasji oraz zdobywaniu specjalistycznych umiejętności w młodym wieku.

Technologia umożliwia również współpracę i interakcję z innymi uczniami na skalę globalną. Dzięki mediom społecznościowym, komunikatorom oraz platformom edukacyjnym młodzież może uczestniczyć w projektach międzynarodowych, wymieniać się pomysłami oraz zdobywać różnorodne perspektywy kulturowe (Selwyn, 2016). Interakcje tego rodzaju rozwijają kompetencje międzykulturowe, umiejętności współpracy oraz zdolność do pracy w grupach.

Pomimo licznych korzyści, technologia niesie również pewne wyzwania, takie jak problem selekcji informacji. Młodzież, mając dostęp do ogromnych ilości danych, często musi zmierzyć się z trudnością oceny ich wiarygodności i przydatności. W erze dezinformacji i fałszywych wiadomości (fake news), kluczowe staje się rozwijanie umiejętności krytycznego myślenia oraz oceny źródeł (Bulger & Davison, 2018). W związku z tym edukacja medialna powinna być integralnym elementem systemu szkolnictwa, aby pomóc młodzieży w odpowiedzialnym korzystaniu z technologii.

Innym wyzwaniem związanym z wykorzystaniem technologii w edukacji jest nierówny dostęp do zasobów cyfrowych. W wielu regionach, zwłaszcza w krajach rozwijających się, brak dostępu do szybkiego Internetu oraz odpowiedniego sprzętu komputerowego ogranicza możliwości korzystania z nowoczesnych narzędzi edukacyjnych. OECD (2019) wskazuje,



że brak równości w dostępie do technologii cyfrowych może pogłębiać istniejące nierówności edukacyjne, co wymaga działań mających na celu zapewnienie powszechnego dostępu do narzędzi cyfrowych.

Podsumowując, technologia oferuje młodzieży ogromne możliwości w zakresie zdobywania wiedzy i rozwijania zainteresowań, jednocześnie stawiając przed nimi wyzwania związane z selekcją informacji oraz dostępnością zasobów. Właściwe wykorzystanie technologii w edukacji wymaga nie tylko odpowiednich narzędzi, ale również wsparcia ze strony nauczycieli, rodziców oraz decydentów politycznych, którzy powinni promować krytyczne i odpowiedzialne podejście do korzystania z zasobów cyfrowych.

### **Rozwój kompetencji cyfrowych**

Umiejętności cyfrowe odgrywają kluczową rolę we współczesnym społeczeństwie, które coraz bardziej opiera się na technologiach informacyjno-komunikacyjnych. W erze globalizacji i szybko rozwijającej się gospodarki cyfrowej zdolność do efektywnego korzystania z technologii jest nie tylko atutem, ale wręcz koniecznością. Młodzież, będąca jedną z najbardziej aktywnych grup użytkowników technologii, rozwija kompetencje, które wykraczają poza tradycyjne umiejętności akademickie i obejmują krytyczne myślenie, rozwiązywanie problemów oraz efektywną komunikację w środowisku cyfrowym (OECD, 2019).

Umiejętności cyfrowe takie jak zdolność do krytycznego myślenia, która pozwala młodzieży analizować, oceniać i weryfikować informacje dostępne w Internecie. W dobie dezinformacji, fałszywych wiadomości (fake news) oraz manipulacji cyfrowej, umiejętność rozróżniania wiarygodnych źródeł informacji od tych, które mogą wprowadzać w błąd, ma kluczowe znaczenie (Livingstone et al., 2018). Młodzi ludzie muszą być wyposażeni w narzędzia, które pozwolą im oceniać jakość treści oraz podejmować świadome decyzje dotyczące ich dalszego wykorzystania.

Rozwiązywanie problemów to kolejny istotny element kompetencji cyfrowych, który rozwija się dzięki korzystaniu z nowoczesnych technologii. Aplikacje, gry edukacyjne i interaktywne platformy uczą młodzież podejmowania decyzji w zmieniających się warunkach oraz znajdowania kreatywnych rozwiązań dla skomplikowanych sytuacji. Na przykład gry logiczne, takie jak „Minecraft: Education Edition”, nie tylko promują myślenie analityczne, ale również uczą współpracy i planowania strategicznego (Selwyn, 2016). Takie doświadczenia



nie tylko wzbogacają proces uczenia się, ale również przygotowują młodych ludzi do wyzwań współczesnego rynku pracy, który coraz bardziej wymaga umiejętności adaptacji i elastyczności.

Komunikacja w środowisku cyfrowym jest równie wymiarem umiejętności cyfrowych. Młodzież, korzystając z mediów społecznościowych, platform komunikacyjnych oraz narzędzi współpracy online, rozwija zdolności interpersonalne, takie jak efektywna komunikacja, negocjacja czy praca zespołowa. Narzędzia takie jak Zoom, Microsoft Teams czy Google Workspace umożliwiają młodym ludziom współpracę w grupach zarówno lokalnych, jak i międzynarodowych. Dzięki temu uczniowie uczą się, jak skutecznie wyrażać swoje myśli, prezentować pomysły oraz współpracować z różnorodnymi zespołami (Bocconi et al., 2016).

Pomimo licznych korzyści, rozwijanie umiejętności cyfrowych przez młodzież wiąże się również z pewnymi wyzwaniami, jak równowaga między czasem spędzonym online a innymi aktywnościami, takimi jak interakcje twarzą w twarz, sport czy czytanie. Nadmierne korzystanie z technologii może prowadzić do problemów związanych z koncentracją, zdrowiem psychicznym oraz izolacją społeczną (Hale & Guan, 2015). Dlatego ważne jest, aby młodzi ludzie uczyli się odpowiedzialnego korzystania z technologii oraz równoważenia życia online i offline.

Innym wyzwaniem jest nierówny dostęp do technologii cyfrowych, znany jako cyfrowa przepaść (digital divide). Młodzież z obszarów o ograniczonym dostępie do Internetu lub braku odpowiedniego sprzętu może być pozbawiona możliwości rozwijania swoich umiejętności cyfrowych w równym stopniu co ich rówieśnicy z lepiej wyposażonych regionów (van Deursen & van Dijk, 2019). Ta różnica w dostępie może prowadzić do pogłębiania nierówności społecznych i edukacyjnych.

Aby w pełni wykorzystać potencjał technologii, istotne jest wprowadzenie programów edukacyjnych, które wspierają rozwijanie umiejętności cyfrowych. Edukacja medialna, włączona do programów szkolnych, może pomóc młodzieży w zrozumieniu złożoności świata cyfrowego, rozwijaniu krytycznego myślenia oraz nauce efektywnego korzystania z nowoczesnych narzędzi (Bulger & Davison, 2018). Takie podejście zapewni młodym ludziom solidne podstawy do funkcjonowania w dynamicznie zmieniającym się społeczeństwie informacyjnym.



Podsumowując, umiejętności cyfrowe są niezbędne we współczesnym świecie, w którym technologia odgrywa coraz większą rolę. Aktywne korzystanie z technologii przez młodzież wspiera rozwój krytycznego myślenia, rozwiązywania problemów oraz komunikacji w środowisku cyfrowym. Aby jednak zminimalizować potencjalne zagrożenia i zapewnić równy dostęp do możliwości, konieczne jest wsparcie edukacyjne i infrastrukturalne, które umożliwi młodzieży pełne wykorzystanie potencjału technologii.

### **Wsparcie społeczne i budowanie relacji**

Media społecznościowe i komunikatory internetowe odgrywają kluczową rolę w życiu współczesnej młodzieży, umożliwiając zarówno utrzymywanie kontaktów z rodziną i przyjaciółmi, jak i nawiązywanie nowych znajomości. Dzięki nim młodzi ludzie mogą dzielić się swoimi doświadczeniami, myślami i emocjami, niezależnie od miejsca, w którym się znajdują. Dla wielu nastolatków platformy takie jak Facebook, Instagram, Snapchat czy TikTok stają się podstawowym narzędziem komunikacji, które ułatwia budowanie i podtrzymywanie relacji. Media społecznościowe mogą stanowić istotne źródło wsparcia emocjonalnego, szczególnie dla młodzieży, która doświadcza trudności w nawiązywaniu relacji w świecie rzeczywistym (Best et al., 2014).

Jednym z największych atutów mediów społecznościowych jest ich zdolność do zacierania barier geograficznych. Rodziny i przyjaciele, którzy mieszkają w różnych częściach świata, mogą pozostawać w stałym kontakcie dzięki komunikatorom internetowym, takim jak WhatsApp czy Messenger. Młodzież, korzystając z tych narzędzi, nie tylko utrzymuje istniejące więzi, ale również buduje nowe relacje z osobami o podobnych zainteresowaniach, często należącymi do różnych kultur. Takie interakcje wzbogacają ich doświadczenia społeczne oraz rozwijają kompetencje międzykulturowe (Livingstone & Sefton-Green, 2016).

Media społecznościowe są szczególnie ważne dla młodzieży, która z różnych przyczyn może mieć ograniczone możliwości interakcji w świecie rzeczywistym. Dla osób nieśmiałych, introwertycznych lub zmagających się z problemami zdrowotnymi media społecznościowe mogą stanowić bezpieczną przestrzeń do komunikacji. Dzięki nim młodzież może dzielić się swoimi uczuciami i myślami, co często prowadzi do poczucia przynależności i wsparcia społecznego. Badania pokazują, że aktywność w mediach społecznościowych może być związana z wyższym poziomem samooceny oraz redukcją poczucia samotności (Ellison et al., 2007).



Jednakże korzystanie z mediów społecznościowych nie jest pozbawione wyzwań i potencjalnych zagrożeń. Z jednej strony umożliwiają one młodzieży budowanie pozytywnych relacji i wspierają ich rozwój emocjonalny, ale z drugiej mogą prowadzić do problemów takich jak uzależnienie, cyberprzemoc czy porównywanie się z innymi, co często skutkuje obniżeniem samooceny. Młodzież narażona na porównywanie się z nierealistycznymi standardami promowanymi w mediach społecznościowych może doświadczać uczucia niezadowolenia z własnego wyglądu czy osiągnięć, co negatywnie wpływa na ich zdrowie psychiczne (Keles et al., 2020).

Innym istotnym problemem związanym z mediami społecznościowymi jest ich wpływ na jakość snu młodzieży. Korzystanie z urządzeń elektronicznych przed snem, zwłaszcza smartfonów, może zakłócać rytm dobowy, prowadząc do trudności z zasypianiem i obniżonej jakości snu (Hale & Guan, 2015). Ponadto ciągła dostępność i natychmiastowość komunikacji w mediach społecznościowych może prowadzić do poczucia presji bycia online, co negatywnie przekłada się na zdolność do odpoczynku i regeneracji.

Aby zminimalizować potencjalne negatywne skutki korzystania z mediów społecznościowych, ważne jest edukowanie młodzieży na temat odpowiedzialnego korzystania z technologii. Rodzice i nauczyciele mogą odegrać kluczową rolę w pomaganiu młodzieży w rozwijaniu zdrowych nawyków cyfrowych, takich jak ograniczanie czasu spędzanego w mediach społecznościowych, dbanie o prywatność oraz krytyczne podejście do treści publikowanych online (Livingstone et al., 2018).

Podsumowując, media społecznościowe i komunikatory internetowe odgrywają znaczącą rolę w życiu młodzieży, oferując zarówno możliwości rozwoju społecznego i emocjonalnego, jak i stawiając przed nimi wyzwania. Odpowiedzialne korzystanie z tych narzędzi może pomóc młodym ludziom w budowaniu pozytywnych relacji, jednocześnie minimalizując ryzyko związane z ich nadmiernym użytkowaniem.

## **Negatywne aspekty technologii**

### **Uzależnienie od technologii**

Nadmierne korzystanie z technologii, zwłaszcza urządzeń cyfrowych i mediów społecznościowych, staje się coraz większym wyzwaniem w życiu współczesnej młodzieży. Problematiczne korzystanie z Internetu, smartfonów oraz gier komputerowych prowadzi do wzrostu ryzyka uzależnienia, które może negatywnie wpływać na zdrowie psychiczne



i fizyczne młodych ludzi. Uzależnienie to nie tylko przesadna ilość czasu spędzanego online, ale także utrata kontroli nad użytkowaniem technologii oraz występowanie negatywnych skutków, takich jak zaniedbywanie obowiązków szkolnych, rodzinnych czy społecznych (Kuss & Lopez-Fernandez, 2016).

Jednym z najczęściej omawianych skutków nadmiernego korzystania z technologii jest negatywny wpływ na zdrowie psychiczne młodzieży. Badania wskazują, że problematyczne użytkowanie Internetu (PIU - Project Implementation Unit) i mediów społecznościowych może prowadzić do wzrostu poziomu lęku, depresji oraz poczucia izolacji społecznej (Keles et al., 2020). Młodzi ludzie, którzy spędzają wiele godzin online, narażeni są na nieustanne porównywanie się z innymi użytkownikami mediów społecznościowych, co często prowadzi do obniżenia samooceny i niezadowolenia z własnego życia. Negatywne skutki te są potęgowane przez nierealistyczne standardy piękna i sukcesu promowane w mediach cyfrowych (Huang, 2017).

Ponadto uzależnienie od gier komputerowych, znane jako Gaming Disorder, zostało oficjalnie uznane przez Światową Organizację Zdrowia (WHO) jako zaburzenie zdrowia psychicznego (WHO, 2018). Charakteryzuje się ono nadmiernym zaangażowaniem w gry wideo, co prowadzi do zaniedbywania innych obszarów życia. Badania dowodzą, że młodzież uzależniona od gier często doświadcza wyższych poziomów stresu oraz problemów z regulacją emocji (Griffiths et al., 2016).

### **Wpływ na zdrowie fizyczne**

Nadmierne korzystanie z technologii negatywnie wpływa również na zdrowie fizyczne młodzieży, stanowiąc istotne wyzwanie ich ogólnego dobrostanu. Problem stanowi brak aktywności fizycznej, który prowadzi do szeregu negatywnych konsekwencji zdrowotnych, takich jak wzrost ryzyka otyłości, problemy z układem krążenia oraz inne choroby przewlekłe, w tym cukrzyca typu 2. Młodzież spędzająca wiele godzin dziennie przed ekranami często zaniedbuje aktywność fizyczną, co przyczynia się do wzrostu masy ciała i spadku ogólnej sprawności fizycznej (Stiglic & Viner, 2019). Brak ruchu ma również wpływ na kondycję układu mięśniowo-szkieletowego, prowadząc do osłabienia mięśni oraz obniżenia elastyczności stawów.

Długotrwałe korzystanie z urządzeń cyfrowych wiąże się także z problemami posturalnymi. Młodzież, która spędza znaczną część dnia w pozycji siedzącej, często przybiera niewłaściwą



postawę ciała, co prowadzi do dolegliwości takich jak bóle pleców, karku czy głowy. Tzw. „smartphone neck” lub „tablet neck” to terminy coraz częściej pojawiające się w literaturze medycznej, odnoszące się do schorzeń związanych z przeciążeniem kręgosłupa szyjnego spowodowanym długotrwałym nachyleniem głowy nad ekranem urządzenia (Neupane et al., 2017). Problem ten jest szczególnie niepokojący w przypadku młodzieży, ponieważ ich układ kostny wciąż się rozwija, a nieprawidłowa postawa może prowadzić do trwałych deformacji i przewlekłych dolegliwości w przyszłości.

Potomnym zagadnieniem jest wpływ ekranów na jakość snu, co ma kluczowe znaczenie dla zdrowia i samopoczucia młodzieży. Ekspozycja na niebieskie światło emitowane przez urządzenia elektroniczne zakłóca naturalną produkcję melatoniny, hormonu odpowiedzialnego za regulację rytmu dobowego (Hale & Guan, 2015). Spędzanie czasu przed ekranami, zwłaszcza w godzinach wieczornych, może powodować trudności z zasypianiem, skrócenie czasu snu oraz obniżenie jego jakości. Brak odpowiedniej ilości snu ma negatywny wpływ na zdolność koncentracji, pamięć oraz ogólne funkcjonowanie poznawcze młodzieży. Badania wykazują, że uczniowie, którzy regularnie korzystają z urządzeń elektronicznych przed snem, osiągają gorsze wyniki w nauce, są bardziej zmęczeni i mają trudności z regulacją emocji (Carter et al., 2016).

Negatywny wpływ technologii na zdrowie fizyczne młodzieży może być również związany z nadmiernym obciążeniem wzroku. Długotrwałe patrzenie na ekran powoduje tzw. „cyfrowe zmęczenie oczu” (digital eye strain), objawiające się suchością oczu, bólem głowy, rozmytym widzeniem oraz uczuciem zmęczenia. Problem ten jest szczególnie powszechny wśród młodzieży, która spędza wiele godzin na korzystaniu z urządzeń elektronicznych zarówno w celach edukacyjnych, jak i rozrywkowych (Rosenfield, 2016).

W celu przeciwdziałania negatywnym skutkom zdrowotnym związanym z nadmiernym korzystaniem z technologii, konieczne jest promowanie zdrowych nawyków wśród młodzieży. Regularne przerwy podczas korzystania z urządzeń cyfrowych, aktywność fizyczna oraz ograniczenie czasu spędzanego przed ekranem, zwłaszcza przed snem, mogą przyczynić się do poprawy zdrowia fizycznego i ogólnego samopoczucia młodzieży. Rodzice i nauczyciele powinni edukować młodych ludzi na temat wpływu technologii na zdrowie, a także zachęcać ich do stosowania zasad higieny cyfrowej, takich jak reguła 20-20-20 (co 20 minut patrzenie przez 20 sekund na obiekt oddalony o 20 stóp) w celu ochrony wzroku (Rosenfield, 2016).



Podsumowując, nadmierne korzystanie z technologii może mieć poważne konsekwencje dla zdrowia fizycznego młodzieży, wpływając na ich postawę, jakość snu, kondycję fizyczną oraz zdrowie oczu. Kluczowe jest zatem promowanie zrównoważonego podejścia do korzystania z urządzeń cyfrowych, które pozwoli młodym ludziom czerpać korzyści z technologii przy jednoczesnym minimalizowaniu jej negatywnego wpływu.

### **Wpływ na zdrowie psychiczne**

Badania nasuwają myśl na wyraźny związek między intensywnym korzystaniem z mediów społecznościowych a pogorszeniem zdrowia psychicznego młodzieży. W szczególności zauważono korelację między wysokim poziomem zaangażowania w media społecznościowe a objawami depresji, lęku oraz obniżonym dobrostanem psychicznym (Keles et al., 2020). Media społecznościowe, choć mogą oferować wsparcie społeczne i umożliwiać budowanie relacji, niosą również ze sobą ryzyko, szczególnie przy presji społecznej, porównywania się z innymi oraz ekspozycji na cyberprzemoc.

Głównym mechanizmem negatywnego wpływu mediów społecznościowych na zdrowie psychiczne jest zjawisko porównywania się z innymi użytkownikami. Młodzież często porównuje swoje życie z idealizowanymi obrazami publikowanymi w mediach społecznościowych, co prowadzi do niezadowolenia z własnego wyglądu, osiągnięć czy stylu życia (Huang, 2017). Tego rodzaju porównania mogą skutkować obniżeniem samooceny, poczuciem nieadekwatności oraz wzrostem poziomu stresu. Badania wykazują, że młodzi ludzie, którzy spędzają dużo czasu na przeglądaniu profili innych użytkowników, częściej doświadczają uczucia zazdrości oraz niezadowolenia z własnego życia (Festinger, 1954; Chou & Edge, 2012).

Pozostałym zagrożeniem związanym z mediami społecznościowymi jest cyberprzemoc. W przeciwieństwie do tradycyjnych form przemocy, cyberprzemoc charakteryzuje się anonimowością sprawców oraz brakiem ograniczeń czasowych i przestrzennych, co sprawia, że jej skutki mogą być bardziej długotrwałe i dotkliwe. Młodzież, która doświadcza cyberprzemocy, jest bardziej narażona na rozwój zaburzeń psychicznych, takich jak depresja, lęk czy myśli samobójcze (Kowalski et al., 2014). Ofiary cyberprzemocy często czują się osamotnione, bezradne i wykluczone społecznie, co dodatkowo pogłębia ich problemy emocjonalne.



Negatywne skutki korzystania z mediów społecznościowych mogą być również związane z tzw. „fear of missing out” (FOMO), czyli lękiem przed przegapieniem ważnych wydarzeń. To zjawisko, charakterystyczne dla młodzieży intensywnie korzystającej z mediów społecznościowych, prowadzi do obsesyjnego sprawdzania powiadomień i ciągłego pozostawania online (Przybylski et al., 2013; Bowman, 2019). FOMO zwiększa poziom stresu, zakłóca koncentrację oraz negatywnie oddziałuje na jakość snu, co w dłuższej perspektywie może obniżać ogólny dobrostan psychiczny.

Ważnym czynnikiem pośredniczącym w relacji między mediami społecznościowymi a zdrowiem psychicznym jest sposób, w jaki młodzież korzysta z tych platform. Badania demonstrują, że aktywne korzystanie, takie jak publikowanie własnych treści i interakcja z innymi użytkownikami, wiąże się z mniejszym ryzykiem problemów psychicznych w porównaniu z biernym przeglądaniem treści (Verduyn et al., 2017). Biernie korzystanie może prowadzić do negatywnych porównań społecznych i poczucia izolacji, podczas gdy aktywne angażowanie się sprzyja budowaniu pozytywnych relacji i poczucia przynależności.

Aby zminimalizować negatywne skutki korzystania z mediów społecznościowych, ważne jest promowanie edukacji medialnej, która nauczy młodzież krytycznego podejścia do treści online oraz odpowiedzialnego korzystania z technologii. Wspieranie zdrowych nawyków cyfrowych, takich jak ograniczenie czasu spędzanego na mediach społecznościowych czy regularne przerwy od ekranów, może przyczynić się do poprawy dobrostanu psychicznego młodzieży (Livingstone & Sefton-Green, 2016). Rodzice i nauczyciele powinni również aktywnie uczestniczyć w edukacji młodych ludzi, pomagając im zrozumieć mechanizmy działania mediów społecznościowych i ich potencjalny wpływ na emocje oraz zdrowie psychiczne.

Podsumowując, intensywne korzystanie z mediów społecznościowych wiąże się z wieloma wyzwaniami dla zdrowia psychicznego młodzieży. Porównywanie się z innymi, narażenie na cyberprzemoc oraz zjawisko FOMO to tylko niektóre z problemów, które mogą prowadzić do obniżenia samooceny i wzrostu poziomu lęku oraz depresji. Kluczowe jest podejmowanie działań edukacyjnych i profilaktycznych, które pomogą młodzieży w rozwijaniu zdrowych nawyków cyfrowych oraz budowaniu pozytywnych relacji z technologią.

### **Zaburzenia snu i koncentracji**

Ekspozycja na światło emitowane przez ekrany urządzeń elektronicznych przed snem, szczególnie światło niebieskie, stanowi istotny czynnik wpływający na zdrowie i jakość snu



młodzieży. Światło to zakłóca naturalną produkcję melatoniny, hormonu odpowiedzialnego za regulację cyklu snu i czuwania. W konsekwencji, spędzanie czasu przed ekranami wieczorem utrudnia zasypianie, skraca czas snu oraz obniża jego jakość, co z kolei jest przyczyną negatywnego funkcjonowania poznawczego i emocjonalnego w ciągu dnia (Hale & Guan, 2015). Badania nasuwają myśl, że młodzież korzystająca z urządzeń cyfrowych przed snem częściej zgłasza trudności z zasypianiem, wybudzanie się w nocy oraz uczucie zmęczenia rano (Carter et al., 2016).

Negatywne skutki zakłócenia rytmu dobowego są szczególnie istotne w okresie dojrzewania, kiedy to naturalne zmiany w zegarze biologicznym przesuwają preferowane godziny snu na późniejsze. W połączeniu z używaniem urządzeń cyfrowych przed snem, młodzież może doświadczać przewlekłego niedoboru snu, który prowadzi do problemów z koncentracją, pamięcią oraz regulacją emocji. Niedobór snu wpływa również na układ odpornościowy, co może zwiększać podatność na choroby oraz obniżać ogólną wydolność organizmu (Wheaton et al., 2016).

Oprócz problemów ze snem, jest wielozadaniowość cyfrowa, związana z intensywnym korzystaniem z technologii. Wielozadaniowość, definiowana jako jednoczesne wykonywanie kilku czynności wymagających uwagi, np. oglądanie wideo, pisanie wiadomości i przeglądanie mediów społecznościowych, jest powszechna wśród młodzieży. Jednak badania dowodzą, że taki sposób korzystania z technologii może negatywnie wpływać na zdolność koncentracji, pamięć oraz ogólną efektywność poznawczą (Rosen et al., 2013). Wielozadaniowość wymaga ciągłego przełączania uwagi między zadaniami, co zwiększa obciążenie poznawcze i prowadzi do spadku jakości wykonywanej pracy.

Długotrwałe korzystanie z technologii w sposób wielozadaniowy może prowadzić do trwałych zmian w sposobie przetwarzania informacji. Badania sugerują, że młodzież przyzwyczajona do wielozadaniowości może mieć trudności z utrzymaniem uwagi podczas wykonywania zadań wymagających skupienia przez dłuższy czas (Junco, 2012). Takie nawyki mogą negatywnie wpływać na osiągnięcia szkolne oraz zdolność do rozwiązywania złożonych problemów.

Przejawem przeciwdziałania tym negatywnym skutkom jest edukacja młodzieży na temat higieny cyfrowej i świadomego korzystania z technologii. Rodzice i nauczyciele mogą odegrać kluczową rolę w promowaniu zdrowych nawyków, takich jak ograniczenie czasu spędzanego przed ekranami przed snem, wprowadzenie regularnych przerw od urządzeń cyfrowych oraz nauka technik zarządzania czasem. Praktycznym rozwiązaniem może być



wprowadzenie „cyfrowej godziny policyjnej” – wyłączenia urządzeń na godzinę przed snem, co pozwoli organizmowi na dostosowanie się do naturalnego rytmu dobowego (Cain & Gradisar, 2010).

Podsumowując, ekspozycja na światło niebieskie emitowane przez urządzenia cyfrowe przed snem oraz praktyki wielozadaniowości cyfrowej mogą mieć poważne konsekwencje dla zdrowia i funkcjonowania poznawczego młodzieży. Problemy ze snem i obniżenie zdolności koncentracji stanowią istotne wyzwania, które wymagają podjęcia działań zarówno na poziomie indywidualnym, jak i systemowym. Edukacja w zakresie zdrowych nawyków cyfrowych oraz promowanie równowagi między korzystaniem z technologii a innymi aktywnościami są kluczowe dla zapewnienia harmonijnego rozwoju młodzieży.

Uzależnienie od technologii ma również poważne konsekwencje społeczne. Nadmierne korzystanie z Internetu i gier komputerowych może prowadzić do osłabienia więzi rodzinnych oraz ograniczenia czasu spędzanego z bliskimi. Młodzi ludzie często wybierają interakcje online zamiast kontaktów twarzą w twarz, co może prowadzić do izolacji społecznej i problemów z rozwijaniem umiejętności interpersonalnych (Livingstone & Sefton-Green, 2016). Aby przeciwdziałać negatywnym skutkom nadmiernego korzystania z technologii, ważne jest wdrażanie programów edukacyjnych oraz interwencyjnych, które wspierają młodzież w rozwijaniu zdrowych nawyków cyfrowych. Rodzice i nauczyciele mogą odegrać kluczową rolę, promując równowagę między życiem online i offline, ograniczając czas spędzany przed ekranem oraz edukując młodzież na temat zagrożeń związanych z uzależnieniem od technologii (Bulger & Davison, 2018). Wsparcie psychologiczne oraz terapia behawioralno-poznawcza są również skutecznymi metodami leczenia uzależnienia od Internetu i gier komputerowych (King et al., 2017).

## **Interakcja między otoczeniem społecznym a technologią**

### **Technologia jako narzędzie społecznej interakcji**

Dzięki mediom społecznościowym, komunikatorom internetowym oraz platformom wideo, młodzież może utrzymywać relacje z rodziną i przyjaciółmi, niezależnie od odległości, a także nawiązywać nowe znajomości. Jednak wpływ technologii na komunikację i budowanie relacji jest złożony, ponieważ może ona zarówno wzbogacać, jak i zastępować tradycyjne formy kontaktów społecznych (Subrahmanyam & Greenfield, 2008).



Pozytywną cechą technologii w czynniku komunikacji jest ułatwienie nawiązywania i utrzymywania relacji, zwłaszcza dla młodzieży, która może doświadczać barier w kontaktach twarzą w twarz, takich jak nieśmiałość, introwersja czy ograniczenia geograficzne. Komunikatory internetowe, takie jak WhatsApp czy Messenger, pozwalają młodym ludziom na natychmiastowe przekazywanie wiadomości, dzielenie się doświadczeniami i organizowanie spotkań, co wzmacnia poczucie przynależności oraz buduje sieci społeczne (Livingstone & Sefton-Green, 2016). Platformy takie jak Instagram czy TikTok oferują młodzieży możliwość wyrażania siebie i budowania tożsamości społecznej poprzez publikowanie treści, interakcje z rówieśnikami oraz uczestnictwo w globalnych dyskusjach.

Technologia pozwala również młodzieży na rozwijanie umiejętności międzykulturowych i poszerzanie horyzontów poprzez kontakt z osobami z różnych środowisk kulturowych i społecznych. Dzięki globalnym społecznościom online młodzi ludzie mogą uczyć się, jak radzić sobie z różnorodnością oraz rozwijać kompetencje związane z empatią i współpracą międzykulturową (Selwyn, 2016).

Chociaż technologia wzbogaca możliwości komunikacyjne, może również prowadzić do zastępowania tradycyjnych form kontaktów społecznych. Młodzież, która spędza dużo czasu na interakcjach online, może zaniedbywać relacje twarzą w twarz, co negatywnie wpływa na rozwój umiejętności interpersonalnych, takich jak komunikacja niewerbalna czy zdolność do rozwiązywania konfliktów w rzeczywistości (Turkle, 2015). Badania pokazują, że nadmierne korzystanie z mediów społecznościowych może prowadzić do poczucia samotności

oraz obniżenia jakości relacji międzyludzkich, szczególnie jeśli relacje online nie są wspierane kontaktami w rzeczywistości (Keles et al., 2020).

Zjawisko tzw. „płytkiej komunikacji” (shallow communication) jest wyzwaniem wynikającym z cyfrowej komunikacji. Wirtualne interakcje, choć szybkie i efektywne, często brakuje im głębi emocjonalnej, co może osłabiać jakość relacji. Młodzi ludzie, korzystając z technologii, mogą unikać trudnych rozmów lub konfliktów, co w dłuższej perspektywie

Z drugiej strony, technologie cyfrowe mogą stanowić istotne źródło wsparcia społecznego, szczególnie dla młodzieży zmagającej się z problemami emocjonalnymi, zdrowotnymi czy społecznymi. Społeczności online, fora dyskusyjne oraz grupy wsparcia oferują młodym ludziom przestrzeń, w której mogą dzielić się swoimi doświadczeniami, uzyskiwać porady oraz



poczucie zrozumienia i akceptacji (Best et al., 2014). Platformy te mogą być szczególnie cenne dla osób zmagających się z poczuciem izolacji w środowisku offline.

Technologia odgrywa również coraz większą rolę w kształtowaniu relacji romantycznych wśród młodzieży. Aplikacje randkowe oraz platformy społecznościowe pozwalają młodym ludziom na poznawanie potencjalnych partnerów oraz rozwijanie relacji na odległość. Chociaż technologie te oferują nowe możliwości, mogą również prowadzić do wyzwań, takich jak trudności w budowaniu zaufania czy ryzyko związane z prywatnością i bezpieczeństwem (Anderson & Jiang, 2018).

Aby zmaksymalizować pozytywne efekty technologii w komunikacji i budowaniu relacji, kluczowe jest promowanie edukacji medialnej, która uczy młodzież, jak odpowiedzialnie korzystać z technologii, równoważyć czas spędzany online i offline oraz rozwijać umiejętności komunikacyjne w obu tych sferach (Livingstone & Helsper, 2007). Nauczyciele, rodzice oraz decydenci polityczni powinni wspierać młodych ludzi w rozwijaniu zdrowych nawyków cyfrowych oraz budowaniu autentycznych relacji, zarówno online, jak i w świecie rzeczywistym.

Technologia zmienia sposób, w jaki młodzi ludzie komunikują się i budują relacje, oferując zarówno szanse, jak i wyzwania. Interakcje online mogą wzbogacać życie społeczne młodzieży, umożliwiając nawiązywanie nowych znajomości oraz utrzymywanie relacji na odległość. Jednak zastępowanie tradycyjnych form kontaktów społecznych komunikacją cyfrową może negatywnie wpływać na rozwój umiejętności interpersonalnych i jakość relacji, dlatego promowanie świadomego i odpowiedzialnego korzystania z technologii jest decydujące dla zapewnienia młodym ludziom harmonijnego rozwoju społecznego.

### **Wpływ rodziny na korzystanie z technologii**

Rodzice odgrywają kluczową rolę w kształtowaniu nawyków związanych z korzystaniem z technologii przez młodzież, zarówno poprzez modelowanie własnych zachowań, jak i wprowadzanie zasad regulujących korzystanie z urządzeń elektronicznych. Współczesne badania potwierdzają, że rodzice, którzy aktywnie uczestniczą w cyfrowym życiu swoich dzieci, mogą znacząco wpłynąć na ich umiejętność odpowiedzialnego korzystania z technologii oraz zminimalizować potencjalne zagrożenia związane z nadmiernym użytkowaniem (Livingstone & Byrne, 2018). Dynamiczny rozwój technologii sprawia, że rola



rodziców staje się jeszcze bardziej istotna, ponieważ młodzież potrzebuje przewodnictwa w nawigowaniu w cyfrowym świecie.

Jednym z najważniejszych sposobów, w jaki rodzice wpływają na nawyki technologiczne młodzieży, jest modelowanie własnych zachowań. Młodzi ludzie często naśladują wzorce obserwowane w rodzinie, co oznacza, że sposób, w jaki rodzice korzystają z urządzeń elektronicznych, ma bezpośredni wpływ na ich dzieci (Uhls et al., 2014). Rodzice, którzy spędzają znaczną część czasu przed ekranami, mogą nieświadomie przekazywać młodzieży sygnał, że korzystanie z technologii przez długie godziny jest akceptowalne. Z kolei rodzice, którzy potrafią zachować równowagę między czasem spędzonym online i offline, mogą inspirować młodzież do zdrowego korzystania z technologii.

Wprowadzenie zasad ograniczających korzystanie z urządzeń w określonych sytuacjach, takich jak podczas posiłków czy w godzinach wieczornych, stanowi ważny element modelowania zdrowych nawyków. Przykładowo, badania dostrzegają, że rodziny, które spożywają posiłki bez korzystania z urządzeń cyfrowych, częściej zgłaszają wyższy poziom satysfakcji z relacji rodzinnych oraz lepszą komunikację (Hiniker et al., 2016). Takie podejście promuje nie tylko zdrowe nawyki technologiczne, ale również wzmacnia więzi rodzinne.

Rodzice mogą wpływać na nawyki technologiczne młodzieży również poprzez ustanawianie jasnych zasad dotyczących korzystania z urządzeń elektronicznych. Ograniczenia czasowe, zasady dotyczące treści, które mogą być oglądane, oraz wspólne ustalanie priorytetów, takich jak nauka czy aktywność fizyczna, są skutecznymi strategiami w zapobieganiu negatywnym skutkom nadmiernego korzystania z technologii (Livingstone et al., 2017). Kluczowe jest, aby te zasady były jasno komunikowane i dostosowane do wieku oraz potrzeb dziecka, a także wprowadzane w sposób konsekwentny.

Badania pokazują, że rodzice, którzy stosują podejście autorytatywne, charakteryzujące się połączeniem ciepła emocjonalnego i stawiania jasnych granic, mają większe szanse na skuteczne kształtowanie zdrowych nawyków cyfrowych u młodzieży (Rudi et al., 2015). Takie podejście pozwala młodym ludziom czuć się wspieranymi, jednocześnie ucząc ich odpowiedzialności za własne decyzje związane z korzystaniem z technologii.

Innym skutecznym sposobem, w jaki rodzice mogą wspierać zdrowe nawyki technologiczne, jest wspólne korzystanie z technologii z dziećmi. Oglądanie filmów, granie w gry czy korzystanie z aplikacji edukacyjnych może stanowić okazję do budowania relacji, a także



do rozmów na temat treści konsumowanych w Internecie. Wspólne doświadczenia pomagają rodzicom lepiej zrozumieć cyfrowy świat młodzieży i wprowadzać odpowiednie strategie edukacyjne (Clark, 2011). Ponadto takie podejście umożliwia rodzicom edukację dzieci na temat bezpieczeństwa online, w tym ochrony prywatności, unikania cyberprzemocy oraz rozpoznawania fałszywych informacji.

Wyzwaniem związanym z rolą rodziców w kształtowaniu nawyków technologicznych młodzieży jest ich własny poziom kompetencji cyfrowych. Współczesne technologie zmieniają się w szybkim tempie, co sprawia, że wielu rodziców może czuć się mniej kompetentnymi w porównaniu z ich dziećmi, które często są bardziej biegłe w korzystaniu z urządzeń cyfrowych (Livingstone & Byrne, 2018). Dlatego kluczowe jest, aby rodzice mieli dostęp do programów edukacyjnych, które pomogą im zrozumieć technologiczne wyzwania oraz nauczyć się skutecznych strategii wspierania zdrowych nawyków cyfrowych.

Rola rodziców w kształtowaniu nawyków związanych z korzystaniem z technologii przez młodzież jest nieoceniona. Poprzez modelowanie własnych zachowań, ustanawianie zasad oraz wspólne korzystanie z technologii, rodzice mogą wspierać młodych ludzi w rozwijaniu zdrowych i odpowiedzialnych nawyków cyfrowych. Współczesny świat technologii wymaga jednak od rodziców nie tylko konsekwencji i zaangażowania, ale również edukacji w zakresie kompetencji cyfrowych, aby mogli skutecznie pełnić swoją rolę przewodników w cyfrowym świecie.

## **Edukacja medialna**

Wprowadzenie edukacji medialnej w szkołach jest jednym z działań, które mogą pomóc młodzieży w odpowiedzialnym korzystaniu z technologii oraz w rozwijaniu umiejętności krytycznego myślenia. W dynamicznie zmieniającym się środowisku cyfrowym młodzi ludzie potrzebują narzędzi, które pozwolą im analizować treści cyfrowe, oceniać ich wiarygodność oraz zrozumieć mechanizmy działania platform technologicznych. Edukacja medialna ma potencjał nie tylko wspierać rozwój kompetencji cyfrowych, ale również przeciwdziałać zagrożeniom, takim jak dezinformacja, cyberprzemoc czy uzależnienie od technologii (Bulger & Davison, 2018).

Głównym celem edukacji medialnej jest rozwijanie u młodzieży zdolności do krytycznej analizy treści cyfrowych. W erze dezinformacji i fałszywych wiadomości (fake news) młodzi ludzie są narażeni na niezweryfikowane informacje, które mogą wpływać na ich



postawy, decyzje oraz zdrowie psychiczne. Według badań, wiele osób w młodym wieku ma trudności z rozpoznawaniem wiarygodnych źródeł informacji oraz odróżnianiem faktów od opinii (McGrew et al., 2018). Współczesne badania sugerują, że wykorzystanie nowoczesnych narzędzi sztucznej inteligencji w edukacji może wspierać rozwój kreatywności i umiejętności krytycznego myślenia (CEJSH, 2024). Szkoły powinny nie tylko uczyć rozpoznawania fałszywych informacji, ale także kształcić umiejętności ich analizy i oceny w dynamicznie zmieniającym się świecie cyfrowym. Wprowadzenie programów edukacji medialnej w szkołach może pomóc uczniom w rozwijaniu umiejętności oceny treści, takich jak sprawdzanie źródeł, analiza intencji nadawcy.

Nauczanie krytycznego podejścia do mediów jest szczególnie istotne w środowisku mediów społecznościowych, które często promują treści o wysokim potencjale angażującym, ale niskiej wartości merytorycznej. Młodzież uczona, jak zrozumieć algorytmy stojące za wyświetlaniem treści oraz jak unikać pułapek w postaci teorii spiskowych czy manipulacji informacyjnej, może skuteczniej poruszać się w przestrzeni cyfrowej (Livingstone & Sefton-Green, 2016).

Edukacja medialna odgrywa również kluczową rolę w promowaniu bezpiecznego korzystania z technologii. Młodzież, która jest świadoma zagrożeń w Internecie, takich jak cyberprzemoc, oszustwa internetowe czy niewłaściwe wykorzystywanie danych osobowych, jest lepiej przygotowana do unikania tych problemów. Programy edukacji medialnej mogą uczyć młodych ludzi, jak chronić swoją prywatność online, rozpoznawać ryzykowne sytuacje oraz reagować na nie w sposób odpowiedni (Livingstone et al., 2017).

Bezpieczne korzystanie z technologii obejmuje również edukację w zakresie zdrowych nawyków cyfrowych. Młodzież powinna być świadoma, jak nadmierne korzystanie z urządzeń może wpływać na ich zdrowie fizyczne, psychiczne oraz społeczne. Edukacja medialna może promować równowagę między czasem spędzonym online i offline, ucząc młodych ludzi zarządzania czasem ekranowym oraz wartości regularnych przerw od technologii (Hale & Guan, 2015).

Główną charakterystyką edukacji medialnej jest rozwijanie u młodzieży umiejętności efektywnego korzystania z technologii. Współczesny rynek pracy coraz bardziej ceni kompetencje cyfrowe, takie jak umiejętność wyszukiwania informacji, korzystanie z narzędzi do pracy zespołowej online czy tworzenie treści multimedialnych. Programy edukacyjne w szkołach mogą wspierać młodych ludzi w rozwijaniu tych umiejętności, przygotowując ich do wyzwań zawodowych przyszłości. Kompetencje cyfrowe stały się czynnikiem nowoczesnej



edukacji i przygotowania młodzieży do przyszłego rynku pracy. Raport OECD (2023) podkreśla, że edukacja cyfrowa powinna być komponentem programów szkolnych, aby przygotować młodzież na wyzwania związane z automatyzacją i rozwojem sztucznej inteligencji. World Economic Forum w "The Future of Jobs Report 2025" wskazuje na rosnące znaczenie umiejętności cyfrowych, zwłaszcza w kontekście transformacji rynku pracy i wzrostu znaczenia sztucznej inteligencji.

Efektywne korzystanie z technologii obejmuje również naukę korzystania z narzędzi wspierających naukę, takich jak aplikacje edukacyjne, kursy online czy platformy e-learningowe. Młodzież powinna być zachęcana do korzystania z technologii w sposób, który wspiera ich rozwój osobisty i edukacyjny, a nie tylko do celów rozrywkowych (Selwyn, 2016).

Wdrażanie edukacji medialnej w szkołach wymaga współpracy nauczycieli, rodziców oraz decydentów politycznych. Kluczowe jest, aby nauczyciele byli odpowiednio przygotowani do prowadzenia zajęć z zakresu edukacji medialnej, co oznacza konieczność zapewnienia im szkoleń oraz materiałów dydaktycznych. Ponadto, edukacja medialna powinna być włączona do programów nauczania w sposób systemowy, a nie jedynie jako dodatkowe zajęcia (Bulger & Davison, 2018).

Przykłady krajów, które z powodzeniem wprowadziły edukację medialną, takie jak Finlandia czy Estonia, pokazują, że takie działania mogą znacząco wpłynąć na poziom kompetencji cyfrowych w społeczeństwie. Młodzież w tych krajach osiąga wysokie wyniki w testach mierzących umiejętności krytycznego myślenia i rozwiązywania problemów w środowisku cyfrowym (OECD, 2019).

## **Wyzwania i perspektywy**

### **Nierówności społeczne**

Dostęp do technologii oraz umiejętność jej wykorzystania stają się czynnikami kształtującymi społeczne, edukacyjne i zawodowe szanse jednostek w cyfrowym społeczeństwie. Mimo dynamicznego rozwoju technologii, nierówny dostęp do niej, znany jako cyfrowa przepaść (digital divide), może prowadzić do pogłębiania istniejących nierówności społecznych. Problemy te obejmują zarówno różnice w dostępie do sprzętu i Internetu, jak i brak odpowiednich umiejętności cyfrowych, które są niezbędne do pełnego uczestnictwa w nowoczesnym społeczeństwie (van Deursen & van Dijk, 2019).



Cyfrowa przepaść może być rozpatrywana na kilku poziomach. Pierwszym z nich jest dostęp fizyczny, czyli możliwość korzystania z urządzeń cyfrowych oraz infrastruktury internetowej. W krajach rozwijających się brak dostępu do Internetu i technologii jest powszechny, co ogranicza możliwości edukacyjne i zawodowe dla dużych grup społecznych. Nawet w krajach rozwiniętych dostęp do szybkiego Internetu i nowoczesnych urządzeń może być nierówny, zwłaszcza w regionach wiejskich i wśród osób o niższym statusie ekonomicznym (OECD, 2019).

Drugim poziomem jest dostęp materialny, który obejmuje koszty związane z zakupem urządzeń i opłatami za usługi internetowe. Rodziny o niskich dochodach często muszą wybierać między podstawowymi potrzebami a inwestycją w technologię, co prowadzi do ograniczeń w dostępie do nowoczesnych narzędzi edukacyjnych i komunikacyjnych (Hargittai, 2010).

Trzeci poziom dotyczy różnic w umiejętnościach cyfrowych, zwanych także drugim poziomem cyfrowej przepaści. Nawet jeśli dostęp do technologii jest zapewniony, brak kompetencji cyfrowych może uniemożliwić efektywne korzystanie z jej potencjału. Osoby o niższym poziomie wykształcenia lub starsze mają często trudności z nawigowaniem w środowisku cyfrowym, co ogranicza ich szanse na rynku pracy oraz w dostępie do usług online (van Deursen & van Dijk, 2019).

Brak dostępu do technologii oraz umiejętności jej wykorzystania ma szczególnie negatywny wpływ na edukację dzieci i młodzieży. Podczas pandemii COVID-19, kiedy nauka zdalna stała się koniecznością, różnice w dostępie do sprzętu komputerowego i Internetu spowodowały, że wiele dzieci nie miało możliwości uczestniczenia w zajęciach online. Badania poświadczają, że uczniowie z rodzin o niskich dochodach osiągnęli gorsze wyniki edukacyjne w porównaniu z rówieśnikami z lepszym dostępem do technologii, co pogłębiło istniejące nierówności edukacyjne (Di Pietro et al., 2020).

Na rynku pracy brak kompetencji cyfrowych stanowi poważną barierę w zdobywaniu zatrudnienia w sektorach wymagających umiejętności technologicznych. Pracownicy, którzy nie są biegli w obsłudze komputerów czy oprogramowania, są bardziej narażeni na marginalizację oraz trudności w dostosowaniu się do wymagań nowoczesnych miejsc pracy (Selwyn, 2016). W miarę postępującej automatyzacji i cyfryzacji gospodarki różnice te mogą się pogłębiać, prowadząc do wykluczenia społecznego osób niezdolnych do adaptacji.



Aby przeciwdziałać cyfrowej przepaści, konieczne są działania na kilku poziomach. Po pierwsze, inwestycje w infrastrukturę internetową, zwłaszcza na obszarach wiejskich i słabiej rozwiniętych, są kluczowe dla zapewnienia dostępu fizycznego do technologii. Programy rządowe i inicjatywy międzynarodowe, takie jak dostarczanie taniego sprzętu komputerowego oraz bezpłatnego Internetu, mogą znacząco przyczynić się do zmniejszenia nierówności (World Bank, 2021).

Po drugie, należy promować edukację cyfrową, która zapewni wszystkim obywatelom, niezależnie od wieku czy statusu społecznego, możliwość rozwijania kompetencji cyfrowych. Szkoły powinny odgrywać kluczową rolę w nauczaniu umiejętności technologicznych, a nauczyciele powinni być odpowiednio przygotowani do prowadzenia zajęć z tego zakresu (Livingstone & Helsper, 2007). Programy szkoleniowe dla dorosłych, zwłaszcza osób starszych, mogą również wspierać walkę z cyfrowym wykluczeniem.

Wreszcie, polityki społeczne powinny skupiać się na zmniejszaniu kosztów dostępu do technologii, poprzez subsydiowanie sprzętu i usług internetowych dla rodzin o niskich dochodach. Wspieranie inicjatyw non-profit, takich jak biblioteki cyfrowe czy centra edukacyjne, może również zwiększyć dostępność technologii dla osób z mniej uprzywilejowanych środowisk.

Dostęp do technologii i umiejętność jej wykorzystania są podłożem zapewniania równych szans w społeczeństwie cyfrowym. Cyfrowa przepaść, obejmująca różnice w dostępie fizycznym, materialnym i umiejętnościach, może prowadzić do pogłębiania nierówności społecznych, edukacyjnych i zawodowych. Aby przeciwdziałać temu zjawisku, konieczne są zintegrowane działania na rzecz poprawy infrastruktury, edukacji cyfrowej oraz redukcji kosztów technologii. Tylko w ten sposób możliwe będzie budowanie bardziej równego i inkluzywnego społeczeństwa.

### **Balans między technologią a bezpośrednimi interakcjami**

Kluczowym wyzwaniem współczesnego społeczeństwa jest znalezienie równowagi między korzystaniem z technologii a bezpośrednimi interakcjami społecznymi, które odgrywają fundamentalną rolę w rozwoju emocjonalnym i społecznym młodzieży. W erze cyfrowej technologia stała się nieodłącznym elementem codziennego życia, oferując młodzieży liczne korzyści, takie jak łatwy dostęp do informacji, możliwość komunikacji z rówieśnikami i rozwój kompetencji cyfrowych. Jednak nadmierne korzystanie z technologii, w szczególności



mediów społecznościowych i komunikatorów internetowych, może negatywnie wpływać na zdolność młodych ludzi do nawiązywania i utrzymywania głębokich, bezpośrednich relacji międzyludzkich (Turkle, 2015).

Bezpośrednie interakcje społeczne, takie jak rozmowy twarzą w twarz, są kluczowe dla rozwoju umiejętności interpersonalnych, empatii oraz zdolności do rozwiązywania konfliktów. Technologia, choć ułatwia komunikację, często zastępuje tradycyjne formy kontaktu, co może prowadzić do tzw. „płytkiej komunikacji” (shallow communication). Badania podkreślają, że młodzież, która spędza więcej czasu na interakcjach online niż offline, może doświadczać trudności w rozumieniu niewerbalnych sygnałów społecznych, takich jak mimika twarzy czy ton głosu (Kirkpatrick, 2016). Tego rodzaju ograniczenia mogą wpływać na zdolność do budowania głębokich relacji oraz rozwijania więzi opartych na wzajemnym zaufaniu.

Bezpośrednie interakcje społeczne są niezbędne dla zdrowego rozwoju emocjonalnego i społecznego młodzieży. Spotkania twarzą w twarz umożliwiają młodym ludziom doświadczanie autentycznych emocji, takich jak radość, smutek czy empatia, które są trudne do pełnego odzwierciedlenia w komunikacji cyfrowej. Badania informują, że dzieci i młodzież, którzy regularnie uczestniczą w bezpośrednich interakcjach społecznych, wykazują wyższy poziom kompetencji społecznych, lepsze zdolności komunikacyjne oraz większe poczucie przynależności (Livingstone & Sefton-Green, 2016).

Bezpośrednie kontakty społeczne odgrywają również kluczową rolę w kształtowaniu umiejętności emocjonalnych, takich jak regulacja emocji i radzenie sobie ze stresem. Spotkania w świecie rzeczywistym pozwalają młodym ludziom na naukę rozwiązywania konfliktów oraz budowanie trwałych relacji, które stanowią podstawę zdrowego rozwoju społecznego (Turkle, 2015).

Nadmierne korzystanie z technologii, zwłaszcza mediów społecznościowych, może prowadzić do izolacji społecznej, poczucia samotności oraz obniżenia jakości relacji międzyludzkich. Zjawisko tzw. „phubbingu” (ignorowania innych osób na rzecz telefonu) stało się przykładem, jak technologia może zakłócać interakcje społeczne. Badania sugerują, że młodzież, która spędza zbyt dużo czasu na korzystaniu z technologii, często doświadcza obniżenia jakości relacji rodzinnych oraz przyjacielskich (Przybylski & Weinstein, 2017).

Ponadto młodzież, która nadmiernie korzysta z technologii, może odczuwać trudności w radzeniu sobie z presją społeczną, wynikającą z konieczności bycia stale dostępnym online.



Lęk przed przegapieniem ważnych wydarzeń (FOMO – fear of missing out) prowadzi do ciągłego sprawdzania powiadomień, co negatywnie przekłada się na koncentrację oraz zdolność do bycia obecnym w interakcjach offline (Elhai et al., 2018).

Aby przeciwdziałać negatywnym skutkom nadmiernego korzystania z technologii, kluczowe jest promowanie równowagi między czasem spędzonym online i offline. Rodzice, nauczyciele oraz decydenci polityczni odgrywają kluczową rolę w edukowaniu młodzieży na temat zdrowych nawyków cyfrowych oraz znaczenia bezpośrednich interakcji społecznych. Wprowadzenie „cyfrowych godzin policyjnych”, ograniczenie czasu spędzanego przed ekranem oraz organizowanie zajęć promujących interakcje offline, takich jak sport czy wolontariat, może pomóc młodym ludziom w rozwijaniu umiejętności społecznych (Cain & Gradisar, 2010).

Szkoły mogą również odgrywać istotną rolę w kształtowaniu zdrowych nawyków, wprowadzając programy edukacyjne, które podkreślają znaczenie bezpośrednich interakcji społecznych oraz uczą młodzież, jak świadomie korzystać z technologii. Promowanie inicjatyw, takich jak dni bez technologii czy zajęcia wspierające rozwój empatii, może wspierać młodych ludzi w budowaniu trwałych i autentycznych relacji (Livingstone & Byrne, 2018).

Znalezienie równowagi między korzystaniem z technologii a bezpośrednimi interakcjami społecznymi jest priorytetowe dla zdrowego rozwoju młodzieży w erze cyfrowej. Bezpośrednie kontakty społeczne są niezastąpione w kształtowaniu umiejętności interpersonalnych, emocjonalnych oraz społecznych, które stanowią fundament zdrowego funkcjonowania w dorosłym życiu. Wspieranie młodzieży w rozwijaniu zdrowych nawyków cyfrowych oraz promowanie wartościowych interakcji offline jest zadaniem rodziców, nauczycieli oraz całego społeczeństwa.

### **2.3. Wybrane teorie psychologiczne związane z uczeniem się i rozwojem**

Uczenie się i rozwój są procesami w życiu człowieka, a ich zrozumienie jest niezbędne w edukacji, psychologii oraz wielu innych dziedzinach. Istnieje wiele teorii psychologicznych, które starają się wyjaśnić, jak ludzie uczą się nowych umiejętności, przyswajają wiedzę oraz jak kształtują się ich zdolności poznawcze, emocjonalne i społeczne. W tym rozdziale przedstawiono kilka wybranych teorii psychologicznych związanych z uczeniem się i rozwojem, które odegrały kluczową rolę w zrozumieniu tych procesów.



### 2.3.1 Teoria behawioralna

Teoria behawioralna, zapoczątkowana przez badaczy takich jak Ivan Pawłow, John Watson i B.F. Skinner, odegrała kluczową rolę w zrozumieniu mechanizmów uczenia się. Koncentruje się na obserwowalnych zachowaniach oraz procesach warunkowania, które prowadzą do zmian w zachowaniu organizmów. Ta perspektywa teoretyczna wywarła istotny wpływ na rozwój psychologii jako nauki, zwłaszcza w XX wieku, i znajduje szerokie zastosowanie w edukacji, terapii oraz innych dziedzinach.

Ivan Pawłow, rosyjski fizjolog, zapoczątkował teorię behawioralną poprzez swoje badania nad warunkowaniem klasycznym. W swoim eksperymencie z psami wykazał, że organizmy uczą się asocjacji między bodźcami, co prowadzi do wystąpienia określonych reakcji. Pawłow (1927) zaobserwował, że psy zaczynają ślinić się w odpowiedzi na bodźce, które pierwotnie były neutralne, takie jak dźwięk dzwonka, jeśli te bodźce były regularnie kojarzone z jedzeniem. Mechanizm ten opisał jako warunkowanie klasyczne, w którym neutralny bodziec (np. dźwięk dzwonka) staje się bodźcem warunkowym wywołującym reakcję warunkową (ślinienie).

Warunkowanie klasyczne znajduje zastosowanie w wielu dziedzinach, w tym w terapii behawioralnej i psychologii zdrowia. Na przykład techniki oparte na tej teorii, takie jak systematyczna desensytyzacja, są wykorzystywane w leczeniu fobii. Pacjenci stopniowo uczą się zmniejszać reakcję lękową na bodźce wywołujące strach poprzez zastąpienie reakcji lękowej reakcją relaksacyjną (Wolpe, 1958).

B.F. Skinner, amerykański psycholog, poszerzył teorię behawioralną, wprowadzając pojęcie warunkowania operacyjnego (instrumentalnego). W przeciwieństwie do warunkowania klasycznego, które koncentruje się na reakcjach wywoływanych przez bodźce, warunkowanie operacyjne zajmuje się wpływem konsekwencji na zachowanie. Skinner (1953) wykazał, że zachowanie organizmów może być wzmacniane lub osłabiane w zależności od tego, czy jest nagradzane czy karane. Wprowadził także pojęcia wzmocnienia pozytywnego (np. nagrody) oraz wzmocnienia negatywnego (np. unikanie kary).

Przykładem zastosowania tej teorii jest użycie "skrzynki Skinnera" w eksperymentach, gdzie zwierzęta, takie jak szczury czy gołębie, uczyły się wykonywać określone czynności (np. naciskanie dźwigni) w zamian za nagrodę, taką jak jedzenie. Badania te podkreślają znaczenie regularnych i odpowiednio dobranych wzmocnień w procesie uczenia się.



Teoria behawioralna znalazła szerokie zastosowanie w edukacji, zwłaszcza w procesach nauczania i zarządzania klasą. Nauczyciele mogą stosować techniki oparte na wzmocnieniu pozytywnym, aby zachęcać uczniów do pożądaných zachowań. Na przykład przyznawanie pochwał, naklejek czy punktów za poprawne odpowiedzi lub osiągnięcia akademickie może zwiększyć motywację uczniów do nauki. Skinner (1953) podkreślał, że nagradzanie poprawnych odpowiedzi i działań jest bardziej skuteczne niż karanie za błędy, ponieważ wzmocnia pozytywne zachowania.

Współczesne systemy zarządzania klasą, takie jak systemy tokenowe, również opierają się na zasadach warunkowania operacyjnego. Uczniowie zdobywają tokeny za określone zachowania, które następnie mogą wymieniać na nagrody. Systemy te pomagają nauczycielom utrzymać dyscyplinę w klasie oraz wspierają rozwój nawyków, takich jak punktualność, uprzejmość czy odpowiedzialność.

Chociaż teoria behawioralna odegrała kluczową rolę w zrozumieniu procesów uczenia się, jest również przedmiotem krytyki. Jej przeciwnicy wskazują, że skupia się ona wyłącznie na obserwowalnych zachowaniach, pomijając wewnętrzne procesy poznawcze, takie jak myślenie, emocje czy motywacje (Bandura, 1977). W odpowiedzi na te ograniczenia rozwinięto podejścia integrujące behawioryzm z teorią poznawczą, takie jak teoria społecznego uczenia się Alberta Bandury. Bandura wprowadził pojęcie modelowania, wskazując, że ludzie uczą się poprzez obserwację innych, a nie tylko przez bezpośrednie doświadczenie konsekwencji swoich działań.

Teoria behawioralna wniosła istotny wkład w zrozumienie mechanizmów uczenia się oraz w rozwój praktycznych narzędzi stosowanych w edukacji i terapii. Badania Pawłowa nad warunkowaniem klasycznym oraz Skinnera nad warunkowaniem operacyjnym dostarczyły podstawowych zasad, które są nadal wykorzystywane w różnych dziedzinach. Pomimo krytyki, teoria ta pozostaje elementem psychologii, a jej połączenie z innymi podejściami pozwala na bardziej kompleksowe zrozumienie zachowań ludzkich.

### **2.3.2 Teoria społecznego uczenia się Alberta Bandury**

Teoria społecznego uczenia się Alberta Bandury stanowi jedno z najważniejszych osiągnięć w psychologii rozwojowej i poznawczej. Bandura wprowadził tę teorię w latach 60. XX wieku, podkreślając, że ludzie uczą się nie tylko poprzez bezpośrednie doświadczenie i konsekwencje swoich działań, ale także poprzez obserwację innych osób, modelowanie ich



zachowań oraz analizę konsekwencji, jakie te zachowania przynoszą (Bandura, 1977). Kluczowym elementem tej teorii jest rola procesów poznawczych, które umożliwiają jednostkom obserwowanie, przetwarzanie i naśladowanie zachowań społecznych, a także podejmowanie decyzji o ich adaptacji w zależności od sytuacji.

Bandura podkreślał, że proces uczenia się w podejściu społecznym nie jest bierny, lecz wymaga aktywnego udziału jednostki. Uczenie się zachodzi w wyniku interakcji trzech składowych: jednostki, jej środowiska oraz zachowania. Ten wzajemny wpływ jest określany jako „determinacja wzajemna” (reciprocal determinism) (Bandura, 1986).

Podstawowymi założeniami teorii są Uczenie się przez obserwację: Ludzie uczą się, obserwując zachowania innych, a także analizując ich konsekwencje. Obserwacja może prowadzić do naśladowania, jeśli model jest postrzegany jako atrakcyjny, kompetentny lub podobny do obserwatora. Modelowanie: Zachowania innych osób (modele) dostarczają jednostkom wzorców, które mogą być naśladowane. Modele te mogą być rzeczywiste (np. rodzice, nauczyciele, rówieśnicy) lub symboliczne (np. postacie z mediów). Wzmocnienia pośrednie: Jednostka nie musi bezpośrednio doświadczyć nagrody lub kary, aby się uczyć. Obserwowanie konsekwencji, jakie spotykają innych, jest przyczyną decyzji podejmowanych przez obserwatora. Samoregulacja: Ludzie nie tylko reagują na bodźce zewnętrzne, ale także stosują procesy samoregulacji, takie jak wyznaczanie celów, samoocena oraz podejmowanie działań na podstawie własnych standardów i wartości.

Najbardziej znany eksperyment Bandury to badanie z użyciem lalki Bobo, które miało na celu zrozumienie, jak dzieci uczą się agresywnych zachowań poprzez obserwację. W badaniu tym dzieci obserwowały dorosłego, który w różny sposób zachowywał się wobec lalki: agresywnie (uderzając lalkę i używając wulgarnych słów), neutralnie lub ignorując lalkę. Wyniki pokazały, że dzieci, które były świadkami agresywnych zachowań modelu, częściej powtarzały podobne zachowania niż te, które nie widziały takich działań (Bandura, Ross, & Ross, 1961). Eksperyment ten potwierdził, że obserwacja może prowadzić do uczenia się nowych zachowań, nawet bez bezpośredniego wzmocnienia.

Teoria społecznego uczenia się odróżnia się od tradycyjnego behawioryzmu poprzez uwzględnienie procesów poznawczych. Bandura podkreślał, że ludzie nie naśladowują automatycznie każdego zachowania, które zaobserwują. Kluczowe znaczenie mają procesy takie jak uwaga (czy jednostka zwróci uwagę na dane zachowanie), retencja (czy potrafi zapamiętać obserwowane zachowanie), reprodukcja (czy jest w stanie fizycznie lub mentalnie

odtworzyć to zachowanie) oraz motywacja (czy istnieje chęć podjęcia takiego działania) (Bandura, 1986).

Teoria Bandury znalazła szerokie zastosowanie w wielu dziedzinach, takich jak edukacja, psychoterapia, media, oraz zapobieganie zachowaniom ryzykownym.

- Edukacja: W środowisku szkolnym nauczyciele pełnią rolę modeli, których zachowania mogą być naśladowane przez uczniów. Bandura podkreślał znaczenie pozytywnych modeli w nauczaniu oraz rozwijaniu motywacji uczniów. Na przykład nauczyciele, którzy wykazują pasję do nauczania i empatię wobec uczniów, wpływają na ich podejście do nauki i rozwój umiejętności społecznych.
- Terapia behawioralna: W psychoterapii teoria społecznego uczenia się jest wykorzystywana w pracy z pacjentami, którzy uczą się nowych sposobów radzenia sobie z problemami poprzez obserwację i modelowanie zachowań terapeuty (Kazdin, 2013).
- Media: Media są potężnym źródłem modeli dla młodzieży. Badania sygnalizują, że treści medialne mogą zarówno promować pozytywne wzorce, takie jak zdrowy styl życia, jak i wzmocnić negatywne zachowania, takie jak agresja lub niezdrowe nawyki.

Współczesne badania nad teorią społecznego uczenia się podkreślają znaczenie technologii oraz mediów cyfrowych jako źródeł modelowania. Internet, media społecznościowe oraz gry komputerowe stały się głównymi środowiskami, w których młodzi ludzie uczą się poprzez obserwację (Livingstone et al., 2018). Ponadto teoria ta została rozwinięta w kierunku poznawczo-behawioralnym, co pozwala na łączenie jej założeń z bardziej kompleksowym podejściem do procesów uczenia się.

Teoria społecznego uczenia się Alberta Bandury dostarcza cennych narzędzi do zrozumienia, w jaki sposób ludzie uczą się poprzez obserwację i interakcję społeczną. Jej znaczenie wykracza poza tradycyjną psychologię behawioralną, włączając procesy poznawcze oraz motywacyjne. Dzięki szerokiemu zastosowaniu w edukacji, terapii i mediach, teoria ta pozostaje fundamentem współczesnej psychologii społecznej i poznawczej.

### 2.3.3 Teoria poznawcza Jeana Piageta

Jean Piaget opracował jedną z najbardziej wpływowych teorii rozwoju poznawczego, która stanowi fundament współczesnej psychologii rozwojowej i pedagogiki. Jego badania



koncentrowały się na zrozumieniu, w jaki sposób dzieci rozwijają zdolności poznawcze w interakcji z otoczeniem. Piaget wyróżnił cztery etapy rozwoju poznawczego: sensoryczno-motoryczny, przedoperacyjny, operacji konkretnych oraz operacji formalnych (Piaget, 1952). Każdy z tych etapów charakteryzuje się specyficznymi zdolnościami poznawczymi oraz ograniczeniami, które stopniowo ustępują w miarę dojrzewania dziecka.

Piaget podkreślał, że rozwój poznawczy jest procesem aktywnym, w którym dziecko nie tylko przyswaja informacje, ale również konstruuje własne rozumienie świata poprzez interakcje z otoczeniem. Dwa kluczowe mechanizmy tego procesu to **Asymilacja** będąca integracją nowych informacji z istniejącymi schematami poznawczymi. Na przykład dziecko, które zna pojęcie psa, może początkowo uważać kota za psa, ponieważ oba są czworonożnymi zwierzętami oraz **Akomodacja** czyli dostosowanie istniejących schematów poznawczych do nowych informacji. W tym przypadku dziecko uczy się, że kot różni się od psa i tworzy nowy schemat dla kota. Proces ten jest dynamiczny i odbywa się w sposób ciągły, co pozwala dziecku na coraz bardziej precyzyjne rozumienie świata.

Teoria Piageta miała ogromny wpływ na pedagogikę, szczególnie dostosowywania programów nauczania do różnych etapów rozwoju poznawczego dziecka. Wnioskiem wynikającym z jego teorii jest potrzeba uwzględnienia zdolności poznawczych uczniów przy projektowaniu lekcji. Na przykład:

- W wieku przedszkolnym (etap przedoperacyjny) dzieci mogą korzystać z materiałów wizualnych i manipulacyjnych, które wspierają myślenie symboliczne.
- W szkole podstawowej (etap operacji konkretnych) nauczanie powinno uwzględniać eksperymenty i działania praktyczne, które pomagają dzieciom zrozumieć zasady logiki.
- W szkołach średnich (etap operacji formalnych) uczniowie mogą być angażowani w dyskusje na temat problemów abstrakcyjnych, takich jak kwestie etyczne czy naukowe.

Piaget podkreślał również znaczenie eksploracji i samodzielnego rozwiązywania problemów przez dzieci. Nauczyciele powinni stymulować uczniów do aktywnego odkrywania wiedzy, a nie jedynie przekazywać gotowe informacje.



Choć teoria Piageta była przełomowa, nie jest pozbawiona krytyki. Badacze wskazują, że rozwój poznawczy dzieci może być bardziej zróżnicowany, niż sugeruje Piaget, a etapy rozwoju mogą nakładać się na siebie. Inni badacze, tacy jak Lev Vygotsky, podkreślali rolę społecznych i kulturowych kontekstów w rozwoju poznawczym, co zostało mniej uwzględnione w teorii Piageta (Vygotsky, 1978).

Wg teorii Piageta rozwój poznawczy dziecka przechodzi przez kolejne etapy, w tym fazę operacji konkretnych oraz operacji formalnych. Systemy AI, takie jak chatboty edukacyjne i aplikacje wspierające naukę, mogą przyspieszać przechodzenie między tymi etapami, dostarczając dostosowane do wieku treści edukacyjne. Jak wskazano w rozdziale 1.2, algorytmy uczenia maszynowego personalizują doświadczenie edukacyjne, co może mieć istotne konsekwencje dla procesów uczenia się.

Teoria rozwoju poznawczego Jeana Piageta dostarcza fundamentalnego zrozumienia mechanizmów uczenia się i rozwoju dzieci. Jego podział na etapy oraz koncepcje asymilacji i akomodacji stanowią podstawę dla wielu współczesnych badań w psychologii i pedagogice. Mimo pewnych ograniczeń, teoria Piageta pozostaje niezwykle istotna dla praktyki edukacyjnej i pomaga nauczycielom lepiej dostosować metody nauczania do potrzeb uczniów na różnych etapach ich rozwoju.

### 2.3.4 Socjokulturowa teoria Lwa Wygotskiego

Lew Wygotski, jeden z najbardziej wpływowych psychologów XX wieku, opracował teorię socjokulturową, która podkreśla rolę społecznych i kulturowych kontekstów w procesach rozwoju i uczenia się. Wygotski twierdził, że uczenie się jest nieodłącznie związane z interakcjami społecznymi oraz kulturą, w której jednostka żyje. Jego teoria zmieniła sposób, w jaki rozumie się procesy edukacyjne, wprowadzając nowe podejście do roli nauczyciela, rówieśników oraz dialogu w procesie uczenia się (Vygotsky, 1978).

Teoria Wygotskiego opiera się na założeniu, że rozwój poznawczy dziecka nie odbywa się w izolacji, ale w kontekście społecznym, w którym interakcje z innymi osobami odgrywają kluczową rolę. Wygotski uważał, że kultura kształtuje sposób myślenia, język oraz narzędzia poznawcze, które jednostka wykorzystuje w swoim codziennym życiu. Język, jako podstawowe narzędzie komunikacji, jest jednocześnie narzędziem myślenia w procesie uczenia się. W miarę



jak dziecko opanowuje język, jego zdolności poznawcze stają się bardziej złożone, co pozwala na bardziej abstrakcyjne myślenie i rozwiązywanie problemów.

Centralnym pojęciem w teorii Wygotskiego jest **internalizacja**, czyli proces, w którym dziecko przekształca zewnętrzne interakcje społeczne w wewnętrzne schematy poznawcze. Na przykład dziecko, które uczy się rozwiązywać zadanie matematyczne poprzez wspólne działanie z nauczycielem, z czasem nabywa zdolność do samodzielnego rozwiązywania podobnych problemów.

Znaną koncepcją Wygotskiego jest **strefa najbliższego rozwoju (ZPD)**. Strefa ta odnosi się do różnicy między tym, co dziecko jest w stanie zrobić samodzielnie, a tym, co może osiągnąć przy wsparciu bardziej doświadczonej osoby, takiej jak nauczyciel, rodzic lub rówieśnik. Wygotski argumentował, że uczenie się jest najbardziej efektywne, gdy odbywa się w ZPD, ponieważ tam dziecko napotyka wyzwania, które są dla niego osiągalne przy odpowiednim wsparciu (Vygotsky, 1978).

ZPD podkreśla znaczenie roli nauczyciela jako przewodnika w procesie uczenia się. Nauczyciel powinien dostarczać wsparcia adekwatnego do poziomu rozwoju ucznia, stopniowo zmniejszając pomoc w miarę, jak dziecko staje się bardziej kompetentne. Proces ten jest określany jako **scaffolding** (Bruner, 1985). Przykładem scaffolding może być nauczyciel pomagający uczniowi zrozumieć nowe pojęcie matematyczne poprzez wyjaśnienia, zadawanie pytań czy wspólne rozwiązywanie zadań, a następnie zachęcanie ucznia do samodzielnego rozwiązywania podobnych problemów.

W teorii Wygotskiego język pełni kluczową rolę jako narzędzie mediujące w procesach uczenia się. Wygotski podkreślał, że dialog między uczniem a nauczycielem lub rówieśnikiem jest istotnym elementem procesu edukacyjnego. Poprzez rozmowę dziecko nie tylko nabywa wiedzę, ale również uczy się myślenia logicznego, formułowania pytań oraz rozwiązywania problemów. Wspólne działania, takie jak omawianie problemu czy wspólne poszukiwanie rozwiązania, pozwalają na rozwój umiejętności poznawczych i społecznych.

Wygotski wyróżnił również znaczenie **mowy wewnętrznej**, która rozwija się z mowy społecznej. Mowa wewnętrzna, czyli myślenie werbalne, umożliwia dziecku planowanie działań, analizowanie sytuacji oraz podejmowanie decyzji. W miarę jak dziecko dorasta, mowa



wewnętrzna staje się coraz bardziej abstrakcyjna, co pozwala na bardziej złożone procesy poznawcze.

Teoria socjokulturowa Wygotskiego ma szerokie zastosowanie w praktyce edukacyjnej. Podkreśla ona znaczenie pracy zespołowej, współpracy oraz interakcji społecznych w procesie uczenia się. Zgodnie z tą teorią nauczyciele powinni tworzyć sytuacje edukacyjne, które angażują uczniów w dialog oraz wspólne rozwiązywanie problemów. Przykłady zastosowań teorii Wygotskiego w edukacji jest to **Nauczanie oparte na współpracy** - Uczniowie pracują w grupach, dzieląc się pomysłami i wspólnie rozwiązując zadania, co pozwala im uczyć się od siebie nawzajem. **Konstruktywne pytania nauczyciela** - Pytania, które prowokują do refleksji i zachęcają uczniów do wyciągania wniosków, wspierają rozwój myślenia krytycznego. **Użycie narzędzi kulturowych** - Technologie, takie jak komputery czy aplikacje edukacyjne, mogą być wykorzystywane jako narzędzia wspomagające rozwój poznawczy uczniów.

Choć teoria Wygotskiego miała ogromny wpływ na edukację, spotkała się również z krytyką. Niektórzy badacze wskazują, że teoria ta nie uwzględnia indywidualnych różnic w tempie rozwoju dzieci oraz ich zdolności do samodzielnego uczenia się. Mimo to teoria socjokulturowa stała się podstawą wielu współczesnych podejść edukacyjnych, takich jak nauczanie konstruktywistyczne oraz modele oparte na współpracy.

Teoria socjokulturowa Lwa Wygotskiego dostarcza cennych narzędzi do zrozumienia, jak rozwój poznawczy i uczenie się są kształtowane przez interakcje społeczne i kontekst kulturowy. Koncepcje takie jak strefa najbliższego rozwoju, scaffolding oraz rola języka mają kluczowe znaczenie dla praktyki edukacyjnej, pomagając nauczycielom skuteczniej wspierać rozwój uczniów. Dzięki swojemu interdyscyplinarnemu charakterowi teoria Wygotskiego pozostaje ważnym podejściem w psychologii rozwojowej i pedagogice.

### 2.3.5 Teoria konstruktywistyczna

Konstruktywizm, rozwijany przez takich badaczy jak Jean Piaget, Lew Wygotski i Jerome Bruner, jest istotnym podejściem w teorii uczenia się. Podstawowym założeniem konstruktywizmu jest to, że proces edukacyjny polega na aktywnym budowaniu wiedzy przez jednostkę, a nie na biernym przyswajaniu gotowych informacji przekazywanych przez nauczyciela. Wiedza powstaje w wyniku doświadczeń, interakcji z otoczeniem



oraz refleksji nad nimi (Bruner, 1966). Konstruktywizm podkreśla, że uczenie się jest procesem dynamicznym i indywidualnym, silnie związanym z kontekstem społecznym i kulturowym.

Jerome Bruner, jeden z głównych przedstawicieli konstruktywizmu, wprowadził koncepcję nauczania odkrywczego (discovery learning), która zakłada, że uczniowie powinni aktywnie uczestniczyć w procesie uczenia się poprzez eksplorację, eksperymentowanie i samodzielne formułowanie wniosków. Według Brunera uczenie się jest najbardziej efektywne, gdy uczniowie mają możliwość samodzielnego odkrywania wiedzy, co rozwija ich kreatywność, zdolności analityczne oraz motywację wewnętrzną. Nauczanie odkrywcze znajduje zastosowanie w wielu nowoczesnych metodach edukacyjnych, takich jak uczenie problemowe (problem-based learning, PBL) oraz edukacja STEM, obejmująca naukę, technologię, inżynierię i matematykę. Bruner podkreślał również znaczenie reprezentacji poznawczych, wskazując, że wiedza jest przyswajana i przechowywana w formie enaktycznej (opartej na działaniach), ikonicznej (opartej na obrazach) oraz symbolicznej (opartej na języku i abstrakcyjnych pojęciach). Efektywne nauczanie powinno uwzględniać te różnorodne formy reprezentacji, dostosowując metody dydaktyczne do etapu rozwoju poznawczego uczniów (Bruner, 1966).

Konstruktywizm znalazł szerokie zastosowanie w praktyce edukacyjnej, wprowadzając nowe podejście do procesu nauczania i roli nauczyciela. Ewentualność uczenia problemowego uczniowie są zaangażowani w rozwiązywanie realistycznych problemów, które wymagają zastosowania zdobytej wiedzy w nowym kontekście. Praca w grupach zadaniowych pozwala na rozwijanie zdolności krytycznego myślenia, współpracy oraz analizy informacji. Edukacja STEM, inspirowana zasadami konstruktywizmu, promuje interdyscyplinarne podejście do nauczania, które zachęca uczniów do stosowania zdobytej wiedzy w praktyce poprzez projekty badawcze czy eksperymenty. Ponadto konstruktywizm odegrał istotną rolę w rozwoju technologii edukacyjnych, takich jak symulatory, gry edukacyjne czy interaktywne platformy, które umożliwiają uczniom eksplorowanie i odkrywanie wiedzy w sposób angażujący i dostosowany do ich indywidualnych potrzeb.

W konstruktywistycznym podejściu rola nauczyciela znacząco różni się od tradycyjnych modeli edukacyjnych. Nauczyciel przestaje być wyłącznie dostarczycielem wiedzy, a staje się przewodnikiem i mentorem, który wspiera uczniów w ich procesie uczenia się. Zadaniem nauczyciela jest tworzenie środowiska sprzyjającego eksploracji oraz zadawanie pytań, które



prowołują uczniów do myślenia i samodzielnego poszukiwania odpowiedzi. Współpraca między uczniami, wspólne rozwiązywanie problemów oraz interakcje społeczne są istotnymi elementami procesu edukacyjnego, które wspierają rozwój zarówno poznawczy, jak i społeczny.

Mimo swoich licznych zalet konstruktywizm nie jest pozbawiony ograniczeń. Krytycy, tacy jak Kirschner, Sweller i Clark (2006), wskazują, że metody oparte na konstruktywizmie mogą być czasochłonne i wymagają od nauczycieli wysokich kompetencji w projektowaniu zajęć. Ponadto uczniowie z mniejszymi zasobami poznawczymi lub ograniczoną motywacją mogą mieć trudności z samodzielnym odkrywaniem wiedzy. Pomimo tych wyzwań konstruktywizm pozostaje najważniejszym z kierunków w edukacji współczesnej, oferując podejście, które promuje aktywność, kreatywność oraz zdolność do samodzielnego rozwiązywania problemów.

Konstruktywizm, rozwijany przez Piageta, Wygotskiego i Brunera, wniósł fundamentalne zmiany w rozumieniu procesów uczenia się i nauczania. Jego założenia o aktywnym charakterze uczenia się oraz roli kontekstu społecznego i kulturowego w kształtowaniu wiedzy zainspirowały rozwój wielu nowoczesnych metod dydaktycznych. Podejście to, choć wymagające, oferuje ogromny potencjał w rozwijaniu umiejętności poznawczych, społecznych i emocjonalnych uczniów, co czyni je niezwykle wartościowym w praktyce edukacyjnej.

Teorie psychologiczne związane z uczeniem się i rozwojem dostarczają cennych wskazówek dla zrozumienia, jak ludzie przyswajają wiedzę i kształtują swoje umiejętności na różnych etapach życia. Od podejścia behawioralnego, przez poznawcze i socjokulturowe, aż po konstruktywizm, każda z tych teorii wnosi unikalne perspektywy, które znajdują zastosowanie w edukacji, psychoterapii oraz rozwoju zawodowym. Zrozumienie tych teorii pozwala na projektowanie skuteczniejszych metod nauczania i wsparcia, które odpowiadają na potrzeby uczniów i wspierają ich harmonijny rozwój.



### Rozdział 3. Wpływ sztucznej inteligencji na edukację i procesy uczenia się

W poprzednich rozdziałach omówiono kluczowe technologie związane z AI, w tym uczenie maszynowe, sieci neuronowe oraz przetwarzanie języka naturalnego oraz etapy rozwoju dzieci i młodzieży. Warto jednak zastanowić się, w jaki sposób te narzędzia kształtują rozwój dzieci i młodzieży, zarówno w edukacji, jak i zdrowia psychicznego. Niniejszy rozdział analizuje pozytywne i negatywne skutki interakcji młodych ludzi ze sztuczną inteligencją.

Sztuczna inteligencja (AI) staje się ważnym elementem współczesnej transformacji technologicznej, zmieniając nie tylko sposób, w jaki funkcjonują społeczeństwa, ale także sposób, w jaki uczymy się i nauczamy. W kontekście edukacji AI jest wykorzystywana do personalizacji nauczania, automatyzacji procesów administracyjnych, wspierania pracy nauczycieli oraz tworzenia nowych form interakcji i zdobywania wiedzy. W miarę jak technologie popierane przez AI, takie jak systemy rekomendacyjne, chatboty edukacyjne czy platformy e-learningowe, stają się coraz bardziej zaawansowane, zmieniają się również oczekiwania wobec systemów edukacyjnych oraz rola uczniów i nauczycieli w procesie uczenia się.

Sztuczna inteligencja oferuje wyjątkowe możliwości personalizacji edukacji, umożliwiając dostosowanie materiałów dydaktycznych, tempa nauczania oraz metod nauczania do indywidualnych potrzeb i stylów uczenia się uczniów. Na przykład systemy adaptacyjnego nauczania, takie jak Smart Sparrow czy DreamBox, wykorzystują algorytmy AI do analizowania postępów uczniów i dostosowywania treści edukacyjnych w czasie rzeczywistym. Dzięki temu uczniowie mogą uczyć się w sposób bardziej efektywny, a nauczyciele zyskują narzędzia wspierające identyfikację obszarów, które wymagają większej uwagi (Luckin et al., 2016). Personalizacja nauczania nie tylko poprawia wyniki edukacyjne, ale również zwiększa zaangażowanie uczniów, co jest wiodące we współczesnych wyzwaniach edukacyjnych, takich jak spadek motywacji do nauki czy rosnąca różnorodność potrzeb uczniów.

AI wpływa również na automatyzację procesów administracyjnych, odciążając nauczycieli i administratorów od rutynowych zadań. Systemy oparte na sztucznej inteligencji są wykorzystywane do oceniania prac pisemnych, śledzenia postępów uczniów czy zarządzania harmonogramami zajęć. Automatyzacja tych procesów pozwala nauczycielom skupić



się na bardziej kreatywnych i interaktywnych funkcjach nauczania, co sprzyja tworzeniu bardziej angażujących i efektywnych środowisk edukacyjnych (Holmes et al., 2019). Ponadto technologie takie jak chatboty edukacyjne, które wykorzystują przetwarzanie języka naturalnego, umożliwiają szybkie udzielanie odpowiedzi na pytania uczniów, oferując wsparcie w nauce w czasie rzeczywistym. Takie rozwiązania stają się szczególnie cenne w sytuacjach, gdy nauczyciel nie jest dostępny, co zwiększa dostępność i elastyczność edukacji.

Częścią bardziej obiecujących obszarów zastosowania AI w edukacji jest rozwój wirtualnych i rozszerzonych środowisk rzeczywistości (VR/AR), które pozwalają na tworzenie immersyjnych doświadczeń edukacyjnych. Dzięki technologii VR uczniowie mogą na przykład odbywać wirtualne wycieczki po starożytnych miastach, eksplorować struktury molekularne w chemii czy symulować doświadczenia laboratoryjne w naukach przyrodniczych. AR z kolei umożliwia wzbogacanie tradycyjnych metod nauczania poprzez dodawanie interaktywnych treści wizualnych do rzeczywistych materiałów edukacyjnych. Takie podejście nie tylko zwiększa zainteresowanie uczniów, ale również ułatwia zrozumienie trudnych konceptów, które często wymagają wyobraźni przestrzennej lub zaawansowanej abstrakcji (Anwar et al., 2023).

Mimo licznych korzyści związanych z wprowadzeniem sztucznej inteligencji do edukacji, pojawiają się również wyzwania, między innymi konieczność zapewnienia równomiernego dostępu do technologii, szczególnie w regionach o ograniczonych zasobach. Brak dostępu do nowoczesnych narzędzi edukacyjnych może pogłębiać nierówności społeczne, ograniczając możliwości uczniów z mniej uprzywilejowanych środowisk. Cyklicznym wyzwaniem jest ochrona danych osobowych i prywatności uczniów, które są nieodłącznym elementem funkcjonowania systemów AI. Wprowadzenie odpowiednich regulacji prawnych oraz edukacja w zakresie cyberbezpieczeństwa stają się zatem kluczowe dla skutecznego i bezpiecznego wykorzystania AI w edukacji (Williamson, 2020).

Rola nauczyciela również ulega przekształceniu w erze sztucznej inteligencji. Zamiast być jedynie źródłem wiedzy, nauczyciele stają się przewodnikami i mentorami, którzy wspierają uczniów w korzystaniu z nowoczesnych technologii oraz rozwijają ich umiejętności krytycznego myślenia i współpracy. Współczesna edukacja wymaga zatem od nauczycieli ciągłego doskonalenia swoich kompetencji technologicznych, aby mogli skutecznie integrować AI w proces nauczania (Luckin et al., 2016).



Podsumowując, sztuczna inteligencja ma potencjał, aby zrewolucjonizować edukację, wprowadzając nowe możliwości personalizacji, automatyzacji i interaktywności. Jej rola wykracza jednak poza technologię – wymaga zmiany podejścia do nauczania, które uwzględni zarówno korzyści, jak i wyzwania związane z jej wdrożeniem. Ten rozdział analizuje wpływ AI na edukację i procesy uczenia się, badając jej zastosowania, potencjalne ograniczenia oraz perspektywy rozwoju.

### **3.1 AI w edukacji: narzędzia wspierające naukę**

Sztuczna inteligencja (AI) wprowadza znaczące zmiany w edukacji, oferując narzędzia, które wspierają proces nauczania i uczenia się. Inteligentne aplikacje oraz platformy e-learningowe stają się czynnikami współczesnych systemów edukacyjnych, pozwalając na personalizację nauki, zwiększenie dostępności do edukacji oraz rozwijanie nowych metod interakcji z wiedzą. Rozwój tych technologii nie tylko usprawnia tradycyjne metody nauczania, ale także otwiera drzwi do nowych możliwości edukacyjnych.

Ważnym zastosowaniem AI w edukacji jest personalizacja procesu nauczania. Inteligentne systemy edukacyjne analizują dane o postępach ucznia, jego stylu uczenia się oraz indywidualnych preferencjach, aby dostosować treści dydaktyczne i tempo nauki. Przykładem takich systemów są aplikacje, jak DreamBox czy Smart Sparrow, które wykorzystują algorytmy uczenia maszynowego do identyfikowania mocnych i słabych stron uczniów. Dzięki temu możliwe jest dostosowanie zadań i materiałów edukacyjnych do ich aktualnych potrzeb, co pozwala na bardziej efektywne i angażujące uczenie się (Holmes et al., 2019).

Personalizacja nauki ma szczególne znaczenie w pracy z uczniami o zróżnicowanych potrzebach edukacyjnych. Dzieci z trudnościami w nauce, uczniowie utalentowani czy osoby uczące się w drugim języku mogą korzystać z materiałów dostosowanych do ich indywidualnych możliwości. Na przykład systemy takie jak Carnegie Learning oferują wsparcie w nauce matematyki poprzez adaptacyjne lekcje, które automatycznie zmieniają poziom trudności w zależności od wyników ucznia. Tego rodzaju technologie pomagają również nauczycielom, dostarczając im informacji o postępach uczniów i obszarach wymagających dodatkowej uwagi.



Inteligentne aplikacje edukacyjne wykorzystują sztuczną inteligencję do wspierania uczenia się w różnych dziedzinach, takich jak języki obce, matematyka czy programowanie. Przykładem są aplikacje takie jak Duolingo, które wykorzystują algorytmy uczenia maszynowego

do dostosowywania lekcji językowych do poziomu i tempa użytkownika. Duolingo analizuje odpowiedzi uczniów, identyfikuje trudności w nauce poszczególnych słów czy struktur gramatycznych, a następnie dostosowuje ćwiczenia w celu utrwalenia wiedzy. Dzięki temu proces nauki jest bardziej efektywny i motywujący dla użytkownika (von Ahn, 2013).

Innym przykładem są aplikacje wspierające rozwój umiejętności STEM (nauki, technologii, inżynierii i matematyki), takie jak Photomath czy Mathway, które wykorzystują technologie rozpoznawania obrazu i algorytmy AI do rozwiązywania problemów matematycznych. Uczniowie mogą nie tylko uzyskać odpowiedź na dane zadanie, ale także krok po kroku prześledzić proces rozwiązania, co wspiera rozwój ich umiejętności analitycznych i logicznego myślenia.

Platformy e-learningowe, takie jak Coursera, Khan Academy czy EdX, zrewolucjonizowały sposób, w jaki uczniowie na całym świecie zdobywają wiedzę. Wykorzystując sztuczną inteligencję, te platformy mogą oferować adaptacyjne ścieżki nauczania, dostosowując treści do potrzeb użytkowników. Na przykład Coursera wykorzystuje algorytmy AI do rekomendowania kursów i materiałów edukacyjnych na podstawie wcześniejszych aktywności użytkownika. Platformy te oferują również interaktywne narzędzia, takie jak quizy i symulacje, które umożliwiają uczniom zastosowanie wiedzy w praktyce (Pappano, 2012).

E-learning wspierany przez AI pozwala na dostęp do edukacji na niespotykaną dotąd skalę, szczególnie w regionach, gdzie tradycyjny system edukacji jest trudno dostępny. Uczniowie z różnych części świata mogą uczestniczyć w kursach prowadzonych przez renomowane uniwersytety, co zwiększa dostępność do wysokiej jakości edukacji. Ponadto platformy te umożliwiają naukę w dowolnym miejscu i czasie, co jest szczególnie korzystne dla osób pracujących lub posiadających inne zobowiązania czasowe.

Chatboty edukacyjne, wykorzystujące przetwarzanie języka naturalnego, odgrywają coraz większą rolę w procesie uczenia się. Chatboty, takie jak Watson Tutor od IBM, są wykorzystywane do odpowiadania na pytania uczniów, dostarczania wskazówek



czy pomagania w rozwiązywaniu problemów w czasie rzeczywistym. Dzięki analizie języka ucznia chatboty mogą dostosowywać swoje odpowiedzi, oferując bardziej spersonalizowane wsparcie. Ponadto chatboty mogą być używane do nauki języków obcych, symulując rozmowy z rodzimymi użytkownikami języka, co pozwala na rozwijanie umiejętności komunikacyjnych (Holmes et al., 2019).

Mimo licznych korzyści wynikających z wykorzystania sztucznej inteligencji w edukacji, istnieją również wyzwania związane z jej wdrożeniem, jak konieczność zapewnienia równomiernego dostępu do technologii, szczególnie w regionach o ograniczonych zasobach. Brak infrastruktury technologicznej i wysokie koszty urządzeń mogą prowadzić do pogłębiania nierówności edukacyjnych. Systemy AI gromadzą i analizują ogromne ilości danych, co rodzi pytania dotyczące prywatności oraz bezpieczeństwa informacji osobowych uczniów.

Sztuczna inteligencja w edukacji oferuje szeroki wachlarz możliwości wspierania procesu nauczania i uczenia się. Inteligentne aplikacje, platformy e-learningowe oraz chatboty edukacyjne zmieniają sposób, w jaki uczniowie zdobywają wiedzę, umożliwiając personalizację nauki, rozwijanie umiejętności i zwiększanie dostępności do edukacji. Mimo istniejących wyzwań, potencjał AI w edukacji jest ogromny i może prowadzić do dalszych innowacji, które jeszcze bardziej usprawnią proces dydaktyczny i zwiększą jego efektywność.

### **3.2 Personalizacja nauczania dzięki AI**

Personalizacja nauczania jest istotnym czynnikiem zastosowań sztucznej inteligencji (AI) w edukacji. Współczesne systemy edukacyjne coraz częściej wykorzystują zaawansowane technologie AI do tworzenia bardziej zindywidualizowanych ścieżek nauczania, które odpowiadają na potrzeby, zainteresowania i zdolności każdego ucznia. Dzięki personalizacji proces edukacyjny staje się bardziej efektywny, angażujący i dostosowany do specyficznych wymagań jednostki. W niniejszym rozdziale omówiono personalizację nauczania wspieranej przez AI, jej zastosowania, korzyści oraz wyzwania związane z wdrażaniem tych technologii.

Charakter osobisty nauczania opiera się na założeniu, że każdy uczeń uczy się w swoim tempie i stylu, a jego potrzeby edukacyjne są unikalne. Tradycyjny model edukacji oparty na jednolitym podejściu do wszystkich uczniów nie jest w stanie w pełni uwzględnić tej różnorodności. Sztuczna inteligencja pozwala na przełamanie tego schematu, umożliwiając



analizę danych o postępach ucznia, jego preferencjach i stylu uczenia się w czasie rzeczywistym. Algorytmy AI dostosowują treści, tempo nauki oraz metody nauczania w sposób dynamiczny, co znacząco zwiększa efektywność procesu edukacyjnego (Holmes et al., 2019).

Z głównych narzędzi wspierających personalizację nauczania są platformy edukacyjne wyposażone w sztuczną inteligencję, takie jak DreamBox, Smart Sparrow czy Edmentum. Systemy te analizują wyniki uczniów, identyfikując ich mocne i słabe strony, a następnie dostosowują zadania i materiały dydaktyczne do ich potrzeb. Na przykład DreamBox, platforma do nauczania matematyki, wykorzystuje algorytmy AI do tworzenia spersonalizowanych ścieżek edukacyjnych, które są dostosowane do poziomu zaawansowania ucznia. Uczeń, który szybko opanowuje nowe zagadnienia, otrzymuje trudniejsze zadania, podczas gdy osoba mająca trudności z danym tematem jest wspierana dodatkowymi materiałami i wskazówkami (Means et al., 2020).

Innym przykładem są inteligentne aplikacje edukacyjne, takie jak Duolingo, które wspierają naukę języków obcych. Aplikacja ta dostosowuje treści lekcji do postępów użytkownika, identyfikując słowa i struktury gramatyczne, które sprawiają trudność, i ponownie wprowadzając je w kolejnych ćwiczeniach. Dzięki temu użytkownicy mogą uczyć się w sposób bardziej efektywny i motywujący, co przekłada się na lepsze wyniki edukacyjne (von Ahn, 2013).

Adaptacyjne systemy nauczania, wspierane przez AI, analizują dane o uczniach, takie jak ich postępy, tempo nauki, preferencje czy wyniki testów, a następnie dostosowują treści i metody nauczania w sposób dynamiczny. Przykładem adaptacyjnych systemów nauczania jest Carnegie Learning, platforma edukacyjna, która wykorzystuje uczenie maszynowe do identyfikowania

luk w wiedzy uczniów i dostosowywania materiałów dydaktycznych w celu ich uzupełnienia. Dzięki temu uczniowie mogą skupić się na obszarach wymagających poprawy, co zwiększa skuteczność nauki (Holmes et al., 2019).

Indywidualizacja w nauczaniu przynosi wiele korzyści zarówno uczniom, jak i nauczycielom. Dla uczniów oznacza to możliwość uczenia się w tempie dostosowanym do ich indywidualnych potrzeb i stylu, co zmniejsza stres związany z nauką i zwiększa zaangażowanie. Uczniowie mają również większą kontrolę nad procesem edukacyjnym, co sprzyja rozwojowi samodzielności i umiejętności zarządzania czasem (Luckin et al., 2016).



Nauczyciele zyskują natomiast narzędzia, które pozwalają im lepiej monitorować postępy uczniów i dostarczać bardziej precyzyjne wsparcie. Systemy AI mogą automatycznie identyfikować obszary, w których uczniowie mają trudności, co pozwala nauczycielom skupić się na najbardziej potrzebujących pomocy. Ponadto automatyzacja rutynowych zadań, takich jak ocenianie testów czy tworzenie planów lekcji, pozwala nauczycielom poświęcić więcej czasu na interakcję z uczniami.

Mimo licznych korzyści personalizacja nauczania z wykorzystaniem AI wiąże się również z pewnymi wyzwaniami. Systemy AI gromadzą i analizują ogromne ilości danych, co rodzi pytania dotyczące prywatności oraz bezpieczeństwa informacji. Wprowadzenie odpowiednich regulacji prawnych i standardów bezpieczeństwa jest najważniejsze dla skutecznego wdrożenia personalizacji w edukacji (Williamson, 2020).

Ważnym wyzwaniem jest zapewnienie równego dostępu do technologii. Wiele szkół i uczniów, szczególnie w regionach o ograniczonych zasobach, nie ma dostępu do zaawansowanych narzędzi edukacyjnych. Może to prowadzić do pogłębiania nierówności edukacyjnych. Dlatego konieczne są inwestycje w infrastrukturę technologiczną oraz programy wsparcia dla uczniów i nauczycieli.

Przyszłość personalizacji nauczania z wykorzystaniem AI wydaje się obiecująca. Dynamiczny rozwój technologii oraz rosnące zainteresowanie edukacją cyfrową stwarzają możliwości tworzenia coraz bardziej zaawansowanych narzędzi wspierających proces nauki. W przyszłości możemy spodziewać się jeszcze większej integracji systemów AI z tradycyjnym modelem edukacji, co pozwoli na jeszcze lepsze dostosowanie nauczania do indywidualnych potrzeb uczniów.

Dostosowanie nauczania dzięki AI zmienia sposób, w jaki uczniowie zdobywają wiedzę i rozwijają swoje umiejętności. Dzięki zaawansowanym technologiom uczniowie mogą uczyć się w sposób bardziej dostosowany do ich potrzeb, co zwiększa efektywność nauki i poprawia wyniki edukacyjne. Jednocześnie nauczyciele zyskują narzędzia wspierające ich pracę, pozwalające na bardziej precyzyjne monitorowanie postępów uczniów i dostarczanie im wsparcia. Mimo wyzwań związanych z ochroną danych i dostępem do technologii, indywidualny tok nauczania z wykorzystaniem AI ma potencjał, aby znacząco poprawić jakość edukacji na całym świecie.



Analizując wpływ AI na edukację, widzimy wyraźne korzyści, takie jak personalizacja nauki i interaktywne wsparcie dla uczniów. Jednakże, technologie te mogą również przyczynić się do problemów, takich jak uzależnienie od ekranów czy izolacja społeczna. W kolejnym rozdziale przyjrzymy się bliżej wpływowi AI na zdrowie psychiczne dzieci i młodzieży.

### 3.3 Wyzwania i zagrożenia związane z wykorzystaniem AI w edukacji

Rozwój technologii sztucznej inteligencji w edukacji otwiera nowe możliwości personalizacji nauczania, zwiększenia dostępności materiałów edukacyjnych oraz automatyzacji wielu procesów dydaktycznych. Jednakże, implementacja tych rozwiązań wiąże się z szeregiem wyzwań i potencjalnych zagrożeń, które mają zarówno technologiczne, jak i społeczne implikacje. Niniejszy rozdział przedstawia główne problemy wynikające z wykorzystania AI w edukacji, podkreślając potrzebę ostrożnego podejścia do jej wdrażania.

Pierwszym istotnym wyzwaniem związanym z wykorzystaniem AI w edukacji jest problem prywatności i ochrony danych osobowych. Systemy AI w celu skutecznej personalizacji nauczania gromadzą i analizują ogromne ilości danych uczniów, takich jak ich wyniki w nauce, preferencje edukacyjne czy nawet dane biometryczne (Zawacki-Richter et al., 2019). W przypadku nieodpowiedniego zabezpieczenia tych informacji, może dojść do naruszenia prywatności uczniów, co niesie za sobą poważne konsekwencje prawne i etyczne. W 2019 roku pojawiły się doniesienia o platformach edukacyjnych gromadzących dane uczniów bez ich zgody, co wywołało międzynarodowe obawy dotyczące ochrony prywatności. Na przykład, w Stanach Zjednoczonych organizacja non-profit Common Sense Media opublikowała raport wskazujący, że wiele aplikacji edukacyjnych zbierało dane osobowe dzieci bez odpowiedniej zgody rodziców, naruszając w ten sposób przepisy dotyczące ochrony prywatności dzieci w Internecie. Raport ten podkreślał potrzebę wprowadzenia bardziej rygorystycznych standardów ochrony danych w sektorze edukacyjnym.

W Europie również odnotowano przypadki nieuprawnionego przetwarzania danych uczniów. W Polsce Urząd Ochrony Danych Osobowych (UODO) nałożył karę na szkołę podstawową za zbieranie danych biometrycznych dzieci podczas korzystania ze stołówki szkolnej bez odpowiedniej zgody, co stanowiło naruszenie przepisów RODO. (<https://uodo.gov.pl/pl/329/1451>). Te incydenty zwróciły uwagę na konieczność wzmocnienia



ochrony danych osobowych w środowisku edukacyjnym oraz zapewnienia, że platformy edukacyjne przestrzegają obowiązujących przepisów dotyczących prywatności.

Drugim wyzwaniem jest brak równego dostępu do technologii AI. Istnieje ryzyko, że zaawansowane systemy edukacyjne oparte na sztucznej inteligencji mogą być dostępne jedynie dla zamożniejszych szkół i społeczności, co pogłębia nierówności edukacyjne (Holmes et al., 2019). Szczególnie w krajach rozwijających się brak infrastruktury technologicznej, a także odpowiedniego szkolenia dla nauczycieli, może prowadzić do ograniczonego wykorzystania potencjału AI w edukacji. Konsekwencją tego jest powstawanie "cyfrowej przepaści", która wpływa na dostęp uczniów do nowoczesnych narzędzi wspierających proces kształcenia.

Trzecim atrybutem są kwestie związane z etyką i odpowiedzialnością za decyzje podejmowane przez algorytmy AI. Systemy te mogą przejawiać niezamierzone uprzedzenia wynikające z danych, na których zostały wytrenowane. Na przykład, badania wykazały, że algorytmy oceniające prace pisemne uczniów mogą niesprawiedliwie oceniać teksty w zależności od języka, w jakim zostały napisane, lub używanej składni (Baker., 2021). W takich przypadkach brak przejrzystości w działaniu algorytmów prowadzi do trudności w kwestionowaniu błędnych decyzji, co może wpłynąć na zaufanie uczniów i nauczycieli do systemów edukacyjnych opartych na AI.

Czwartym problemem jest wpływ AI na rolę nauczyciela. Automatyzacja zadań, takich jak ocena prac domowych czy analiza postępów uczniów, może prowadzić do dehumanizacji procesu edukacyjnego (Williamson, 2019). Nauczyciele, zamiast pełnić rolę przewodników w procesie uczenia się, mogą być postrzegani jedynie jako nadzorcy technologii. W dłuższej perspektywie może to wpłynąć negatywnie na relacje między nauczycielami a uczniami oraz osłabić kluczową rolę nauczyciela w procesie wychowawczym.

Ostatnim wyzwaniem jest brak odpowiednich regulacji prawnych i standardów dotyczących wykorzystania AI w edukacji. Obecnie wiele państw nie posiada jasno określonych wytycznych dotyczących wdrażania systemów AI w szkołach, co prowadzi do ich niejednolitego wykorzystania i różnorodnych interpretacji odpowiedzialności za ewentualne problemy (Luckin et al., 2016). Regulacje te są niezbędne, aby zapewnić bezpieczeństwo uczniów, przejrzystość algorytmów oraz odpowiedzialne wykorzystanie danych.



Podsumowując, wykorzystanie AI w edukacji niesie ze sobą szereg wyzwań i zagrożeń, które wymagają starannego rozważenia przed wprowadzeniem tych technologii na szeroką skalę. Problemy związane z ochroną danych, równością dostępu, etyką, rolą nauczycieli oraz regulacjami prawnymi muszą zostać uwzględnione w procesie projektowania i wdrażania systemów AI. Tylko wtedy możliwe będzie pełne wykorzystanie potencjału sztucznej inteligencji w edukacji, przy jednoczesnym zminimalizowaniu negatywnych konsekwencji.

### 3.4 AI w twórczości i rozwoju umiejętności artystycznych

Wykorzystanie sztucznej inteligencji w rozwijaniu umiejętności artystycznych dzieci i młodzieży otwiera nowe możliwości wspierania kreatywności oraz poszerzania zakresu edukacji artystycznej. AI, jako narzędzie, które może generować, analizować i inspirować różnorodne formy sztuki, ma potencjał wzbogacenia procesu twórczego. Niemniej jednak jej wpływ na rozwój umiejętności artystycznych młodych ludzi jest zarówno obiecujący, jak i kontrowersyjny. W tym rozdziale omówione zostaną zarówno korzyści, jakie AI przynosi w dziedzinie edukacji artystycznej, jak i wyzwania związane z jej implementacją.

Jednym z zastosowań AI w twórczości dzieci i młodzieży jest generowanie inspiracji. Narzędzia oparte na sztucznej inteligencji, takie jak DeepArt czy DALL-E, umożliwiają młodym artystom eksplorację nowych stylów i technik, co w innym przypadku mogłoby być trudne do osiągnięcia ze względu na ograniczenia czasowe lub zasoby. Przykładem może być projekt edukacyjny prowadzony w szkołach w USA, w którym uczniowie korzystali z narzędzi AI do przekształcania własnych zdjęć w obrazy inspirowane stylami znanych artystów, takich jak Vincent van Gogh czy Claude Monet. Dzięki temu młodzież mogła lepiej zrozumieć różnice między stylami malarskimi, jednocześnie rozwijając swoje umiejętności analityczne i estetyczne (Black, 2021).

AI wspiera również rozwój umiejętności muzycznych dzieci i młodzieży. Programy takie jak Amper Music czy AIVA pozwalają uczniom na komponowanie muzyki przy wsparciu algorytmów analizujących harmonie, rytmy i style różnych gatunków muzycznych. Na przykład, w eksperymencie przeprowadzonym w Wielkiej Brytanii, młodzież w wieku 12–15 lat tworzyła własne utwory muzyczne z wykorzystaniem AI, co nie tylko rozwijało ich zdolności kompozytorskie, ale również wzmacniało zrozumienie zasad teorii muzyki (François & Van der Merwe, 2020). Dla wielu uczniów możliwość natychmiastowego



eksperymentowania z melodiami i rytmami stała się inspiracją do dalszego rozwijania swoich pasji muzycznych (Li & Wang, 2023, Holland, 2000; ).

AI wspomaga również rozwój umiejętności w zakresie sztuk wizualnych. Przykładem zastosowania AI w edukacji artystycznej jest program AI4Youth, skierowany do uczniów liceów ogólnokształcących i techników. Jego celem jest zwiększenie świadomości w obszarze cyfryzacji, zwłaszcza w zakresie sztucznej inteligencji, oraz promowanie kompetencji przyszłości wśród młodzieży. Program ten umożliwia uczniom zdobycie wiedzy i praktycznych umiejętności pozwalających na stworzenie własnych projektów z wykorzystaniem AI (Ministerstwo Rozwoju i Technologii, 2021).

Ważnym wymiarem edukacji artystycznej wspieranej przez AI jest również rozwój krytycznego myślenia. Korzystanie z algorytmów generujących sztukę pozwala młodzieży na analizowanie procesu twórczego i refleksję nad tym, w jaki sposób technologia przekłada się na tradycyjne formy sztuki. Uczniowie często zastanawiają się, gdzie kończy się kreatywność człowieka, a zaczyna automatyzacja procesu twórczego.

Mimo licznych korzyści, zastosowanie AI w edukacji artystycznej wiąże się również z wyzwaniami, takimi jak ryzyko ograniczenia oryginalności i autentyczności w twórczości dzieci i młodzieży. Krytycy zwracają uwagę, że nadmierne poleganie na AI może prowadzić do sytuacji, w której młodzi artyści traktują algorytmy jako narzędzie zastępujące ich własną inwencję twórczą (Anantrasirichai, 2021). Istnieje również obawa, że technologia może zdominować proces nauczania sztuki, marginalizując rolę nauczyciela jako mentora i przewodnika w rozwijaniu kreatywności.

Bieżącym problemem jest brak dostępu do zaawansowanych technologii AI w niektórych społecznościach, co może prowadzić do pogłębiania nierówności edukacyjnych. W krajach o niższym poziomie infrastruktury technologicznej dzieci i młodzież często nie mają możliwości korzystania z narzędzi wspieranych przez AI, co ogranicza ich szanse na rozwijanie umiejętności artystycznych na równi z rówieśnikami z bardziej uprzywilejowanych środowisk (Holmes et al., 2019).

Podsumowując, sztuczna inteligencja ma ogromny potencjał w rozwijaniu umiejętności artystycznych dzieci i młodzieży, wspierając kreatywność, inspirację i naukę nowych technik. Narzędzia AI, takie jak platformy generujące obrazy czy muzykę, stanowią cenne wsparcie



w procesie edukacji artystycznej. Jednocześnie, aby w pełni wykorzystać te możliwości, konieczne jest rozważenie wyzwań związanych z autentycznością twórczości, dostępem do technologii oraz rolą nauczyciela w procesie edukacji. W przyszłości kluczowe będzie znalezienie balansu między wykorzystaniem technologii a rozwijaniem indywidualnej kreatywności uczniów.



## Rozdział 4. Sztuczna inteligencja a zdrowie psychiczne dzieci i młodzieży

W ostatnich latach obserwuje się dynamiczny rozwój technologii sztucznej inteligencji, co prowadzi do jej coraz szerszego zastosowania w różnych dziedzinach życia, w tym w ochronie zdrowia psychicznego dzieci i młodzieży. W obliczu rosnących wyzwań związanych z dostępnością opieki psychiatrycznej dla młodych pacjentów, AI oferuje innowacyjne rozwiązania wspierające diagnostykę, terapię oraz monitorowanie stanu psychicznego tej grupy wiekowej.

W Polsce problem dostępności specjalistycznej opieki psychiatrycznej dla dzieci i młodzieży jest szczególnie palący. Według danych z 2023 roku, na jednego psychiatrę dziecięcego przypadało około 12,4 tysiąca pacjentów poniżej 18. roku życia, co znacząco utrudniało zapewnienie odpowiedniej opieki (Demagog, 2023). W tym kontekście technologie oparte na AI mogą stanowić cenne wsparcie dla systemu opieki zdrowotnej, umożliwiając szybszą i bardziej precyzyjną diagnozę oraz interwencję.

Przykładem zastosowania AI w tej dziedzinie jest projekt "Mentalio" realizowany przez Szpital Uniwersytecki w Krakowie. System ten wykorzystuje algorytmy sztucznej inteligencji oparte na technologii grafowej do wspierania decyzji diagnostycznych i terapeutycznych w obszarze zdrowia psychicznego nastolatków (LoveKrakow.pl, 2023). Dzięki analizie różnorodnych danych, "Mentalio" ma potencjał usprawnienia procesu leczenia poprzez proponowanie spersonalizowanych ścieżek terapeutycznych.

Innowacyjnym podejściem jest wykorzystanie generatywnej sztucznej inteligencji do oceny dobrostanu psychicznego dzieci. Badania przeprowadzone przez naukowców z Uniwersytetu Łódzkiego wykazały, że na podstawie pytań, jakie dzieci chciałyby zadać AI, można prognozować ich stan psychiczny (Uniwersytet Łódzki, 2024). Takie podejście umożliwia wczesne wykrywanie potencjalnych problemów i szybszą interwencję.

Warto również zauważyć, że AI znajduje zastosowanie w tworzeniu społecznych robotów wspierających zdrowie psychiczne dzieci. Roboty te, poprzez interakcje z młodymi pacjentami, mogą pełnić rolę asystentów terapeutycznych, pomagając w redukcji lęku czy stresu związanego z leczeniem (Wikipedia, 2023). Jednak wprowadzenie takich technologii wiąże się z koniecznością rozważenia elementów etycznych, takich jak zapewnienie prywatności czy unikanie dehumanizacji opieki.

Podsumowując, integracja sztucznej inteligencji w obszarze zdrowia psychicznego dzieci i młodzieży niesie ze sobą obiecujące możliwości poprawy jakości opieki oraz dostępności usług terapeutycznych. Niemniej jednak kluczowe jest prowadzenie dalszych badań nad skutecznością tych rozwiązań oraz uwzględnienie reguł etycznych i społecznych związanych z ich wdrażaniem.

#### **4.1 Ekspozycja na treści generowane przez AI a wpływ na emocje i samopoczucie**

Wraz z dynamicznym rozwojem sztucznej inteligencji rośnie jej wpływ na życie codzienne dzieci i młodzieży. Treści generowane przez AI, takie jak filmy, obrazy, muzyka czy teksty, stają się integralną częścią cyfrowego środowiska, w którym młodzi ludzie spędzają znaczną część czasu. Z jednej strony oferują one szerokie możliwości kreatywnego rozwoju, edukacji i rozrywki, z drugiej jednak mogą wywoływać istotne konsekwencje emocjonalne i wpływać na ich samopoczucie. W niniejszym rozdziale przedstawiono analizę wpływu treści generowanych przez AI na emocje oraz zdrowie psychiczne młodych odbiorców, opartą na dostępnych badaniach naukowych.

Treści generowane przez AI są często projektowane w sposób, który maksymalizuje zaangażowanie użytkowników. Algorytmy rekomendacyjne, takie jak te stosowane przez platformy streamingowe czy media społecznościowe, analizują preferencje odbiorców i proponują spersonalizowane treści. Chociaż takie podejście może zwiększać zainteresowanie i pozytywne doświadczenia użytkownika, niesie również ryzyko nadmiernej ekspozycji na treści o negatywnym wydźwięku emocjonalnym. Badania przeprowadzone przez Orben i Przybylski (2019) wykazały, że częsta ekspozycja na treści generowane przez algorytmy może prowadzić do obniżenia samopoczucia młodzieży, szczególnie w przypadku treści wywołujących lęk, smutek czy niepokój.

Przykładem treści generowanych przez AI są realistyczne obrazy i filmy tworzone za pomocą algorytmów generatywnych, takich jak DALL-E czy GANs (Generative Adversarial Networks). Chociaż mogą one inspirować i rozwijać kreatywność, ich hiperrealistyczny charakter może być trudny do odróżnienia od rzeczywistości. Młodzież, która jeszcze nie w pełni rozwinęła krytyczne myślenie, może być podatna na dezinformację lub zjawisko tzw. uncanny valley, które prowadzi do poczucia niepokoju i dyskomfortu (Mori et al., 2012). Na przykład, realistyczne obrazy o tematyce katastroficznej lub tragicznej mogą wywoływać silne emocje, które negatywnie wpływają na zdrowie psychiczne.



Również chatboty i wirtualni asystenci, tacy jak ChatGPT czy Google Bard, odgrywają coraz większą rolę w życiu młodzieży, oferując wsparcie emocjonalne, odpowiedzi na pytania czy interakcję społeczną. Badania nad wykorzystaniem AI w terapii dzieci i młodzieży wskazują, że takie narzędzia mogą być użyteczne w redukcji samotności i stresu (Hoermann et al., 2017). Jednakże istnieje ryzyko, że młodzi ludzie mogą nadmiernie polegać na interakcji z AI, co prowadzi do ograniczenia kontaktów interpersonalnych i osłabienia umiejętności budowania relacji społecznych.

Istotnym problemem związanym z ekspozycją na treści generowane przez AI jest również ich potencjalnie szkodliwy wpływ na samoocenę. Algorytmy generujące obrazy i filmy są często wykorzystywane w mediach społecznościowych do tworzenia idealizowanych i nierealistycznych przedstawień ludzkiego ciała czy stylu życia. Badania Tiggemann i Slater (2014) pokazują, że nadmierne porównywanie się młodzieży do takich treści prowadzi do zwiększenia niezadowolenia z własnego wyglądu i spadku samooceny, co może przyczyniać się do rozwoju zaburzeń psychicznych, takich jak depresja czy zaburzenia odżywiania.

Z drugiej strony, treści generowane przez AI mogą mieć również pozytywny wpływ na emocje i samopoczucie młodzieży, jeśli są odpowiednio wykorzystywane. Edukacyjne aplikacje generujące treści w sposób interaktywny i angażujący mogą wspierać rozwój emocjonalny i intelektualny. Przykładem są aplikacje mindfulness, które pomagają młodym ludziom radzić sobie z lękiem i stresem, ucząc ich technik relaksacyjnych. W takich przypadkach sztuczna inteligencja może pełnić rolę pomocnika w rozwijaniu zdrowszych nawyków emocjonalnych.

Podsumowując, wpływ ekspozycji na treści generowane przez AI na emocje i samopoczucie dzieci i młodzieży jest złożony i zależy od rodzaju oraz celu tych treści. Chociaż technologie te oferują liczne korzyści, takie jak rozwój kreatywności i wsparcie emocjonalne, niosą ze sobą także ryzyko związane z dezinformacją, uzależnieniem czy obniżeniem samooceny. Aby zminimalizować negatywne skutki, kluczowe jest rozwijanie umiejętności krytycznego myślenia u młodych ludzi oraz świadome korzystanie z technologii AI w sposób etyczny i wspierający zdrowie psychiczne.



## 4.2 Problem uzależnienia od technologii i ekranów

Współczesne dzieci i młodzież dorastają w erze cyfrowej, gdzie technologie informacyjno-komunikacyjne (ICT) odgrywają kluczową rolę w ich codziennym życiu. Urządzenia takie jak smartfony, tablety czy komputery stały się nieodłącznym elementem ich rzeczywistości, oferując nieograniczony dostęp do informacji, rozrywki oraz platform społecznościowych. Jednakże nadmierne korzystanie z tych technologii może prowadzić do uzależnień, które mają istotny wpływ na zdrowie fizyczne, psychiczne oraz funkcjonowanie społeczne młodych ludzi.

Badania kładą nacisk na rosnące rozpowszechnienie korzystania z nowych technologii przez dzieci i młodzież. Według raportu Fundacji Dajemy Dzieciom Siłę, ponad 40% dzieci w wieku 1-2 lat korzysta z tabletów lub smartfonów, a niemal co trzecie dziecko w tym wieku używa tych urządzeń codziennie lub prawie codziennie. Co więcej, 13% dzieci w tej grupie wiekowej korzysta z urządzeń mobilnych przez ponad godzinę dziennie (Bąk, 2015). Tak wczesna i intensywna ekspozycja na ekrany może prowadzić do nałogowego używania technologii informacyjno-komunikacyjnych, zwłaszcza Internetu oraz telefonów komórkowych (Krzyżak-Szymańska, 2015).

Uzależnienie od technologii i ekranów wśród dzieci i młodzieży objawia się m.in. trudnościami w kontrolowaniu czasu spędzanego przed ekranem, zaniedbywaniem obowiązków szkolnych i domowych, a także izolacją społeczną. Nadmierne korzystanie z urządzeń elektronicznych może prowadzić do problemów zdrowotnych, takich jak wady postawy, zaburzenia snu czy problemy ze wzrokiem. Ponadto, intensywne korzystanie z Internetu czy gier komputerowych może prowadzić do uzależnienia, co niesie za sobą szereg negatywnych konsekwencji dla rozwoju i zdrowia dziecka (Krzyżak-Szymańska, 2015).

W literaturze przedmiotu wyróżnia się trzy podejścia do kwestii uzależnienia od Internetu: (1) jako zachowanie ze spektrum zaburzeń obsesyjno-kompulsyjnych lub zaburzeń kontroli impulsów; (2) jako zachowanie analogiczne do uzależnienia od substancji psychoaktywnych; (3) jako zachowanie związane z deficytami w zakresie relacji społecznych oraz ich budowania (Kuss & Griffiths, 2012). Niezależnie od przyjętej perspektywy, uzależnienie od technologii ma istotny wpływ na funkcjonowanie poznawcze i emocjonalne młodych ludzi.

Kuluary uzależnienia od telefonów komórkowych, badania naznaczają, że współczesny styl życia, nauka zdalna oraz cyfryzacja wielu dziedzin życia mają znaczący wpływ na zdrowie



fizyczne i psychiczne najmłodszych. Analiza literatury pokazuje, że uzależnienie od telefonu komórkowego u dzieci i młodzieży objawia się m.in. trudnościami w koncentracji, obniżeniem wyników w nauce oraz problemami w relacjach interpersonalnych (Bielawska, 2023).

W obliczu rosnącego problemu uzależnień technologicznych wśród dzieci i młodzieży, istotne jest podejmowanie działań profilaktycznych oraz terapeutycznych. Publikacje takie jak "Uzależnienia technologiczne wśród dzieci i młodzieży. Teoria, profilaktyka, terapia – wybrane zagadnienia" oferują scenariusze zajęć profilaktycznych, stanowiące zbiór materiałów metodycznych do prowadzenia zajęć z dziećmi i młodzieżą (Krzyżak-Szymańska, 2015). Edukacja w zakresie świadomego i umiarkowanego korzystania z technologii, a także promowanie alternatywnych form spędzania czasu wolnego, są kluczowe w zapobieganiu uzależnieniom i wspieraniu zdrowego rozwoju młodego pokolenia.

Podsumowując, problem uzależnienia od technologii i ekranów wśród dzieci i młodzieży stanowi istotne wyzwanie dla współczesnego społeczeństwa. Nadmierne korzystanie z urządzeń elektronicznych może prowadzić do szeregu negatywnych konsekwencji zdrowotnych, emocjonalnych i społecznych. Dlatego konieczne jest podejmowanie skoordynowanych działań edukacyjnych, profilaktycznych i terapeutycznych, aby wspierać młodych ludzi w zdrowym i zrównoważonym korzystaniu z technologii.

### **4.3 Rola AI w terapii i wsparciu psychologicznym**

W ostatnich latach sztuczna inteligencja zyskała na znaczeniu w dziedzinie terapii i wsparcia psychologicznego dla dzieci i młodzieży. Jej zastosowanie obejmuje diagnozowanie zaburzeń psychicznych, prowadzenie terapii oraz monitorowanie postępów pacjentów. W niniejszym rozdziale omówiono rolę AI w tych obszarach, opierając się na aktualnych badaniach naukowych.

#### **Diagnozowanie zaburzeń psychicznych**

Tradycyjne metody diagnozowania zaburzeń psychicznych u dzieci i młodzieży opierają się na wywiadach klinicznych, kwestionariuszach i obserwacjach behawioralnych. Chociaż są one skuteczne w wielu przypadkach, ich ograniczenia wynikają z subiektywności obserwacji, zależności od doświadczenia klinicysty oraz trudności w identyfikacji subtelnych wzorców zachowań. Na przykład, u dzieci z zaburzeniami lękowymi objawy mogą być maskowane przez inne trudności, takie jak problemy somatyczne czy zachowania unikania, co utrudnia trafną diagnozę. Wprowadzenie sztucznej inteligencji do procesu diagnostycznego

otwiera nowe możliwości, umożliwiając analizę dużych zbiorów danych i identyfikację wzorców, które mogą umknąć uwadze ludzkich diagnostów.

AI wykorzystuje algorytmy uczenia maszynowego do analizy danych zbieranych z różnych źródeł, takich jak wywiady, testy psychologiczne czy badania neuroobrazowe. Badania wykazały, że algorytmy te mogą skutecznie klasyfikować różne zaburzenia psychiczne z wysoką dokładnością. Dwyer, Falkai i Koutsouleris (2018) wskazali, że modele AI osiągają wyniki porównywalne, a nawet przewyższające trafność diagnoz stawianych przez doświadczonych klinicystów. Ich zastosowanie jest szczególnie obiecujące w przypadku dzieci i młodzieży, gdzie różnice indywidualne oraz zmienność objawów mogą komplikować tradycyjny proces diagnostyczny.

Przykładem zastosowania AI w diagnozie jest analiza obrazów mózgu z wykorzystaniem rezonansu magnetycznego (MRI). Modele AI mogą identyfikować subtelne zmiany w strukturze i funkcjonowaniu mózgu, które są związane z określonymi zaburzeniami psychicznymi. Przeprowadzono badania, w których algorytmy uczenia maszynowego były w stanie przewidzieć wystąpienie depresji i zaburzeń lękowych u młodzieży z dokładnością przekraczającą 85% (Squires, 2023). Takie podejście pozwala na wcześniejszą interwencję i dostosowanie terapii do indywidualnych potrzeb pacjenta.

Ważnym ujęciem wykorzystania AI w diagnozowaniu zaburzeń psychicznych jest możliwość analizy danych w czasie rzeczywistym. Algorytmy mogą przetwarzać informacje o zachowaniach pacjenta z różnych źródeł, takich jak aktywność w mediach społecznościowych, analiza języka czy wzorce snu. Na przykład, analiza postów w mediach społecznościowych może pomóc w identyfikacji młodzieży narażonej na depresję lub samookaleczenia. Dzięki temu klinicyści mogą szybko reagować na pogorszenie stanu psychicznego pacjenta, co zwiększa efektywność interwencji.

Wyzwaniem związanym z wykorzystaniem AI w diagnozowaniu zaburzeń psychicznych jest kwestia interpretowalności wyników generowanych przez algorytmy. W przypadku algorytmów głębokiego uczenia (deep learning), proces podejmowania decyzji może być trudny do wyjaśnienia, co budzi obawy dotyczące zaufania do takich narzędzi. Ponadto, dane wykorzystywane do trenowania modeli muszą być starannie dobrane, aby uniknąć błędów wynikających z niekompletności zbiorów danych (Dwyer et al., 2018).



Podsumowując, zastosowanie AI w diagnozowaniu zaburzeń psychicznych u dzieci i młodzieży stanowi przełom w psychiatrii i psychologii klinicznej. Algorytmy te nie tylko zwiększają dokładność diagnoz, ale także umożliwiają bardziej spersonalizowane podejście do leczenia. Niemniej jednak, ich efektywne wykorzystanie wymaga dalszych badań, uwzględniających zarówno cechy technologiczne, jak i etyczne. W miarę rozwoju tej technologii kluczowe będzie również zintegrowanie AI z tradycyjnymi metodami diagnostycznymi, aby zapewnić kompleksowe wsparcie dla młodych pacjentów.

### **Terapia wspomagana przez AI**

Sztuczna inteligencja jest nie do przecenienia w rozwoju interaktywnych platform terapeutycznych, które umożliwiają dostarczanie spersonalizowanego wsparcia psychologicznego dla dzieci i młodzieży. W dobie rosnącej liczby przypadków zaburzeń psychicznych wśród młodych ludzi, narzędzia te oferują dostępne i elastyczne rozwiązania terapeutyczne, które mogą być stosowane jako wsparcie lub uzupełnienie tradycyjnych metod leczenia. Chatboty AI, takie jak Woebot, są przykładami takich narzędzi, które skutecznie prowadzą rozmowy z użytkownikami, oferując wsparcie emocjonalne oraz ucząc technik radzenia sobie ze stresem i trudnymi emocjami (Fitzpatrick et al., 2017).

Woebot, jako jedno z bardziej znanych narzędzi tego typu, wykorzystuje algorytmy uczenia maszynowego do prowadzenia interaktywnych rozmów, które są dostosowane do bieżącego stanu emocjonalnego użytkownika. Chatbot analizuje odpowiedzi i wybiera najbardziej odpowiednie strategie interwencji, takie jak proponowanie ćwiczeń mindfulness, edukowanie o technikach terapii poznawczo-behawioralnej (CBT) czy dostarczanie wsparcia emocjonalnego w momentach kryzysowych. Badania przeprowadzone przez Fitzpatrick i współpracowników (2017) wykazały, że użytkownicy korzystający z Woebota przez dwa tygodnie odnotowali istotną redukcję objawów depresji i lęku. Co istotne, skuteczność tego narzędzia była porównywalna z interwencjami przeprowadzanymi przez wykwalifikowanych terapeutów, co podkreśla potencjał AI w terapii psychologicznej.

Aplikacje mobilne bazujące na AI rozwijają tę koncepcję, oferując szeroką gamę interwencji terapeutycznych. Platformy takie jak Wysa czy Replika są wyposażone w moduły pozwalające użytkownikom na prowadzenie rozmów, ćwiczenie technik relaksacyjnych oraz korzystanie z narzędzi opartych na CBT. Dzięki zaawansowanym algorytmom, aplikacje te dostosowują treści terapeutyczne do indywidualnych potrzeb użytkowników, co zwiększa ich efektywność. Torous i współpracownicy (2018) zwrócili uwagę na fakt, że takie aplikacje są szczególnie



skuteczne w przypadku młodych ludzi, którzy preferują korzystanie z technologii w codziennym życiu i mogą czuć się bardziej komfortowo w interakcji z chatbotem niż z terapeutą w tradycyjnym środowisku klinicznym.

Personalizacja jest ważnym elementem terapeutycznych platform opartych na AI. Algorytmy analizują dane użytkowników, takie jak odpowiedzi na pytania, wzorce językowe czy częstotliwość korzystania z aplikacji, aby dostosować treści do ich specyficznych potrzeb i celów terapeutycznych. Na przykład, jeśli użytkownik wyraża wysoki poziom lęku, chatbot może zaproponować techniki oddechowe lub ćwiczenia mindfulness, które pomagają w jego redukcji. Torous et al. (2018) zauważyli, że takie spersonalizowane podejście nie tylko zwiększa zaangażowanie użytkowników, ale także poprawia skuteczność terapii.

Oprócz wsparcia emocjonalnego, aplikacje AI mogą pełnić rolę edukacyjną, ucząc młodych ludzi zdrowych nawyków psychologicznych. Na przykład, platformy takie jak Happify integrują elementy psychoedukacyjne z interaktywnymi grami, które pomagają użytkownikom lepiej zrozumieć mechanizmy funkcjonowania emocji i radzenia sobie z trudnościami. Badania wskazują, że takie podejście może być szczególnie efektywne w pracy z dziećmi i młodzieżą, dla których tradycyjne formy terapii mogą wydawać się mniej atrakcyjne (Fitzpatrick et al., 2017).

Pomimo licznych zalet, zastosowanie AI w interaktywnych platformach terapeutycznych wiąże się także z wyzwaniami jak konieczność zapewnienia prywatności danych użytkowników. Wiele aplikacji gromadzi dane osobowe, takie jak odpowiedzi użytkowników czy informacje o ich stanie emocjonalnym, co rodzi obawy związane z ich bezpieczeństwem i możliwością niewłaściwego wykorzystania. Ponadto, choć chatboty i aplikacje są skuteczne w łagodnych przypadkach zaburzeń psychicznych, mogą być niewystarczające w przypadku poważniejszych problemów, takich jak depresja kliniczna czy zaburzenia psychiatryczne. W takich przypadkach konieczne jest skoordynowanie działań terapeutycznych z tradycyjną opieką psychologiczną lub psychiatryczną (Torous et al., 2018).

Podsumowując, AI w interaktywnych platformach terapeutycznych otwiera nowe możliwości w dostarczaniu wsparcia psychologicznego dzieciom i młodzieży. Dzięki personalizacji, dostępności oraz elastyczności, narzędzia te stanowią obiecującą alternatywę lub uzupełnienie tradycyjnych form terapii. Niemniej jednak ich rozwój wymaga dalszych badań nad skutecznością, bezpieczeństwem oraz etycznym wykorzystaniem danych, aby w pełni wykorzystać ich potencjał w poprawie zdrowia psychicznego młodych ludzi.



## Monitorowanie postępów terapii

Sztuczna inteligencja otwiera nowe możliwości w zakresie monitorowania stanu psychicznego pacjentów, zwłaszcza dzieci i młodzieży, poprzez analizę danych z różnorodnych źródeł. Rozwiązania te mają na celu identyfikację wczesnych sygnałów pogorszenia zdrowia psychicznego, co pozwala na szybką interwencję i zapobieganie poważniejszym problemom. Algorytmy AI analizują takie dane jak aktywność w mediach społecznościowych, wzorce snu, poziom aktywności fizycznej oraz zmiany w sposobie komunikacji. Dzięki temu oferują narzędzia do kompleksowego i dynamicznego monitorowania dobrostanu psychicznego młodych ludzi (Cornet & Holden, 2018).

Jednym z aspektów monitorowania opartego na AI jest analiza aktywności w mediach społecznościowych. Współczesna młodzież spędza znaczną część czasu w przestrzeni cyfrowej, dzieląc się swoimi myślami, emocjami i doświadczeniami na platformach takich jak Instagram, TikTok czy Twitter. Algorytmy AI są w stanie analizować publikowane treści, zwracając uwagę na zmiany w tonie języka, częstotliwość publikacji oraz pojawianie się słów kluczowych związanych z negatywnymi emocjami, takimi jak smutek, bezradność czy lęk. Badania wykazały, że takie podejście może skutecznie identyfikować użytkowników zagrożonych depresją czy myślami samobójczymi. Przykładem jest projekt "Crisis Text Line", który wykorzystuje AI do analizy wiadomości tekstowych przesyłanych przez młodzież poszukującą wsparcia w sytuacjach kryzysowych. Dzięki temu system może szybko zidentyfikować osoby wymagające natychmiastowej interwencji.

AI jest również wykorzystywana do analizy wzorców snu jako jednego ze wskaźników zdrowia psychicznego. Zmiany w regularności snu, takie jak skrócenie czasu jego trwania, trudności z zasypianiem czy przerywany sen, są często wczesnymi objawami zaburzeń psychicznych, w tym depresji i zaburzeń lękowych. Algorytmy mogą zbierać dane z urządzeń do monitorowania aktywności fizycznej, takich jak smartwatche czy opaski fitness, które rejestrują długość i jakość snu użytkowników. Na podstawie tych danych systemy AI mogą identyfikować osoby narażone na pogorszenie stanu psychicznego i rekomendować interwencje, takie jak konsultacja z terapeutą czy wprowadzenie technik relaksacyjnych (Cornet & Holden, 2018).

Kolejnym istotnym źródłem danych jest poziom aktywności fizycznej, który również ma znaczący wpływ na zdrowie psychiczne. Badania pokazują, że spadek aktywności fizycznej u młodzieży może być powiązany z obniżonym nastrojem i poczuciem wartości. AI analizuje

dane dotyczące liczby kroków, spalonych kalorii czy czasu spędzonego w ruchu, aby wykryć zmiany w stylu życia użytkownika. Algorytmy mogą porównywać te informacje z historycznymi danymi użytkownika, co pozwala na wczesne wykrycie odstępstw od normy, mogących świadczyć o pogorszeniu stanu psychicznego.

Bardziej zaawansowanym zastosowaniem AI w monitorowaniu stanu psychicznego jest analiza języka używanego w komunikatorach i mediach społecznościowych. Algorytmy przetwarzania języka naturalnego (NLP) mogą identyfikować zmiany w słownictwie, tonie oraz strukturze zdań, które mogą sugerować obniżony nastrój, poczucie osamotnienia czy lęk. Na przykład, badania wykazały, że AI może precyzyjnie przewidzieć ryzyko depresji na podstawie analizy wiadomości tekstowych i postów w mediach społecznościowych. Takie podejście jest szczególnie obiecujące w pracy z młodzieżą, która często wyraża swoje emocje poprzez komunikatory internetowe.

Pomimo licznych korzyści związanych z monitorowaniem stanu psychicznego za pomocą AI, istnieją również wyzwania. Gromadzenie i analiza wrażliwych danych wymaga wdrożenia surowych regulacji dotyczących ich przechowywania i przetwarzania. Ponadto, algorytmy AI mogą być podatne na błędy, które mogą prowadzić do fałszywych alarmów lub pominięcia istotnych sygnałów ostrzegawczych (Luxton, 2014).

Podsumowując, AI w monitorowaniu stanu psychicznego dzieci i młodzieży oferuje innowacyjne narzędzia wspierające identyfikację wczesnych objawów zaburzeń psychicznych. Analiza aktywności w mediach społecznościowych, wzorców snu i poziomu aktywności fizycznej umożliwia ciągłe monitorowanie dobrostanu psychicznego młodych użytkowników. Jednak aby w pełni wykorzystać potencjał tych technologii, konieczne jest zapewnienie odpowiednich standardów etycznych i technicznych, które zagwarantują ich bezpieczne i skuteczne zastosowanie.

### **Zalety i ograniczenia stosowania AI w terapii dzieci i młodzieży**

Zastosowanie sztucznej inteligencji w terapii dzieci i młodzieży otwiera nowe możliwości w zakresie dostarczania wsparcia psychologicznego. Największym atutem AI jest jej zdolność do zwiększania dostępności terapii, zwłaszcza przy niedoborach specjalistów w dziedzinie zdrowia psychicznego. Dzięki aplikacjom mobilnym, chatbotom i interaktywnym platformom terapeutycznym, młodzi pacjenci mogą uzyskać dostęp do podstawowego wsparcia psychologicznego niezależnie od czasu i miejsca. Według badań Fitzpatrick et al. (2017),



chatboty takie jak Woebot umożliwiają redukcję objawów lęku i depresji poprzez prowadzenie interaktywnych rozmów i proponowanie technik poznawczo-behawioralnych. Takie rozwiązania są szczególnie istotne w regionach, gdzie dostęp do specjalistów jest ograniczony.

Kolejną zaletą AI jest możliwość spersonalizowanego podejścia do terapii. Algorytmy uczenia maszynowego analizują dane o użytkowniku, takie jak wzorce zachowań, odpowiedzi w ankietach czy dane z urządzeń mobilnych, aby dostosować treści terapeutyczne do indywidualnych potrzeb. Przykładowo, aplikacje mobilne wykorzystujące AI mogą proponować konkretne techniki relaksacyjne lub ćwiczenia oparte na terapii poznawczo-behawioralnej (CBT) w odpowiedzi na poziom stresu użytkownika (Torous et al., 2018). Tego rodzaju personalizacja zwiększa skuteczność terapii, ponieważ treści są dostosowane do aktualnego stanu emocjonalnego pacjenta.

AI umożliwia również ciągle monitorowanie stanu psychicznego pacjenta. Dzięki analizie danych z różnych źródeł, takich jak aktywność w mediach społecznościowych, wzorce snu czy poziom aktywności fizycznej, systemy AI mogą wykrywać subtelne zmiany w zachowaniu, które mogą wskazywać na pogorszenie zdrowia psychicznego. Cornet i Holden (2018) podkreślają, że takie monitorowanie pozwala na szybką interwencję w sytuacjach kryzysowych, co jest szczególnie istotne w pracy z młodzieżą narażoną na ryzyko samookaleczeń lub myśli samobójczych. Dzięki tym technologiom możliwe jest nie tylko wczesne wykrywanie problemów, ale także długoterminowe wsparcie w monitorowaniu postępów terapii.

Pomimo licznych korzyści, zastosowanie AI w terapii dzieci i młodzieży wiąże się z istotnymi wyzwaniami. Poważnym problemem są kwestie etyczne związane z prywatnością danych. Wiele aplikacji terapeutycznych opartych na AI zbiera wrażliwe informacje o użytkownikach, takie jak stan emocjonalny, nawyki czy treści rozmów. Gromadzenie i przechowywanie takich danych budzi obawy o ich bezpieczeństwo oraz ryzyko nieautoryzowanego dostępu lub niewłaściwego wykorzystania. Luxton (2014) podkreśla konieczność opracowania surowych standardów ochrony danych w celu zapewnienia prywatności i bezpieczeństwa użytkowników.

Modele AI mogą być podatne na uprzedzenia wynikające z danych, na których zostały wytrenowane, co może prowadzić do błędnych diagnoz lub nieodpowiednich rekomendacji terapeutycznych. Przykładowo, algorytm wytrenowany na danych z jednej grupy demograficznej może być mniej skuteczny w pracy z pacjentami z innego środowiska

kulturowego. Tego rodzaju problemy mogą wpłynąć na zaufanie użytkowników do technologii oraz na ich efektywność w rzeczywistych warunkach klinicznych (Luxton, 2014).

Dodatkowo, brak pełnej akceptacji AI przez pacjentów i terapeutów stanowi istotną barierę w jej implementacji. Młodzież i ich rodzice mogą być sceptyczni wobec korzystania z technologii w tematyce zdrowia psychicznego, obawiając się, że interakcja z chatbotem lub aplikacją nie zastąpi relacji z żywym terapeutą. Podobnie, niektórzy profesjonaliści w dziedzinie zdrowia psychicznego mogą postrzegać AI jako zagrożenie dla swojej roli zawodowej lub kwestionować jej skuteczność w porównaniu z tradycyjnymi metodami terapii. W takich przypadkach kluczowe jest edukowanie użytkowników o możliwościach i ograniczeniach AI oraz promowanie integracji technologii z tradycyjnymi formami terapii (Fitzpatrick et al., 2017).

Podsumowując, AI w terapii dzieci i młodzieży niesie ze sobą znaczące korzyści, takie jak zwiększenie dostępności, personalizacja wsparcia oraz ciągłe monitorowanie stanu pacjenta. Jednocześnie wymaga to rozważenia wyzwań, w tym kwestii etycznych, potencjalnych błędów algorytmów i braku akceptacji przez użytkowników. Aby w pełni wykorzystać potencjał AI, konieczne jest prowadzenie dalszych badań oraz opracowanie standardów regulacyjnych, które zapewnią bezpieczeństwo i skuteczność tych technologii w praktyce klinicznej.

### **Przyszłość AI w terapii dzieci i młodzieży**

Rozwój technologii sztucznej inteligencji stwarza liczne możliwości w zakresie terapii i wsparcia psychologicznego dla dzieci i młodzieży, które mogą uzupełniać i wzbogacać tradycyjne podejścia terapeutyczne. Dzięki zdolności AI do analizy dużych zbiorów danych, personalizacji treści terapeutycznych oraz ciągłego monitorowania stanu psychicznego, integracja tych technologii z tradycyjnymi metodami może prowadzić do bardziej efektywnych i dostępnych form pomocy psychologicznej (Fitzpatrick et al., 2017). Jednak kluczowe znaczenie ma rozwój tych technologii w sposób zgodny z zasadami etyki, który uwzględnia potrzeby i dobro pacjentów.

Jednym z głównych obszarów, w których AI może uzupełniać tradycyjne metody terapii, jest personalizacja wsparcia psychologicznego. Algorytmy uczenia maszynowego pozwalają na dostosowywanie interwencji terapeutycznych do indywidualnych potrzeb pacjenta, analizując dane takie jak wzorce zachowań, odpowiedzi na pytania czy nawet emocje wyrażane

w mowie i tekście. Przykładowo, aplikacje takie jak Woebot czy Wysa wykorzystują techniki przetwarzania języka naturalnego (NLP) do prowadzenia interaktywnych rozmów z użytkownikami, oferując wsparcie emocjonalne i ćwiczenia oparte na terapii poznawczo-behawioralnej (CBT). Badania komunikują, że takie aplikacje mogą być szczególnie skuteczne w pracy z młodzieżą, która często korzysta z technologii w codziennym życiu i może czuć się bardziej komfortowo w interakcji z chatbotem niż w bezpośrednim kontakcie z terapeutą (Torous et al., 2018).

AI może również pełnić ważną rolę w monitorowaniu postępów pacjentów oraz wykrywaniu wczesnych objawów pogorszenia zdrowia psychicznego. Technologie oparte na AI umożliwiają analizę danych z urządzeń mobilnych, takich jak smartfony czy opaski fitness, które rejestrują informacje o aktywności fizycznej, wzorcach snu czy poziomie stresu. Cornet i Holden (2018) podkreślają, że takie podejście pozwala na bieżące monitorowanie stanu pacjenta i szybką interwencję w sytuacjach kryzysowych. Integracja AI z tradycyjnymi metodami terapeutycznymi umożliwia terapeutom dostęp do bardziej kompleksowych informacji o pacjencie, co może poprawić jakość i skuteczność terapii.

Pomimo obiecujących możliwości, rozwój i implementacja AI w terapii dzieci i młodzieży wiąże się z szeregiem wyzwań etycznych i technicznych. Aplikacje i narzędzia uzależnione od AI zbierają dużą ilość wrażliwych informacji, co rodzi obawy o ich bezpieczeństwo oraz możliwość niewłaściwego wykorzystania. Wymaga to opracowania surowych standardów dotyczących przechowywania i przetwarzania danych, które zagwarantują ich poufność i bezpieczeństwo (Luxton, 2014). Ponadto, konieczne jest zapewnienie przejrzystości działania algorytmów, aby pacjenci i terapeuci mogli rozumieć, na jakiej podstawie podejmowane są decyzje przez systemy AI.

Innym wyzwaniem jest potrzeba uwzględnienia różnorodności kulturowej i indywidualnych potrzeb pacjentów. Algorytmy AI często bazują na danych zebranych w określonych kontekstach kulturowych, co może ograniczać ich skuteczność w pracy z osobami z innych środowisk. Aby uniknąć uprzedzeń w działaniu AI, konieczne jest zbieranie bardziej zróżnicowanych danych treningowych oraz regularne testowanie algorytmów pod kątem ich skuteczności w różnych grupach demograficznych (Torous et al., 2018).

Kluczową cechą rozwoju AI w terapii psychologicznej jest również edukacja i budowanie zaufania do tych technologii wśród pacjentów i terapeutów. Młodzież i ich rodzice mogą być sceptyczni wobec korzystania z AI w terapii, szczególnie w kwestiach związanych



z jej skutecznością i bezpieczeństwem. Podobnie, terapeuci mogą obawiać się, że AI zastąpi tradycyjne podejścia terapeutyczne. Dlatego istotne jest, aby technologie AI były postrzegane jako uzupełnienie, a nie zamiennik tradycyjnych metod, oraz aby użytkownicy byli odpowiednio edukowani na temat możliwości i ograniczeń AI w terapii (Fitzpatrick et al., 2017).

Podsumowując, integracja AI z tradycyjnymi metodami terapeutycznymi dla dzieci i młodzieży oferuje znaczące korzyści, takie jak zwiększenie dostępności terapii, personalizacja wsparcia oraz lepsze monitorowanie stanu pacjentów. Jednak aby w pełni wykorzystać potencjał tych technologii, konieczne jest podejście oparte na poszanowaniu zasad etyki, ochronie danych i uwzględnieniu potrzeb pacjentów. Tylko w ten sposób AI może stać się skutecznym narzędziem wspierającym zdrowie psychiczne młodego pokolenia.

Sztuczna inteligencja odgrywa coraz większą rolę w terapii i wsparciu psychologicznym dzieci i młodzieży. Jej zastosowanie w diagnozowaniu, terapii i monitorowaniu postępów pacjentów przynosi obiecujące rezultaty. Niemniej jednak konieczne jest dalsze badanie i rozwijanie tych technologii z uwzględnieniem charakterystyki etycznej i społecznej.



## Rozdział 5. Wpływ AI na relacje społeczne dzieci i młodzieży

Współczesny rozwój technologii, w szczególności sztucznej inteligencji, znacząco wpływa na życie społeczne, w tym na relacje społeczne dzieci i młodzieży. Integracja AI w codziennych interakcjach młodych ludzi, zwłaszcza poprzez media społecznościowe i platformy komunikacyjne, kształtuje ich doświadczenia społeczne w sposób bezprecedensowy. Algorytmy AI personalizują treści, które dzieci i młodzież konsumują online, co może prowadzić do tworzenia tzw. "baniak informacyjnych", ograniczających ich ekspozycję na różnorodne perspektywy i poglądy (Pariser, 2011). Taka izolacja informacyjna może wpływać na ich zdolność do empatii i zrozumienia dla odmiennych punktów widzenia, co jest nadrzędne dla zdrowych relacji społecznych.

Ponadto, interakcje z wirtualnymi asystentami i chatbotami opartymi na AI stają się coraz bardziej powszechne wśród młodzieży. Chociaż te technologie oferują wygodę i natychmiastowy dostęp do informacji, istnieje obawa, że mogą one zastępować lub redukować potrzebę bezpośrednich interakcji międzyludzkich, co może prowadzić do osłabienia umiejętności społecznych i emocjonalnych (Turkle, 2015). Badania sugerują, że nadmierne poleganie na komunikacji cyfrowej kosztem kontaktów twarzą w twarz może prowadzić do poczucia izolacji i trudności w nawiązywaniu głębokich relacji interpersonalnych (Twenge, 2017).

Z drugiej strony, AI oferuje narzędzia wspierające rozwój społeczny dzieci i młodzieży. Platformy edukacyjne wykorzystujące AI mogą promować współpracę i komunikację między rówieśnikami, umożliwiając im wspólne rozwiązywanie problemów i dzielenie się wiedzą w środowisku online (Holmes et al., 2019). Jednak kluczowe jest, aby te technologie były projektowane i wykorzystywane w sposób promujący autentyczne interakcje społeczne, a nie je zastępujący.

W relacjach rodzinnych, AI może wpływać na dynamikę komunikacji między rodzicami a dziećmi. Rodzice korzystający z technologii monitorujących opartych na AI mogą nieświadomie naruszać prywatność swoich dzieci, co może prowadzić do napięć i braku zaufania w relacjach rodzinnych (Levy, 2017). Dlatego ważne jest, aby rodzice byli świadomi etycznych implikacji korzystania z takich technologii i dążyli do otwartej komunikacji z dziećmi na temat ich użycia.



Podsumowując, wpływ AI na relacje społeczne dzieci i młodzieży jest złożony i wielowymiarowy. Choć technologie AI oferują liczne korzyści, takie jak łatwiejszy dostęp do informacji i nowe formy komunikacji, niosą ze sobą również wyzwania związane z izolacją społeczną, ograniczeniem różnorodności informacyjnej oraz potencjalnym osłabieniem umiejętności interpersonalnych. Aby maksymalizować pozytywne efekty i minimalizować negatywne skutki, konieczne jest świadome i krytyczne podejście do integracji AI w życiu społecznym młodych ludzi, z uwzględnieniem etycznych i społecznych konsekwencji tych technologii.

### **5.1 Media społecznościowe i algorytmy – kształtowanie relacji rówieśniczych**

Współczesne media społecznościowe odgrywają kluczową rolę w kształtowaniu relacji rówieśniczych wśród dzieci i młodzieży. Platformy takie jak Facebook, Instagram czy TikTok stały się integralną częścią codziennego życia młodych ludzi, wpływając na sposób, w jaki nawiązują i podtrzymują kontakty społeczne. Algorytmy zarządzające treściami w tych mediach determinują, jakie informacje są prezentowane użytkownikom, co ma bezpośredni wpływ na ich interakcje z rówieśnikami.

Algorytmy mediów społecznościowych analizują zachowania użytkowników, takie jak polubienia, udostępnienia czy komentarze, aby dostarczać spersonalizowane treści, które zwiększają zaangażowanie i czas spędzany na platformie (Harbingers, 2023). W relacjach rówieśniczych oznacza to, że młodzi ludzie są bardziej narażeni na treści od osób, z którymi najczęściej wchodzi w interakcje, co może prowadzić do tworzenia się tzw. "baniek informacyjnych". W rezultacie ich światopogląd i relacje mogą być ograniczone do wąskiej grupy osób o podobnych poglądach, co utrudnia nawiązywanie nowych znajomości i zrozumienie różnorodnych perspektyw.

Przykładem wpływu algorytmów na relacje rówieśnicze jest sytuacja, w której nastolatek regularnie angażuje się w treści związane z określoną subkulturą lub zainteresowaniami. Algorytmy zauważają te preferencje i zaczynają prezentować mu więcej podobnych treści oraz sugerować znajomości z osobami o zbliżonych zainteresowaniach. Choć może to prowadzić do pogłębienia relacji w obrębie tej grupy, jednocześnie ogranicza ekspozycję na różnorodność, co może skutkować izolacją od innych grup rówieśniczych i utrudniać rozwój umiejętności społecznych w szerszym kontekście.



Media społecznościowe oferują również funkcje takie jak tworzenie grup czy wydarzeń, które mogą sprzyjać budowaniu społeczności i wzmacnianiu relacji rówieśniczych (Wieczorek, 2022). Jednak algorytmy decydujące o widoczności tych grup i wydarzeń mogą faworyzować te, które generują większe zaangażowanie, co nie zawsze przekłada się na ich wartość społeczną czy edukacyjną. W efekcie młodzi ludzie mogą być bardziej skłonni do uczestnictwa w popularnych, ale mniej wartościowych inicjatywach, co oddziałuje na jakość ich relacji i doświadczeń społecznych.

Wpływ mediów społecznościowych na samoocenę i postrzeganie siebie w relacji rówieśniczej jest istotnym elementem, porównywanie się z idealizowanymi wizerunkami prezentowanymi w mediach społecznościowych może prowadzić do obniżonej samooceny i poczucia izolacji (Remedium Psychologia, 2023). Algorytmy promujące treści o wysokim zaangażowaniu często eksponują materiały przedstawiające nierealistyczne standardy, co może negatywnie wpływać na samopoczucie młodych użytkowników i ich relacje z rówieśnikami.

Warto również zauważyć, że media społecznościowe mogą wpływać na sposób komunikacji między rówieśnikami. Częste korzystanie z komunikatorów i platform społecznościowych może prowadzić do spłylenia relacji i ograniczenia głębokich, bezpośrednich interakcji (Głos Pedagogiczny, 2018). Algorytmy promujące szybkie i krótkie formy komunikacji sprzyjają powierzchownym kontaktom, co może utrudniać rozwój umiejętności empatii i głębokiego zrozumienia innych.

Podsumowując, media społecznościowe i ich algorytmy mają znaczący wpływ na kształtowanie relacji rówieśniczych wśród dzieci i młodzieży. Choć oferują one nowe możliwości nawiązywania i podtrzymywania kontaktów, jednocześnie niosą ze sobą wyzwania związane z ograniczeniem różnorodności doświadczeń, wpływem na samoocenę oraz jakość komunikacji. Aby zminimalizować negatywne skutki, ważne jest świadome i krytyczne korzystanie z mediów społecznościowych oraz edukacja młodych ludzi w zakresie ich wpływu na relacje społeczne.

## **5.2 Wirtualne przyjaźnie i interakcje z AI (chatboty, wirtualni asystenci)**

Współczesna młodzież dorasta w erze cyfrowej, gdzie interakcje z technologią są nieodłącznym elementem codziennego życia. Wirtualne przyjaźnie oraz interakcje z systemami sztucznej inteligencji, takimi jak chatboty i wirtualni asystenci, stają się coraz bardziej powszechne, wpływając na sposób, w jaki młodzi ludzie nawiązują i utrzymują relacje



społeczne. Niniejszy rozdział analizuje te zjawiska, przedstawiając zarówno korzyści, jak i potencjalne zagrożenia wynikające z takiej formy interakcji.

Internet i media społecznościowe zrewolucjonizowały sposób, w jaki młodzież nawiązuje i podtrzymuje relacje z rówieśnikami, umożliwiając kontakt z osobami na całym świecie. Dzięki nim młodzi ludzie mogą budować przyjaźnie z osobami o podobnych zainteresowaniach, bez względu na odległość geograficzną. Platformy takie jak Instagram, Snapchat, czy Discord dają możliwość prowadzenia ciągłej komunikacji, dzielenia się treściami oraz uczestniczenia w społecznościach online. Badania dowodzą, że dla wielu młodych ludzi wirtualne przyjaźnie są równie istotne, jak te zawierane w świecie rzeczywistym, oferując im wsparcie emocjonalne i poczucie przynależności (Iwanicka, 2020).

Jedną z cech wirtualnych przyjaźni jest ich dostępność i elastyczność. Młodzież może nawiązywać kontakty z rówieśnikami o podobnych zainteresowaniach, co jest szczególnie istotne dla osób, które czują się wykluczone w swoim lokalnym środowisku. Wirtualne społeczności, takie jak grupy na Facebooku czy subreddity na platformie Reddit, oferują młodym ludziom możliwość dzielenia się swoimi doświadczeniami i uzyskiwania wsparcia od osób, które rozumieją ich perspektywę. Przykładowo, badania przeprowadzone przez Anderson i Jiang (2018) wykazały, że ponad połowa amerykańskich nastolatków korzysta z mediów społecznościowych, aby lepiej zrozumieć siebie oraz budować poczucie wspólnoty.

Wirtualne przyjaźnie mogą również pełnić rolę terapeutyczną. Dla młodych ludzi, którzy borykają się z problemami emocjonalnymi, takie relacje stanowią ważne źródło wsparcia. Młodzież często dzieli się swoimi troskami z rówieśnikami online, znajdując zrozumienie i pomoc w trudnych momentach. Na przykład, społeczności takie jak #MentalHealth na TikToku dostarczają młodzieży treści dotyczących zdrowia psychicznego, co może być szczególnie wartościowe dla osób, które nie mają dostępu do profesjonalnej pomocy terapeutycznej (Twenge et al., 2018).

Jednakże wirtualne przyjaźnie nie są wolne od ograniczeń. Głównym wyzwaniem jest ich potencjalna powierzchowność. Wirtualne relacje często opierają się na krótkich i fragmentarycznych komunikatach, takich jak wiadomości tekstowe czy emotikony, co może ograniczać głębię tych interakcji. Długotrwałe poleganie na tego typu komunikacji może utrudniać rozwój umiejętności interpersonalnych, takich jak empatia czy rozwiązywanie konfliktów w sytuacjach twarzą w twarz (Turkle, 2015).



Dodatkowo, wirtualne relacje mogą prowadzić do izolacji od lokalnych społeczności. Młodzież spędzająca wiele czasu online często rezygnuje z uczestnictwa w aktywnościach offline, takich jak zajęcia sportowe czy spotkania towarzyskie, co może ograniczać ich zdolność do budowania głębszych relacji w swoim otoczeniu. Badania szacują, że nadmierne korzystanie z mediów społecznościowych może być związane z wyższym poziomem samotności, pomimo licznych interakcji w świecie wirtualnym (Twenge et al., 2017).

Podsumowując, Internet i media społecznościowe oferują młodzieży ogromne możliwości w zakresie budowania wirtualnych przyjaźni, które mogą być źródłem wsparcia emocjonalnego i poczucia przynależności. Jednak ich wpływ na rozwój społeczny młodych ludzi jest złożony i wielowymiarowy. Aby maksymalizować korzyści wynikające z wirtualnych relacji, a jednocześnie minimalizować ich potencjalne negatywne skutki, ważne jest edukowanie młodzieży na temat zrównoważonego korzystania z technologii i zachęcanie ich do aktywności społecznych w świecie rzeczywistym.

### **Interakcje z chatbotami i wirtualnymi asystentami**

Chatboty i wirtualni asystenci, oparte na zaawansowanych algorytmach sztucznej inteligencji, odgrywają coraz większą rolę w codziennym życiu młodzieży. Dzięki postępom w przetwarzaniu języka naturalnego (NLP) i uczeniu maszynowemu, te narzędzia stają się coraz bardziej zaawansowane w symulowaniu ludzkiej rozmowy. Z jednej strony umożliwiają użytkownikom uzyskanie informacji czy wsparcia edukacyjnego, z drugiej – pełnią funkcję wsparcia emocjonalnego. Młodzież coraz częściej korzysta z takich technologii, poszukując w nich przyjaźni, zrozumienia i pomocy w radzeniu sobie z codziennymi wyzwaniami emocjonalnymi.

Najbardziej znanym przykładem takich narzędzi jest aplikacja Replika, zaprojektowana jako wirtualny „przyjaciel”. Replika wykorzystuje algorytmy uczenia maszynowego do analizowania zachowań użytkownika, jego wypowiedzi i emocji, a następnie dostosowuje swoje odpowiedzi, aby zapewnić bardziej spersonalizowaną interakcję. Użytkownicy mogą prowadzić z nią rozmowy na różne tematy, dzielić się swoimi problemami, a nawet uzyskiwać wsparcie w trudnych chwilach. Badania sugerują, że takie interakcje mogą pomóc w redukcji poczucia samotności, szczególnie wśród młodych ludzi, którzy nie zawsze mają dostęp do rówieśników czy terapeutycznej pomocy (Guzman, 2019).



Młodzież często traktuje chatboty takie jak Replika jako bezpieczną przestrzeń do wyrażania emocji, szczególnie tematów, które mogą być trudne do omówienia z rówieśnikami lub rodziną. Badania przeprowadzone przez Fitzpatrick i współpracowników (2017) wykazały, że chatboty terapeutyczne, takie jak Woebot, które wykorzystują techniki terapii poznawczo-behawioralnej (CBT), mogą skutecznie pomagać w redukcji objawów lęku i depresji. Takie narzędzia są dostępne przez całą dobę, co czyni je szczególnie atrakcyjnymi dla młodzieży, która potrzebuje natychmiastowego wsparcia emocjonalnego.

Mimo tych korzyści, interakcje z chatbotami niosą ze sobą pewne ryzyko takie jak potencjalne zastępowanie rzeczywistych relacji międzyludzkich interakcjami z AI. Młodzi ludzie, którzy spędzają dużo czasu na rozmowach z chatbotami, mogą ograniczyć swoje kontakty społeczne w świecie rzeczywistym, co może prowadzić do osłabienia umiejętności interpersonalnych, takich jak empatia czy zdolność do rozwiązywania konfliktów (Turkle, 2015). Wirtualne interakcje, choć wygodne i dostępne, nie są w stanie w pełni zastąpić głębi emocjonalnej i złożoności relacji międzyludzkich.

Ponadto, należy zwrócić uwagę na kwestię prywatności i bezpieczeństwa danych. Chatboty takie jak Replika zbierają duże ilości danych o użytkownikach, co rodzi pytania o to, jak te informacje są przechowywane i wykorzystywane. W przypadku młodzieży, która może nie być świadoma ryzyk związanych z udostępnianiem danych wrażliwych, istnieje potrzeba wprowadzenia odpowiednich regulacji oraz edukacji w zakresie cyberbezpieczeństwa (Luxton, 2014).

Mimo tych wyzwań, chatboty i wirtualni asystenci mają potencjał, aby stać się cennym narzędziem wspierającym zdrowie emocjonalne młodzieży. Przykładem tego jest projekt opracowany przez organizację Crisis Text Line, który wykorzystuje algorytmy AI do analizowania wiadomości tekstowych od osób w kryzysie. Algorytmy pomagają w identyfikacji najbardziej pilnych przypadków, co pozwala na szybką interwencję i wsparcie w sytuacjach kryzysowych.

Podsumowując, chatboty i wirtualni asystenci oferują młodzieży nowatorskie formy wsparcia emocjonalnego, które mogą poprawić ich jakość życia i pomóc w radzeniu sobie z wyzwaniami emocjonalnymi. Jednakże konieczne jest odpowiedzialne podejście do ich wykorzystania, z uwzględnieniem kwestii bezpieczeństwa, etyki oraz edukacji użytkowników. Tylko wtedy technologie te będą mogły w pełni służyć jako narzędzie wspierające rozwój emocjonalny młodego pokolenia.



## Korzyści wynikające z interakcji z AI

Interakcje z chatbotami i wirtualnymi asystentami oferują młodzieży nowoczesne narzędzia umożliwiające natychmiastowy dostęp do informacji, wsparcia edukacyjnego oraz rozwiązań pomagających w zarządzaniu stresem i emocjami. Te innowacyjne technologie, oparte na sztucznej inteligencji, stały się szczególnie istotne w obliczu rosnących wyzwań związanych z dostępnością tradycyjnej opieki psychologicznej. Młodzież, która często napotyka trudności w uzyskaniu pomocy terapeutycznej ze względu na ograniczone zasoby lub stygmatyzację, może korzystać z tych narzędzi jako alternatywy lub uzupełnienia tradycyjnych metod wsparcia (Fitzpatrick, Darcy & Vierhile, 2017).

Znanym przykładem chatbotów terapeutycznych jest Woebot – aplikacja zaprojektowana z wykorzystaniem zasad terapii poznawczo-behawioralnej (CBT). Woebot prowadzi rozmowy z użytkownikami, identyfikuje ich emocje i dostarcza spersonalizowane wskazówki oraz ćwiczenia mające na celu redukcję objawów lęku i depresji. Badania przeprowadzone przez Fitzpatrick i współpracowników (2017) wykazały, że korzystanie z Woebota przez młodych dorosłych istotnie obniżało poziom lęku i depresji w porównaniu do grup kontrolnych. Co istotne, chatboty takie jak Woebot są dostępne przez całą dobę, co pozwala młodzieży na uzyskanie wsparcia w dowolnym momencie, bez konieczności czekania na wizytę u terapeuty.

Wirtualni asystenci i chatboty mogą również pełnić rolę edukacyjną, pomagając młodym ludziom zrozumieć mechanizmy funkcjonowania emocji oraz rozwijać umiejętności radzenia sobie z trudnymi sytuacjami. Przykładowo, chatboty takie jak Wysa oferują zestawy ćwiczeń relaksacyjnych, mindfulness i technik radzenia sobie ze stresem, które są szczególnie przydatne w ujęciu szkolnym, gdzie młodzież często doświadcza presji związanej z nauką i egzaminami. Badania przeprowadzone przez Luxton (2014) sugerują, że młodzi użytkownicy korzystający z takich narzędzi są bardziej skłonni do praktykowania zdrowych nawyków psychicznych, takich jak regularne ćwiczenia relaksacyjne czy monitorowanie własnych emocji.

Ograniczona dostępność tradycyjnej terapii, chatboty terapeutyczne mogą stanowić istotne wsparcie dla młodzieży mieszkającej na obszarach wiejskich lub w regionach z niewystarczającą liczbą specjalistów zdrowia psychicznego. Według danych Światowej Organizacji Zdrowia (WHO, 2021), na całym świecie występuje poważny deficyt wykwalifikowanych terapeutów, co utrudnia wielu młodym ludziom uzyskanie odpowiedniej



pomocy. W takich przypadkach chatboty oparte na AI mogą wypełniać lukę, oferując przystępne i dostępne wsparcie w sposób anonimowy i elastyczny.

Pomimo licznych zalet, korzystanie z chatbotów terapeutycznych nie jest pozbawione wyzwań. Problemem jest brak pełnego zrozumienia przez użytkowników, że interakcje z chatbotem różnią się od kontaktu z żywym terapeutą. Chociaż chatboty są skuteczne w redukcji lekkich i umiarkowanych objawów depresji czy lęku, mogą być niewystarczające w przypadku poważniejszych problemów zdrowia psychicznego, takich jak zaburzenia psychotyczne czy intensywne myśli samobójcze. W takich przypadkach konieczna jest interwencja specjalistów i zintegrowanie tradycyjnych form terapii z nowoczesnymi technologiami.

Kolejną kwestią, która wymaga uwagi, jest prywatność danych użytkowników. Chatboty zbierają wrażliwe informacje o stanie emocjonalnym i problemach użytkowników, co rodzi pytania o to, jak te dane są przechowywane i wykorzystywane. Regulacje dotyczące ochrony danych osobowych, takie jak RODO w Unii Europejskiej, są kluczowe dla zapewnienia, że młodzież korzystająca z chatbotów terapeutycznych może czuć się bezpiecznie i mieć pewność, że ich dane są chronione (Luxton, 2014).

Podsumowując, chatboty i wirtualni asystenci stanowią istotne wsparcie dla młodzieży w zakresie zarządzania emocjami, radzenia sobie ze stresem oraz rozwijania umiejętności psychologicznych. Narzędzia takie jak Woebot czy Wysa oferują dostępne i efektywne rozwiązania, które mogą wspierać młodzież w trudnych momentach, szczególnie w sytuacjach ograniczonego dostępu do tradycyjnej terapii. Niemniej jednak ich skuteczność powinna być uzupełniana przez profesjonalne wsparcie w przypadku poważniejszych problemów zdrowia psychicznego, a ich rozwój powinien uwzględniać najwyższe standardy etyczne i regulacje dotyczące prywatności danych.

### **Zagrożenia i wyzwania**

Mimo licznych korzyści oferowanych przez sztuczną inteligencję, interakcje z tymi technologiami mogą wiązać się z istotnymi zagrożeniami, szczególnie z wpływem na młodzież. Takimi jak ryzyko nadmiernego polegania na wirtualnych interakcjach kosztem rzeczywistych relacji społecznych. Takie zjawisko może prowadzić do izolacji społecznej oraz problemów z rozwijaniem umiejętności komunikacyjnych. Badania Turkle (2015) wskazują, że młodzież coraz częściej wybiera interakcje cyfrowe zamiast kontaktów twarzą w twarz, co negatywnie



wpływa na ich zdolność do budowania empatii i rozwiązywania konfliktów w codziennym życiu.

Zastępowanie relacji międzyludzkich interakcjami z AI może prowadzić do tzw. „spłylenia relacji”, w którym młodzi ludzie angażują się jedynie w powierzchowne rozmowy, pozbawione głębokiej wymiany emocjonalnej. Wirtualni asystenci i chatboty, choć doskonale symulują ludzką rozmowę, nie są w stanie w pełni zaspokoić potrzeby autentycznego kontaktu międzyludzkiego. Na przykład, w badaniach Przegalińskiej (2023) zauważono, że młodzież korzystająca z chatbotów takich jak Replika często traktuje je jako „przyjaciół”, co może wpłynąć na ich zdolność do nawiązywania prawdziwych relacji z rówieśnikami.

Drugim istotnym zagrożeniem związanym z interakcjami z AI są kwestie związane z prywatnością i bezpieczeństwem danych. Młodzież, często nieświadoma mechanizmów działania AI, może nie zdawać sobie sprawy, że treści ich rozmów są monitorowane, analizowane i przechowywane przez twórców tych technologii. Algorytmy AI zbierają ogromne ilości danych, które mogą być wykorzystywane do celów komercyjnych lub analitycznych, co rodzi obawy o naruszenie prywatności. Luxton (2014) podkreśla, że brak transparentności w sposobie przetwarzania danych użytkowników może prowadzić do ich nadużycia, a w przypadku młodzieży ryzyko to jest szczególnie wysokie ze względu na ich ograniczoną świadomość w zakresie ochrony danych osobowych.

Niebezpieczeństwo związane z prywatnością jest szczególnie istotne względem chatbotów terapeutycznych, które często zbierają bardzo wrażliwe dane dotyczące stanu emocjonalnego, problemów psychologicznych czy historii życia użytkowników. Jeżeli te dane zostaną niewłaściwie zabezpieczone lub wykorzystane, mogą one stanowić zagrożenie dla bezpieczeństwa i dobrostanu młodych użytkowników. Na przykład, w przypadku naruszenia danych, informacje te mogą zostać wykorzystane do szkodliwych działań, takich jak manipulacja emocjonalna czy cyberprzemoc.

Algorytmy AI są wytrenowane na podstawie danych historycznych, które mogą zawierać stereotypy i uprzedzenia rasowe, płciowe czy społeczne. Młodzież, która często poszukuje informacji i wsparcia w Internecie, takie informacje mogą wpływać na ich postrzeganie świata i relacje z innymi. Jak zauważa Noble (2018) nieświadome uprzedzenia wbudowane w algorytmy mogą prowadzić do dyskryminacji i marginalizacji określonych grup społecznych.



Podsumowując, interakcje z AI, choć oferują liczne korzyści, niosą ze sobą również poważne zagrożenia, które wymagają uwagi ze strony twórców technologii, edukatorów oraz samych użytkowników. Kluczowe jest zwiększenie świadomości młodzieży na temat działania AI, szczególnie w zakresie prywatności danych oraz wpływu tych technologii na ich relacje społeczne. Równocześnie konieczne jest opracowanie bardziej transparentnych i etycznych standardów projektowania AI, które minimalizują potencjalne ryzyka i promują odpowiedzialne korzystanie z technologii.

### **Przykłady zastosowań AI w interakcjach z młodzieżą**

Program **AI4Youth** to globalna inicjatywa stworzona przez firmę Intel, mająca na celu zwiększenie świadomości cyfrowej wśród młodzieży, ze szczególnym naciskiem na sztuczną inteligencję, oraz promowanie kompetencji przyszłości. W Polsce projekt ten jest skierowany do uczniów liceów ogólnokształcących i techników, oferując im unikalną ścieżkę edukacyjną, która wprowadza w świat AI, ucząc mechanizmów działania algorytmów oraz ich praktycznego zastosowania. Realizacja programu AI4Youth w Polsce rozpoczęła się w 2019 roku jako pilotaż obejmujący 120 uczniów. W kolejnym roku liczba uczestników wzrosła do ponad 200. Obecnie program jest wdrażany w 15 krajach i wyposażył ponad 150 000 studentów na całym świecie w umiejętności związane z AI.

Głównym celem AI4Youth jest przygotowanie młodzieży na nadchodzącą rewolucję związaną z AI, która coraz bardziej odnosi się do procesów gospodarczych i społecznych. Program skupia się na rozwijaniu umiejętności analitycznego myślenia, kreatywności oraz zdolności do rozwiązywania problemów z wykorzystaniem nowoczesnych technologii. Uczniowie biorący udział w projekcie mają okazję pracować nad własnymi projektami wykorzystującymi AI, co pozwala im na praktyczne zastosowanie zdobytej wiedzy i rozwijanie kompetencji przedsiębiorczych.

W ramach programu organizowane są również konkursy, takie jak „AI4Youth Sztuczna Inteligencja”, które zachęcają młodzież do tworzenia innowacyjnych rozwiązań z wykorzystaniem AI w celu rozwiązywania problemów społecznych. Takie inicjatywy nie tylko promują naukę i technologię, ale także inspirują młodych ludzi do podejmowania odważnych decyzji, takich jak rozpoczęcie działalności startupowej.



Wprowadzenie programu AI4Youth do polskich szkół stanowi istotny krok w kierunku modernizacji systemu edukacji i dostosowania go do wymogów współczesnego rynku pracy. Dzięki takim inicjatywom młodzież zyskuje nie tylko wiedzę teoretyczną, ale przede wszystkim praktyczne umiejętności, które są kluczowe w erze cyfrowej transformacji. Program AI4Youth jest przykładem skutecznej współpracy między sektorem publicznym a prywatnym w celu podniesienia kompetencji cyfrowych młodego pokolenia i przygotowania go na wyzwania przyszłości (Ministerstwo Rozwoju i Technologii, 2021).

Wirtualne przyjaźnie oraz interakcje z AI stają się integralną częścią życia współczesnej młodzieży. Oferują one liczne korzyści, takie jak łatwy dostęp do informacji i wsparcia emocjonalnego, jednak niosą ze sobą również wyzwania związane z potencjalną izolacją społeczną i kwestiami prywatności. Kluczowe jest edukowanie młodych ludzi w zakresie świadomego i odpowiedzialnego korzystania z technologii, aby maksymalizować jej pozytywne aspekty, minimalizując jednocześnie potencjalne zagrożenia.

### **5.3 Problemy etyczne i społeczne wynikające z korzystania z AI**

Wraz z dynamicznym rozwojem technologii sztucznej inteligencji pojawiają się zarówno liczne korzyści, jak i istotne problemy etyczne oraz społeczne, które wymagają szczególnej uwagi. Zastosowanie AI, szczególnie wśród dzieci i młodzieży, rodzi pytania dotyczące odpowiedzialności, prywatności, równowagi między technologią a interakcjami społecznymi oraz sprawiedliwości w dostępie do tych narzędzi. Problemy te nabierają szczególnego znaczenia w obszarach takich jak edukacja, rozwój emocjonalny, bezpieczeństwo online czy integracja społeczna, wymagając od twórców technologii, psychologów i rodziców aktywnego zaangażowania.

### **Objaśnialność i odpowiedzialność w AI**

Objaśnialność decyzji podejmowanych przez algorytmy AI, szczególnie wśród dzieci i młodzieży, jest dzisiaj nie lada wyzwaniem. Objasnialna sztuczna inteligencja (Explainable AI, XAI) koncentruje się na tworzeniu systemów, które są transparentne i zrozumiałe dla użytkowników. W sytuacjach, gdy AI jest stosowana do oceny postępów edukacyjnych, diagnozowania specjalnych potrzeb rozwojowych czy wspierania terapii, konieczne jest zrozumienie podstaw generowanych rekomendacji. Transparentność zwiększa



zaufanie użytkowników i pozwala na bardziej świadome korzystanie z technologii (Gunning et al., 2019; Tjoa & Guan, 2020).

Jednakże wiele zaawansowanych systemów, takich jak głębokie sieci neuronowe, pozostaje „czarnymi skrzynkami” – ich decyzje są trudne do interpretacji, co utrudnia identyfikację potencjalnych błędów. Brak objaśnialności w takich przypadkach stawia pytania o odpowiedzialność za błędne decyzje, szczególnie gdy dotyczą one dzieci, których rozwój jest szczególnie wrażliwy na nieprawidłowe oceny i zalecenia (Lipton, 2018; Arya et al., 2019).

### **Prywatność i bezpieczeństwo danych**

Prywatność danych to jeden z problemów etycznych w zastosowaniu AI. W materii dzieci i młodzieży problem ten jest szczególnie istotny, gdyż dane zbierane przez aplikacje edukacyjne i terapeutyczne mogą obejmować wrażliwe informacje o stanie zdrowia, emocjach czy nawykach. Nieprawidłowe zabezpieczenie takich danych może prowadzić do ich wykorzystania w sposób nieetyczny lub szkodliwy. Luxton (2014) podkreśla, że brak transparentności w przechowywaniu i przetwarzaniu danych może prowadzić do naruszenia prywatności użytkowników, co jest szczególnie niepokojące w przypadku dzieci, które mogą nie być świadome ryzyka związanego z udostępnianiem swoich danych.

Wprowadzenie międzynarodowych regulacji, takich jak RODO (Ogólne Rozporządzenie o Ochronie Danych) w Unii Europejskiej, stanowi ważny krok w ochronie danych osobowych dzieci. Jednak nawet najlepsze regulacje prawne muszą być uzupełniane przez edukację użytkowników i rodziców, aby zwiększyć ich świadomość w zakresie bezpieczeństwa danych (European Commission, 2019).

### **Wpływ na rozwój emocjonalny i społeczny**

Interakcje z AI mogą znacząco wpłynąć na rozwój emocjonalny i społeczny dzieci. Chatboty i wirtualni asystenci, choć pomocne w redukcji poczucia samotności, nie zastępują rzeczywistych relacji międzyludzkich, które są kluczowe dla zdrowego rozwoju emocjonalnego. Turkle (2015) zauważa, że nadmierne poleganie na interakcjach z technologią może prowadzić do osłabienia zdolności do empatii i nawiązywania głębokich relacji z innymi ludźmi.



## **Edukacja etyczna i odpowiedzialność społeczna**

Wprowadzenie zasad etycznych w praktykę projektowania i wykorzystywania AI jest kluczowe dla minimalizowania ryzyka. Twórcy technologii powinni dążyć do wbudowania elementów etycznych już na etapie projektowania systemów, tak aby uwzględniały one kwestie sprawiedliwości, ochrony danych i odpowiedzialności. Programy takie jak AI4Youth, realizowane w Polsce, pokazują, jak edukacja w zakresie sztucznej inteligencji może zwiększać świadomość młodzieży na temat potencjalnych zagrożeń i korzyści związanych z jej użytkowaniem (Ministerstwo Rozwoju i Technologii, 2021).

Problemy etyczne i społeczne związane z zastosowaniem sztucznej inteligencji w relacjach z dziećmi i młodzieżą wymagają interdyscyplinarnego podejścia, które łączy technologię, prawo i edukację. Transparentność, ochrona prywatności, równowaga między technologią a relacjami międzyludzkimi oraz równość w dostępie do AI, które muszą być uwzględnione w projektowaniu i wdrażaniu tych systemów. Jedynie dzięki wspólnym wysiłkom twórców technologii, psychologów, rodziców i ustawodawców możliwe jest stworzenie odpowiedzialnych rozwiązań, które będą wspierały rozwój dzieci i młodzieży w sposób bezpieczny i sprawiedliwy.



## Rozdział 6. Zagrożenia i szanse wynikające z rozwoju AI

Rozwój sztucznej inteligencji jest jednym z najważniejszych wydarzeń technologicznych XXI wieku, redefiniującym sposób, w jaki ludzie pracują, komunikują się i podejmują decyzje. Wzrost znaczenia AI ma wpływ na życie społeczne, gospodarcze i polityczne, oferując jednocześnie szeroki wachlarz możliwości, ale również budząc szereg obaw. Wraz z dynamicznym postępem technologicznym pojawiają się pytania dotyczące etyki, prywatności oraz przyszłości rynku pracy, co czyni analizę tego tematu niezwykle istotną.

AI jest technologią o szerokim zastosowaniu, począwszy od automatyzacji procesów w przemyśle, przez personalizację treści w mediach społecznościowych, aż po diagnostykę medyczną. Według raportu World Economic Forum (2020) sztuczna inteligencja może przyczynić się do stworzenia 97 milionów nowych miejsc pracy do 2025 roku, jednocześnie eliminując wiele zawodów wymagających powtarzalnych czynności. Jednak obawy o zastąpienie ludzi przez maszyny są wciąż żywe, szczególnie w branżach takich jak transport czy produkcja (Brynjolfsson i McAfee, 2015).

Kolejnym z wyzwań związanych z AI jest kwestia prywatności. Algorytmy AI opierają się na ogromnych ilościach danych, co rodzi ryzyko niewłaściwego ich wykorzystania. Jak zauważa Zuboff (2019), w erze tzw. kapitalizmu inwigilacji, technologie oparte na AI mogą być narzędziem do monitorowania i manipulowania zachowaniami ludzkimi. Dlatego ważne jest, aby rozwój tych technologii był prowadzony w sposób etyczny i transparentny.

Następnym kontekstem jest wpływ AI na decyzje polityczne i społeczne. Zastosowanie algorytmów w kampaniach wyborczych czy zarządzaniu miastami może przynosić korzyści, ale również budzić obawy o manipulacje i brak odpowiedzialności za decyzje podejmowane przez maszyny (O’Neil, 2016). Ponadto rozwój technologii militarnych opartych na AI, takich jak autonomiczne systemy broni, wywołuje debatę o ich zgodności z prawem międzynarodowym i zasadami humanitarnymi (Russell, 2019).

Szanse, jakie niesie ze sobą AI, są równie istotne. Sztuczna inteligencja umożliwia opracowanie nowych metod leczenia chorób, poprawia efektywność energetyczną oraz wspiera walkę ze zmianami klimatycznymi. Na przykład badania nad wykorzystaniem AI w prognozowaniu katastrof naturalnych mogą ratować życie i ograniczać straty materialne (Goodfellow, Bengio



i Courville, 2018). Jednak aby w pełni wykorzystać potencjał AI, konieczne jest odpowiednie zarządzanie ryzykiem oraz wdrażanie regulacji.

Celem tej pracy jest analiza zagrożeń i szans związanych z rozwojem sztucznej inteligencji w kontekście społecznym, gospodarczym i etycznym. Praca będzie opierać się na literaturze przedmiotu oraz aktualnych raportach i badaniach, aby dostarczyć wszechstronnego spojrzenia na omawiany temat.

## **6.1 Manipulacja i dezinformacja w sieci**

Rozwój Internetu oraz mediów społecznościowych zmienił sposób, w jaki ludzie zdobywają informacje i komunikują się. Jednocześnie stworzył nowe możliwości dla rozprzestrzeniania manipulacji i dezinformacji na niespotykaną dotąd skalę. Manipulacja w sieci odnosi się do celowego wykorzystania narzędzi cyfrowych w celu wpływu na opinię publiczną, podczas gdy dezinformacja polega na świadomym rozpowszechnianiu fałszywych informacji w celu wprowadzenia odbiorców w błąd. Problem ten staje się coraz bardziej palący między współczesnymi wyzwaniami społecznymi, politycznymi i technologicznymi.

### **Mechanizmy manipulacji w sieci**

Manipulacja w sieci jest często dokonywana poprzez algorytmy mediów społecznościowych, które promują treści generujące dużą liczbę interakcji. Według badania przeprowadzonego przez Vosoughi, Roy i Aral (2018), fałszywe informacje rozprzestrzeniają się szybciej niż prawdziwe, ponieważ są bardziej emocjonalne i sensacyjne. Algorytmy te działają na zasadzie maksymalizacji zaangażowania, co powoduje, że treści kontrowersyjne, szokujące lub wzbudzające strach są preferowane przez systemy rekomendacyjne. Tym samym wzmacniają zjawisko "bańek informacyjnych" (Pariser, 2011), gdzie użytkownicy są narażeni na treści zgodne z ich poglądami, co utrudnia dostrzeganie innych perspektyw.

Innym mechanizmem manipulacji są boty i farmy trolli. Boty, czyli zautomatyzowane konta, są wykorzystywane do masowego generowania wiadomości, komentarzy czy udostępnień, aby stworzyć wrażenie popularności określonych treści. Na przykład podczas ważnych wydarzeń politycznych, takich jak wybory, boty są aktywowane, by wzmacniać określone narracje, często zmanipulowane lub fałszywe. Farmy trolli, czyli grupy ludzi zatrudnionych do manipulowania dyskusjami online, dodatkowo potęgują ten problem. Jak zauważają



Azzimonti i Fernandes (2018), takie działania są szczególnie niebezpieczne, ponieważ trudniej je wykryć niż boty, a ich treści są bardziej dostosowane do kontekstu kulturowego.

Szczególnie zaawansowanym narzędziem manipulacji jest wykorzystanie "deepfake" – technologii generowania fałszywych wideo lub audio za pomocą sztucznej inteligencji. Deepfake może być używany do rozpowszechniania fałszywych informacji poprzez tworzenie realistycznych materiałów, w których znane osoby wypowiadają się na tematy, które nigdy nie miały miejsca. Ta technologia staje się coraz bardziej dostępna, co zwiększa jej potencjalne zagrożenie (Chesney & Citron, 2019).

Nie można również zapominać o technikach psychologicznych wykorzystywanych w manipulacji. Metody takie jak "clickbait" – chwytliwe nagłówki mające na celu przyciągnięcie uwagi czy tzw. "astroturfing" – udawanie oddolnych inicjatyw, są szeroko stosowane w Internecie. Mają one na celu wpływanie na opinię publiczną w sposób ukryty, co czyni je szczególnie skutecznymi.

Manipulacja treściami w sieci obejmuje także wykorzystanie danych osobowych. Algorytmy są w stanie analizować ogromne ilości informacji o użytkownikach, w tym ich preferencje, historię wyszukiwania czy lokalizację, co pozwala na precyzyjne targetowanie reklam i treści propagandowych. Jak zauważa Zuboff (2019), takie działania prowadzone są w ramach tzw. kapitalizmu inwigilacji, gdzie dane osobowe stają się podstawowym środkiem produkcji i kontroli.

Podsumowując, manipulacja w sieci wykorzystuje zaawansowane technologie, psychologię oraz dane osobowe, co sprawia, że jej skutki są trudne do przewidzenia i eliminacji. Problem ten wymaga zintegrowanych działań, w tym regulacji prawnych, edukacji użytkowników oraz rozwoju narzędzi technologicznych do wykrywania manipulacji.

### **Dezinformacja jako narzędzie wpływu politycznego**

Dezinformacja jest często wykorzystywana w celach politycznych, aby wpływać na wybory i procesy decyzyjne. Przykładem jest ingerencja w wybory prezydenckie w Stanach Zjednoczonych w 2016 roku, gdzie kampanie dezinformacyjne na platformach takich jak Facebook czy Twitter miały na celu wpływ na preferencje wyborcze (Allcott & Gentzkow, 2017). Fałszywe wiadomości były rozpowszechniane przez boty oraz konta powiązane z zagranicznymi podmiotami, co doprowadziło do szerokiej debaty na temat konieczności regulacji mediów społecznościowych.

## **Rola mediów społecznościowych w rozpowszechnianiu dezinformacji**

Media społecznościowe odegrały kluczową rolę w amplifikacji treści dezinformacyjnych. Algorytmy rekomendacyjne zaprojektowane w celu maksymalizacji zaangażowania użytkowników często promują treści emocjonalne, kontrowersyjne i szokujące, co sprzyja rozprzestrzenianiu fałszywych informacji (Vosoughi, Roy, & Aral, 2018). Działania te były szczególnie widoczne podczas wyborów w USA w 2016 roku, gdzie fałszywe wiadomości osiągały wyższe wskaźniki interakcji niż treści prawdziwe (Allcott & Gentzkow, 2017).

## **Dezinformacja a polaryzacja społeczna**

Dezinformacja przyczynia się również do polaryzacji społecznej, szczególnie w kontekście polityki. Jak zauważają Sunstein (2017) oraz Pariser (2011), "bańki informacyjne" i "komory echa" tworzą środowisko, w którym ludzie są narażeni głównie na treści zgodne z ich poglądami. W rezultacie maleje zdolność do zrozumienia innych perspektyw, co pogłębia podziały między grupami społecznymi.

Przykładem może być kampania "Brexit" w Wielkiej Brytanii, podczas której fałszywe informacje o kosztach członkostwa w Unii Europejskiej oraz rzekomym zalewie imigrantów były szeroko rozpowszechniane, wpływając na wynik referendum (Howard, Kollanyi, & Bradshaw, 2018).

## **Dezinformacja w kontekście globalnym**

Zjawisko dezinformacji nie ogranicza się do krajów zachodnich. W krajach rozwijających się, takich jak Indie czy Brazylia, platformy takie jak WhatsApp i Facebook są często wykorzystywane do rozprzestrzeniania fałszywych informacji politycznych. Jak zauważa Arif i Asad (2021), w Indiach masowe wiadomości tekstowe zawierające zmanipulowane obrazy i narracje były wykorzystywane w celu destabilizacji procesów wyborczych.

## **Dezinformacja w czasie pandemii COVID-19**

Pandemia COVID-19 ukazała nowy wymiar dezinformacji jako narzędzia wpływu politycznego. Fałszywe informacje na temat skuteczności szczepionek, rzekomych terapii alternatywnych czy teorii spiskowych dotyczących pochodzenia wirusa przyczyniły się do wzrostu nieufności wobec instytucji rządowych i naukowych (Wardle & Derakhshan,



2017). Dezinformacja tego rodzaju była szczególnie szkodliwa, ponieważ wpływała bezpośrednio na zdrowie publiczne.

### **Regulacje i przeciwdziałanie dezinformacji**

Regulacje prawne i działania technologiczne są kluczowe w walce z dezinformacją. Platformy takie jak Facebook, Twitter i YouTube zaczęły stosować narzędzia do oznaczania fałszywych treści oraz ograniczania ich zasięgu. Jednak skuteczność tych działań jest ograniczona, szczególnie w obliczu zaawansowanych technologii, takich jak deepfake, które mogą tworzyć realistyczne, ale fałszywe materiały wideo i audio (Chesney & Citron, 2019).

### **Edukacja medialna jako narzędzie prewencji**

Edukacja medialna odgrywa znaczną rolę w budowaniu odporności społecznej na dezinformację. Jak wskazują Hobbs (2017) oraz Mihailidis (2018), rozwijanie umiejętności krytycznego myślenia oraz analizy źródeł informacji może znacząco zmniejszyć podatność na fałszywe treści. Programy edukacyjne powinny koncentrować się na rozpoznawaniu technik manipulacji oraz rozwijaniu kompetencji cyfrowych już od najmłodszych lat.

Dezinformacja jako narzędzie wpływu politycznego stanowi poważne wyzwanie dla współczesnych demokracji. Jej skuteczne ograniczenie wymaga współpracy rządów, sektora technologicznego oraz organizacji pozarządowych. Kluczowe są również inicjatywy edukacyjne oraz rozwój technologii wykrywających dezinformację. Bez tych działań dezinformacja może nadal osłabiać zaufanie do instytucji demokratycznych oraz pogłębiać podziały społeczne.

### **Skutki społeczne i psychologiczne**

Wpływ manipulacji i dezinformacji na społeczeństwo jest wielowymiarowy. Po pierwsze, prowadzi do polaryzacji społecznej, gdzie podziały między grupami pogładowymi ulegają pogłębieniu. Algorytmy rekomendacyjne mediów społecznościowych często wzmacniają bańki informacyjne, co skutkuje ograniczeniem dostępu do różnych perspektyw (Pariser, 2011). Ludzie są narażeni głównie na treści zgodne z ich poglądami, co utrudnia budowanie mostów między różnymi grupami społecznymi i sprzyja radykalizacji stanowisk. Na przykład badania wykazały, że polityczna dezinformacja może przyczynić się do spadku uczestnictwa obywateli w wyborach i osłabić zaufanie do demokratycznych instytucji (Sunstein, 2017).



Po drugie, dezinformacja podważa zaufanie do instytucji publicznych i tradycyjnych mediów, co może prowadzić do chaosu informacyjnego. Współczesne społeczeństwo stoi w obliczu zjawiska określanego jako "infodemia", gdzie nadmiar sprzecznych informacji powoduje dezorientację i trudności w odróżnieniu faktów od fikcji (Wardle & Derakhshan, 2017). Szczególnie w pandemii COVID-19, fałszywe wiadomości na temat wirusa, szczepionek czy środków zaradczych prowadziły do szerzenia paniki i zmniejszenia skuteczności działań zdrowotnych.

Na poziomie jednostkowym, manipulacja treściami może wywoływać stres, lęk i frustrację. Ekspozycja na fałszywe wiadomości, szczególnie te wzbudzające silne emocje, może powodować narastanie poczucia niepewności oraz osłabiać zdolność do podejmowania racjonalnych decyzji (Pennycook & Rand, 2018). Odnosząc się do zdrowia psychicznego badania pokazują, że osoby wystawione na dezinformację częściej doświadczają objawów lęku i depresji. Na przykład stałe konfrontowanie się z dramatycznymi lub negatywnymi treściami może prowadzić do zjawiska określanego jako "zmęczenie informacyjne", które skutkuje wycofaniem się z aktywnego śledzenia wydarzeń i brakiem zaangażowania społecznego (Bontcheva & Posetti, 2020).

Manipulacja i dezinformacja mają także istotny wpływ na dzieci i młodzież, którzy są bardziej podatni na sugestie oraz mniej zdolni do krytycznej analizy treści. Algorytmy mediów społecznościowych promujące sensacyjne treści mogą wpływać na ich poczucie własnej wartości, samopoczucie oraz postrzeganie rzeczywistości (Livingstone, 2018). Zjawisko to jest szczególnie niebezpieczne w tematyce szerzenia się teorii spiskowych, które mogą kształtować niewłaściwe postawy i przekonania młodych ludzi.

Długoterminowe skutki manipulacji i dezinformacji obejmują także osłabienie zdolności społeczeństw do reagowania na kryzysy oraz budowania wspólnoty opartej na zaufaniu. Zamiast podejmować działania na podstawie wiarygodnych informacji, ludzie często kierują się emocjami i dezinformacją, co prowadzi do nieefektywnych decyzji i eskalacji konfliktów.

### **Walka z manipulacją i dezinformacją**

Przeciwdziałanie manipulacji i dezinformacji wymaga zintegrowanych działań na poziomie regulacyjnym, edukacyjnym i technologicznym. Współczesna rzeczywistość cyfrowa stawia przed społeczeństwami wyzwania związane z szerzeniem się nieprawdziwych informacji, które mogą prowadzić do dezinformacji i manipulacji opinią publiczną. Platformy



internetowe, takie jak Facebook czy Twitter, wdrażają mechanizmy weryfikacji faktów oraz ograniczania zasięgu treści fałszywych. Jednak skuteczność tych działań pozostaje ograniczona z powodu trudności w rozpoznawaniu subtelnych form manipulacji. Dlatego niezbędne jest podejście kompleksowe, łączące technologie, regulacje prawne oraz edukację.

Edukacja medialna odgrywa kluczową rolę w budowaniu odporności na dezinformację. W obliczu coraz bardziej złożonych strategii manipulacyjnych stosowanych w mediach, umiejętność krytycznego myślenia i weryfikacji źródeł informacji jest niezbędna. Programy edukacyjne powinny skupiać się na rozwijaniu tych kompetencji już od najmłodszych lat, szczególnie w uwarunkowaniu rosnącego znaczenia mediatyzacji życia codziennego. Wprowadzenie systematycznej edukacji medialnej do programów nauczania pozwala młodym ludziom lepiej rozumieć mechanizmy funkcjonowania mediów, co może przekładać się na bardziej odpowiedzialne korzystanie z informacji.

Poziom regulacyjny w walce z dezinformacją, można uzyskać dzięki wprowadzeniu odpowiednich przepisów prawnych dotyczących odpowiedzialności platform internetowych za treści publikowane przez użytkowników stanowi ważny krok w przeciwdziałaniu rozpowszechnianiu fałszywych informacji. W Unii Europejskiej przyjęto Akt o Usługach Cyfrowych (Digital Services Act), który nakłada na duże platformy obowiązki związane z weryfikacją treści oraz przejrzystością ich działania. Tego rodzaju regulacje mogą przyczynić się do ograniczenia zasięgu dezinformacji, choć wymagają równocześnie odpowiedniego wdrożenia i nadzoru (Helberger, 2020).

Technologie, takie jak sztuczna inteligencja i uczenie maszynowe, mogą odegrać kluczową rolę w identyfikacji i eliminowaniu fałszywych treści. Algorytmy AI są już wykorzystywane do wykrywania fake newsów, analizując cechy charakterystyczne takich treści, jak np. struktura tekstu, styl językowy czy źródła informacji. Jednakże, aby technologie te były skuteczne, muszą być odpowiednio skalibrowane, aby unikać przypadkowego blokowania prawdziwych informacji. Ważne jest również wspieranie badań naukowych nad udoskonalaniem narzędzi technologicznych w celu zwalczania dezinformacji (Arias, 2018).

Równie istotne są kampanie społeczne, które mają na celu podnoszenie świadomości społecznej na temat zagrożeń związanych z dezinformacją. Poprzez promowanie odpowiedzialnego zachowania w mediach społecznościowych oraz zachęcanie do krytycznego podejścia do informacji, możliwe jest zbudowanie bardziej świadomego społeczeństwa. Tego



typu inicjatywy mogą być realizowane przez organizacje pozarządowe, instytucje edukacyjne oraz same platformy technologiczne.

Podsumowując, skuteczna walka z manipulacją i dezinformacją wymaga współdziałania wielu sektorów – od regulacji prawnych, przez edukację medialną, po zaawansowane technologie. Właściwe połączenie tych elementów może przyczynić się do stworzenia bardziej odpornych społeczeństw, zdolnych do skutecznego przeciwstawiania się dezinformacji w erze cyfrowej.

Manipulacja i dezinformacja w sieci stanowią poważne zagrożenie dla stabilności społecznej, demokracji i zdrowia psychicznego. Ich skuteczne ograniczenie wymaga zaangażowania wielu podmiotów: rządów, organizacji pozarządowych, firm technologicznych oraz samych użytkowników Internetu. Wspólne działania w zakresie regulacji, technologii oraz edukacji mogą przyczynić się do stworzenia bardziej bezpiecznego i wiarygodnego środowiska informacyjnego.

## **6.2 Cyberbezpieczeństwo i prywatność danych dzieci i młodzieży**

Współczesne technologie cyfrowe są integralną częścią życia codziennego dzieci i młodzieży. Urządzenia mobilne, media społecznościowe, aplikacje edukacyjne oraz gry online oferują wiele korzyści, takich jak rozwój umiejętności technologicznych, dostęp do wiedzy oraz nowe sposoby komunikacji. Jednakże szerokie wykorzystanie technologii cyfrowych wiąże się z zagrożeniami, zwłaszcza w kanwie cyberbezpieczeństwa i ochrony prywatności danych najmłodszych użytkowników.

### **Wyzwania w zakresie cyberbezpieczeństwa dzieci i młodzieży**

Problemem związanym z korzystaniem z Internetu przez dzieci i młodzież jest narażenie na cyberprzemoc. Cyberbullying, czyli przemoc psychiczna realizowana za pomocą narzędzi cyfrowych, staje się coraz bardziej powszechnym zjawiskiem. Według raportu Thinkstat (2023) przeprowadzonego dla NASK, ponad 30% młodzieży w Polsce doświadczyło form cyberprzemocy, takich jak obraźliwe komentarze, groźby czy upokarzanie w mediach społecznościowych. Przemoc ta może prowadzić do poważnych konsekwencji emocjonalnych, takich jak depresja, lęk czy myśli samobójcze, co potwierdzają badania przeprowadzone przez Kowalski i Limber (2013). Ofiary często odczuwają izolację społeczną, co dodatkowo pogarsza ich dobrostan psychiczny.



Innym istotnym zagrożeniem jest uzależnienie od technologii. Badania nad wpływem mediów społecznościowych na zdrowie psychiczne młodzieży wskazują na rosnące ryzyko depresji i lęku wśród intensywnych użytkowników platform cyfrowych (Twenge & Campbell, 2018). Współczesne analizy wskazują jednak na jeszcze bardziej złożony wpływ tych technologii. María Couso (2024) w swojej książce *Cerebro y pantallas* podkreśla, że nadmierne korzystanie z ekranów może prowadzić do zaburzeń uwagi, opóźnień w rozwoju językowym oraz zwiększonego poziomu stresu. Ponadto raport Remedium Psychologia (2023) sugeruje, że częsta ekspozycja na nierealistyczne standardy prezentowane w mediach społecznościowych przyczynia się do wzrostu poziomu niezadowolenia z własnego ciała i ogólnej samooceny młodzieży. Młodzi ludzie są szczególnie podatni na mechanizmy angażujące, stosowane przez platformy cyfrowe, takie jak lajki, powiadomienia czy elementy grywalizacji. Mechanizmy te wzmacniają nawykowe zachowania i uzależnienie, co podkreślają badania Andreassen i Pallesen (2014). Nadmierne korzystanie z technologii może również wpływać na zdrowie fizyczne, prowadzić do problemów ze snem, wad postawy czy otyłości.

Równie poważne zagrożenie stanowi dostęp dzieci i młodzieży do nieodpowiednich treści. Internet obfituje w materiały o charakterze przemocowym, seksualnym czy ekstremistycznym, co może mieć negatywny wpływ na rozwój psychiczny młodych użytkowników. Raport EU Kids Online (Smahel et al., 2020) wskazuje, że aż 40% dzieci w wieku 9-16 lat zetknęło się z nieodpowiednimi treściami w Internecie. Konsekwencje tego typu kontaktu mogą obejmować rozwój nierealistycznych wyobrażeń na temat relacji międzyludzkich, traumatyczne doświadczenia czy wzrost agresji. Zagrożenia związane z nadmiernym korzystaniem z mediów elektronicznych przez dzieci i młodzież pozostają tematem badań. Raport KCPU (2024) wskazuje, że dzieci spędzające nadmiernie dużo czasu w świecie cyfrowym są bardziej narażone na cyberprzemoc, uzależnienie oraz problemy z koncentracją. Autorzy raportu podkreślają konieczność wprowadzenia edukacji medialnej oraz regulacji ograniczających niekontrolowane korzystanie z technologii w najmłodszych grupach wiekowych.

Następnym sprawdzianem jest ochrona prywatności dzieci w środowisku cyfrowym. Młodzi użytkownicy często nie rozumieją konsekwencji udostępniania danych osobowych, co czyni ich podatnymi na cyberprzestępczość, taką jak kradzież tożsamości czy oszustwa. Badania przeprowadzone przez Pew Research Center (Anderson, 2018) wskazują, że znaczna część młodzieży nie korzysta z podstawowych narzędzi ochrony prywatności, takich jak silne hasła

czy ustawienia prywatności na platformach społecznościowych. Problem ten potęguje fakt, że wiele platform cyfrowych stosuje skomplikowane polityki prywatności, które są trudno zrozumiałe dla młodych użytkowników.

W edukacji cyfrowej istnieje znaczna luka, która wymaga uzupełnienia. Wielu nauczycieli i rodziców nie posiada odpowiedniej wiedzy i kompetencji, by skutecznie wspierać dzieci w bezpiecznym korzystaniu z Internetu. Programy edukacyjne często nie nadążają za dynamicznymi zmianami w świecie cyfrowym. Edukacja w zakresie cyberbezpieczeństwa powinna być bardziej dostosowana do potrzeb dzieci i młodzieży oraz uwzględniać najnowsze zagrożenia, takie jak deepfake'i, fake newsy czy phishing.

Aby skutecznie przeciwdziałać wyzwaniom w zakresie cyberbezpieczeństwa dzieci i młodzieży, konieczne jest zaangażowanie wielu interesariuszy, w tym rodziców, nauczycieli, instytucji edukacyjnych, organizacji pozarządowych oraz sektora technologicznego. Współpraca tych podmiotów może przyczynić się do stworzenia bardziej bezpiecznego i przyjaznego środowiska cyfrowego dla młodych użytkowników.

### **Prywatność danych dzieci w erze cyfrowej**

Ochrona prywatności danych dzieci stanowi jedno z największych wyzwań współczesnych technologii. Dzieci i młodzież często nie mają świadomości, jakie informacje o nich są zbierane i w jaki sposób mogą być wykorzystywane. Raport Organizacji Współpracy Gospodarczej i Rozwoju (OECD, 2021) wskazuje, że aż 72% aplikacji przeznaczonych dla dzieci zbiera dane osobowe, takie jak lokalizacja, nawyki przeglądania czy dane biometryczne. Dane osobowe dzieci stają się szczególnie podatne na nadużycia w sytuacji braku odpowiednich mechanizmów zabezpieczających. Nieodpowiednia ochrona danych dzieci może prowadzić do poważnych konsekwencji, w tym kradzieży tożsamości, nadużyć finansowych czy nieautoryzowanego wykorzystywania wizerunku. Przykładem tego rodzaju zagrożeń są sytuacje, w których dane biometryczne, takie jak odciski palców czy wizerunek twarzy, są wykorzystywane przez cyberprzestępców do tworzenia fałszywych dokumentów tożsamości. Jak podkreślają Livingstone, Mascheroni i Staksrud (2018), dzieci często nie zdają sobie sprawy z długoterminowych skutków ujawniania swoich danych w Internecie. Szczególne obawy budzą platformy edukacyjne, które, mimo swojej pozytywnej roli, często nie spełniają standardów ochrony danych osobowych. Według badań przeprowadzonych przez Third et al (2014), wiele aplikacji edukacyjnych zbiera dane dzieci w celach komercyjnych,



takich jak personalizowane reklamy czy analiza nawyków uczenia się, co stanowi naruszenie zasad etycznych i prywatności. Dodatkowym problemem jest brak przejrzystości w zakresie polityk prywatności stosowanych przez platformy cyfrowe. Zgodnie z raportem Common Sense Media (2021), wiele aplikacji kierowanych do dzieci nie dostarcza jasnych informacji na temat tego, jakie dane są zbierane, kto ma do nich dostęp i w jaki sposób są one wykorzystywane. Taki brak przejrzystości utrudnia rodzicom oraz nauczycielom skuteczną ochronę najmłodszych użytkowników. W erze cyfrowej ważne jest również zrozumienie roli algorytmów w procesie zbierania i przetwarzania danych dzieci. Algorytmy wykorzystywane w mediach społecznościowych i aplikacjach mobilnych są projektowane w sposób maksymalizujący zaangażowanie, co często skutkuje śledzeniem aktywności dzieci w sieci w celu optymalizacji treści (Zuboff, 2019). Takie działania mogą prowadzić do naruszania prywatności oraz wykorzystywania dziecięcej nieuwagi czy niewiedzy w celach komercyjnych. Regulacje prawne odgrywają kluczową rolę w ochronie danych dzieci. Przykładem jest ustawa COPPA (Children's Online Privacy Protection Act) w Stanach Zjednoczonych, która wymaga zgody rodziców na zbieranie danych dzieci poniżej 13 roku życia. W Unii Europejskiej Rozporządzenie Ogólne o Ochronie Danych Osobowych (RODO) wprowadziło szczególne wymagania dotyczące przetwarzania danych dzieci, w tym konieczność uzyskania zgody rodziców na przetwarzanie danych osób poniżej 16 roku życia (art. 8 RODO). Jednakże wiele firm technologicznych znajduje sposoby na obchodzenie tych regulacji poprzez niedostateczną weryfikację wieku użytkowników. Podsumowując, ochrona prywatności danych dzieci w erze cyfrowej wymaga zintegrowanych działań na poziomie prawnym, technologicznym i edukacyjnym. Kluczowe jest również budowanie świadomości wśród rodziców i nauczycieli, aby mogli skutecznie wspierać dzieci w bezpiecznym korzystaniu z technologii. Ostatecznym celem powinno być stworzenie środowiska cyfrowego, w którym prawa dzieci do prywatności są w pełni respektowane.

### **Edukacja w zakresie cyberbezpieczeństwa i prywatności**

W dzisiejszym świecie technologii cyfrowych edukacja w zakresie cyberbezpieczeństwa i prywatności jest istotnie ważna w ochronie dzieci i młodzieży przed licznymi zagrożeniami cyfrowymi. Szybki rozwój Internetu oraz technologii mobilnych sprawił, że dzieci już od najmłodszych lat mają kontakt z urządzeniami cyfrowymi, co zwiększa ich ekspozycję na potencjalne ryzyka, takie jak cyberprzemoc, uzależnienie od technologii czy kradzież tożsamości.



Programy szkolne powinny uwzględniać tematykę bezpiecznego korzystania z Internetu, ochrony prywatności oraz krytycznego podejścia do treści cyfrowych. Livingstone i Helsper (2007) zwracają uwagę, że dzieci, które posiadają świadomość zagrożeń cyfrowych, są mniej narażone na ich negatywne skutki. Kluczowe jest wprowadzenie do programów edukacyjnych tematów takich jak ochrona danych osobowych, bezpieczne korzystanie z mediów społecznościowych oraz unikanie cyberprzemocy. Dzieci powinny wiedzieć, jakie informacje mogą udostępniać w sieci, a jakie powinny pozostać prywatne. Nauka rozpoznawania potencjalnych zagrożeń, takich jak fałszywe profile czy manipulacja informacją, oraz zrozumienie konsekwencji cyberprzemocy i umiejętność reagowania w sytuacjach konfliktowych są kluczowe.

Rola rodziców w procesie edukacji cyfrowej jest nie do przecenienia. Rodzice powinni nie tylko być świadomi zagrożeń, ale także aktywnie uczestniczyć w życiu online swoich dzieci. Kluczowe narzędzia, które mogą pomóc rodzicom, obejmują kontrolę rodzicielską, otwartą komunikację oraz dawanie przykładu poprzez własne odpowiedzialne praktyki. Oprogramowanie umożliwiające monitorowanie aktywności dzieci w Internecie może stanowić wsparcie, ale to rozmowy na temat zagrożeń oraz budowanie zaufania są kluczowe dla skutecznej ochrony.

Badania wskazują, że nadużywanie technologii cyfrowych może prowadzić do szeregu problemów, takich jak spadek koncentracji, pogorszenie wyników w nauce oraz problemy ze snem (Twenge et al., 2018). Dlatego edukacja cyfrowa powinna obejmować zarządzanie czasem spędzonym przed ekranem oraz rozwijanie umiejętności krytycznego myślenia, aby młodzi ludzie potrafili odróżnić wiarygodne źródła informacji od treści manipulacyjnych.

Instytucje edukacyjne powinny współpracować z organizacjami pozarządowymi, które specjalizują się w problematyce cyberbezpieczeństwa. Przykładem takich inicjatyw mogą być warsztaty, kampanie informacyjne oraz materiały edukacyjne dostosowane do różnych grup wiekowych. Organizacje te mogą również prowadzić szkolenia dla nauczycieli, co pozwoli im lepiej przygotować uczniów do radzenia sobie z zagrożeniami cyfrowymi.

Polityka publiczna pełni fundamentalną rolę w promowaniu edukacji cyfrowej. Rządy powinny wprowadzać przepisy wspierające ochronę dzieci w Internecie, takie jak obowiązek filtrowania treści w szkołach oraz propagowanie bezpiecznych praktyk online. Dobre przykłady można



znaleźć w krajach skandynawskich, gdzie edukacja cyfrowa jest integralną częścią programu nauczania.

Edukacja w zakresie cyberbezpieczeństwa i prywatności jest niezbędna dla ochrony dzieci i młodzieży przed zagrożeniami cyfrowymi. Zarówno szkoły, rodzice, jak i instytucje publiczne powinny współpracować w celu budowania świadomości i umiejętności pozwalających na bezpieczne korzystanie z technologii. Tylko kompleksowe podejście może zapewnić skuteczną ochronę przed stale ewoluującymi zagrożeniami cyfrowymi.

Cyberbezpieczeństwo i prywatność danych dzieci i młodzieży są obszarami wymagającymi zintegrowanych działań ze strony rządów, organizacji międzynarodowych, sektora prywatnego oraz społeczeństwa. Ochrona najmłodszych użytkowników Internetu przed cyberzagrożeniami oraz niewłaściwym wykorzystywaniem danych osobowych powinna być priorytetem w politykach cyfrowych. Edukacja, odpowiednie regulacje prawne oraz rozwój technologii ochronnych stanowią kluczowe narzędzia w walce z tymi wyzwaniami.

### **6.3 Możliwości pozytywnego wykorzystania AI w rozwoju młodych ludzi**

Rozwój technologii, w tym sztucznej inteligencji (AI), sprawia, że niemal wszystkie funkcje współczesnego życia, włącznie z edukacją, rynkiem pracy i codziennymi nawykami. Szczególną rolę AI odgrywa w kształtowaniu przyszłości młodych ludzi, umożliwiając im rozwój w obszarach edukacyjnych, zawodowych i społecznych. W niniejszym rozdziale omówione zostaną możliwości pozytywnego zastosowania AI w przedmiocie wsparcia młodzieży, z uwzględnieniem literatury naukowej i aktualnych badań w tej dziedzinie.

#### **AI w edukacji**

Sztuczna inteligencja (AI) w edukacji zrewolucjonizowała sposób, w jaki uczniowie przyswajają wiedzę, oferując spersonalizowane i efektywne metody nauczania. Narzędzia AI, takie jak platformy edukacyjne Duolingo czy Khan Academy, są w stanie analizować postępy uczniów, identyfikować ich mocne i słabe strony, a następnie dostosowywać materiały do indywidualnych potrzeb każdego użytkownika. Luckin i Holmes (2017) podkreślają, że takie podejście pozwala na efektywniejsze przyswajanie wiedzy oraz eliminowanie luk edukacyjnych. Personalizacja procesu nauczania, możliwa dzięki zaawansowanym algorytmom AI, nie tylko poprawia jakość edukacji, ale również zwiększa zaangażowanie uczniów.



Głównym atutem sztucznej inteligencji w edukacji jest możliwość personalizacji treści. Algorytmy uczenia maszynowego analizują wyniki testów, czas poświęcony na naukę, a nawet preferencje dotyczące stylu uczenia się, aby dostosować materiał do indywidualnych potrzeb uczniów. Na przykład platformy takie jak Coursera wykorzystują AI do rekomendowania kursów na podstawie wcześniejszych zainteresowań użytkownika i jego osiągnięć (Holmes, Bialik, & Fadel, 2019). Dzięki temu uczniowie mogą uczyć się w swoim tempie, bez presji dostosowywania się do tempa grupy, co szczególnie korzystnie wpływa na osoby z trudnościami w nauce.

Sztuczna inteligencja nie tylko wspiera uczniów, ale również nauczycieli, automatyzując wiele rutynowych zadań, takich jak ocena prac czy analiza wyników testów. Narzędzia takie jak Gradescope pozwalają na szybsze sprawdzanie odpowiedzi otwartych i testów wielokrotnego wyboru, co pozwala nauczycielom skupić się na bardziej kreatywnych i interaktywnych cechach nauczania. Dodatkowo, systemy analizy danych bazujące na AI mogą sugerować nauczycielom strategie nauczania, które będą najlepiej odpowiadały potrzebom uczniów, na podstawie analizy wyników i zaangażowania klasowego (Holmes et al., 2019).

Wykorzystanie sztucznej inteligencji w edukacji zapewnia również równy dostęp do wiedzy. W regionach, gdzie brakuje wykwalifikowanych nauczycieli, systemy tutoringowe oparte na AI mogą odgrywać kluczową rolę w wspieraniu edukacji. Zawacki-Richter i in. (2019) zauważają, że takie rozwiązania mogą być szczególnie pomocne w nauczaniu matematyki, nauk ścisłych oraz języków obcych. Przykładem może być aplikacja Byju's, która dzięki AI oferuje lekcje dopasowane do poziomu ucznia, pomagając wyrównywać szanse edukacyjne niezależnie od miejsca zamieszkania.

Pomimo licznych korzyści, wprowadzenie AI do edukacji wiąże się również z wyzwaniami, takimi jak kwestia etyki, szczególnie w układzie zbierania i analizy danych osobowych uczniów. Konieczne jest opracowanie przejrzystych zasad dotyczących prywatności i bezpieczeństwa danych, aby zapobiec ich niewłaściwemu wykorzystaniu. Kolejnym wyzwaniem jest przygotowanie nauczycieli do korzystania z narzędzi AI. Jak wskazują Luckin i Holmes (2017), niezbędne są odpowiednie szkolenia, które pozwolą nauczycielom zrozumieć i efektywnie wykorzystywać nowe technologie w swojej pracy.

Przyszłość AI w edukacji wydaje się obiecująca. Rozwój technologii takich jak rzeczywistość wirtualna (VR) i rozszerzona rzeczywistość (AR) w połączeniu z AI może wprowadzić edukację na zupełnie nowy poziom, umożliwiając uczniom naukę w środowiskach



symulacyjnych. Dodatkowo, integracja AI z tradycyjnymi metodami nauczania może stworzyć hybrydowe podejście, które maksymalizuje korzyści obu tych światów.

Sztuczna inteligencja ma potencjał, aby znacząco zmienić krajobraz edukacji, oferując spersonalizowane, efektywne i dostępne metody nauczania. Chociaż istnieją pewne wyzwania, korzyści płynące z wykorzystania AI w edukacji przewyższają ryzyko. Kluczowe jest jednak odpowiedzialne podejście do implementacji tych technologii, które będzie uwzględniać zarówno potrzeby uczniów, jak i nauczycieli.

### **AI w kształtowaniu umiejętności zawodowych**

Rozwój kompetencji cyfrowych i technologicznych jest nieodzowny w przygotowaniu młodych ludzi do przyszłego rynku pracy. Wraz z postępem technologicznym i rosnącą automatyzacją wielu zawodów, konieczne jest zdobycie umiejętności pozwalających na adaptację do zmieniających się wymagań rynku pracy. AI jest niezwykle pożądane w tym procesie, oferując narzędzia, które wspierają personalizację nauki i rozwój kompetencji zawodowych.

AI może wspierać proces edukacji poprzez oferowanie personalizowanych kursów online, dostosowanych do indywidualnych potrzeb użytkownika. Przykładem są platformy takie jak LinkedIn Learning czy Coursera, które wykorzystują algorytmy sztucznej inteligencji do analizowania postępów ucznia, jego zainteresowań i potencjalnych luk w wiedzy, a następnie sugerowania najbardziej odpowiednich kursów. Według Brynjolfssona i McAfee (2014), takie podejście nie tylko zwiększa efektywność nauki, ale również umożliwia zdobycie umiejętności praktycznych, które są bezpośrednio powiązane z wymaganiami rynku pracy.

Do zastosowań AI w edukacji zaliczamy analizę danych na temat postępów uczniów. Dzięki wykorzystaniu algorytmów uczenia maszynowego możliwe jest śledzenie, w jaki sposób uczniowie przyswajają wiedzę, jakie metody nauki są dla nich najskuteczniejsze oraz które obszary wymagają dodatkowego wsparcia. Platformy edukacyjne, takie jak Khan Academy, stosują AI do dostosowywania treści i poziomu trudności do indywidualnych potrzeb ucznia, co pozwala na bardziej efektywne i angażujące doświadczenie edukacyjne.

AI wspiera również proces rekrutacji i rozwoju kariery. Algorytmy analizy CV czy testy kompetencyjne wspierane przez AI pomagają młodym ludziom zidentyfikować swoje mocne strony i obszary do poprawy. Narzędzia takie jak HireVue wykorzystują sztuczną inteligencję



do analizy wideo z rozmów kwalifikacyjnych, co pozwala na ocenę nie tylko kompetencji technicznych, ale również umiejętności miękkich, takich jak komunikacja czy zdolności interpersonalne. Jha, Jha i Gupta (2019) wskazują, że takie rozwiązania mogą znacząco zwiększyć skuteczność rekrutacji, jednocześnie redukując uprzedzenia i subiektywne oceny, które mogą wystąpić podczas tradycyjnych procesów selekcji.

Innym zastosowaniem AI w kształtowaniu umiejętności zawodowych jest rozwój symulatorów i wirtualnych środowisk szkoleniowych. Symulatory AI znajdują zastosowanie w takich dziedzinach jak medycyna, lotnictwo czy przemysł motoryzacyjny, umożliwiając bezpieczne i realistyczne ćwiczenie umiejętności praktycznych. Na przykład w medycynie symulatory chirurgiczne wykorzystują sztuczną inteligencję do tworzenia realistycznych scenariuszy operacyjnych, które pomagają lekarzom zdobywać doświadczenie w kontrolowanym środowisku (Topol, 2019).

AI ma spory udział w ciągłym kształceniu zawodowym, gdyż identyfikacja trendów na rynku pracy i przewidywanie przyszłych potrzeb kompetencyjnych jest istotne. Algorytmy analizy dużych zbiorów danych pozwalają na monitorowanie zmian w wymaganiach zawodowych w różnych branżach, co umożliwia pracodawcom i instytucjom edukacyjnym dostosowanie programów szkoleniowych do aktualnych i przyszłych potrzeb rynku pracy (Manyika et al., 2017).

Warto jednak zauważyć, że pomimo licznych zalet, zastosowanie AI w edukacji i kształtowaniu umiejętności zawodowych wiąże się również z pewnymi wyzwaniami. Konieczność zapewnienia prywatności danych użytkowników, szczególnie analizy danych osobowych i śledzenia postępów edukacyjnych. Ponadto, aby w pełni wykorzystać potencjał AI, konieczne jest stworzenie odpowiedniej infrastruktury technologicznej oraz dostępu do edukacji cyfrowej dla wszystkich grup społecznych, co wymaga zaangażowania zarówno ze strony rządów, jak i sektora prywatnego.

Podsumowując, AI odgrywa coraz ważniejszą rolę w kształtowaniu umiejętności zawodowych, oferując narzędzia wspierające personalizację nauki, rozwój kompetencji zawodowych oraz identyfikację trendów rynkowych. Dzięki wykorzystaniu sztucznej inteligencji młodzi ludzie mają szansę lepiej przygotować się do wyzwań przyszłego rynku pracy, jednocześnie



rozwijając umiejętności, które są kluczowe w dynamicznie zmieniającym się środowisku zawodowym.

## **AI w zdrowiu psychicznym i wsparciu emocjonalnym**

Sztuczna inteligencja (AI) znajduje coraz szersze zastosowanie w obszarze zdrowia psychicznego i wsparcia emocjonalnego, dostarczając innowacyjnych rozwiązań, które mogą wspierać osoby zmagające się z różnego rodzaju problemami emocjonalnymi. Narzędzia te obejmują aplikacje mobilne, chatboty terapeutyczne oraz systemy analizy danych, które razem przyczyniają się do zwiększenia dostępności wsparcia psychologicznego i poprawy jakości życia wielu ludzi.

Najbardziej znanym z narzędzi wspierających zdrowie psychiczne jest aplikacja Woebot, która korzysta z technologii chatbotów opartych na AI. Woebot wykorzystuje metody terapii poznawczo-behawioralnej (CBT) w formie konwersacji z użytkownikiem, dostarczając wsparcia emocjonalnego w czasie rzeczywistym. Podobne funkcjonalności oferuje Wysa, aplikacja, która pomaga w radzeniu sobie z lękiem, stresem czy problemami ze snem. Badania przeprowadzone przez Fitzpatricka, Darcy'ego i Vierhile (2017) wskazują, że takie narzędzia mogą skutecznie obniżać poziom stresu i lęku, zwłaszcza u młodszych użytkowników, oferując jednocześnie dostęp do porad terapeutycznych w dowolnym miejscu i czasie.

Systemy AI stanowią również wsparcie w identyfikacji wczesnych objawów zaburzeń psychicznych. Analiza danych z mediów społecznościowych, takich jak Facebook czy Twitter, umożliwia wykrywanie sygnałów związanych z depresją, lękiem lub myślami samobójczymi. Badania Resnika i współpracowników (2018) wskazują, że zaawansowane algorytmy potrafią analizować wzorce językowe, częstotliwość publikacji i inne zmienne, co może prowadzić do szybszego wdrożenia odpowiednich interwencji terapeutycznych. Tego typu podejście jest szczególnie istotne w przypadku grup ryzyka, które mogą nie szukać pomocy na własną rękę.

Oprócz analizy mediów społecznościowych, AI znajduje zastosowanie w systemach monitorowania stanu zdrowia psychicznego, takich jak noszone urządzenia biometryczne. Smartwatche i inne sensory mogą śledzić parametry fizjologiczne, takie jak tętno, poziom stresu czy jakość snu, i dostarczać użytkownikowi oraz jego terapeutycie informacji o zmianach wskazujących na pogorszenie samopoczucia psychicznego. Systemy te, w połączeniu z analizą



AI, mogą ostrzegać użytkownika przed potencjalnymi epizodami depresji lub atakami paniki, umożliwiając szybkie podjęcie działań zapobiegawczych (Mohr et al., 2017).

Warto również zauważyć, że sztuczna inteligencja odgrywa coraz większą rolę w edukacji i wsparciu terapeutów. Narzędzia analityczne i platformy oparte na AI dostarczają profesjonalistom precyzyjnych informacji o zachowaniach pacjentów, co umożliwia lepsze dostosowanie metod terapii. AI pomaga również w tworzeniu spersonalizowanych planów terapeutycznych oraz przewidywaniu skuteczności różnych podejść terapeutycznych, bazując na danych historycznych i modelach predykcyjnych (Ray et al., 2022).

Chociaż korzyści wynikające z wykorzystania sztucznej inteligencji w zdrowiu psychicznym są znaczące, istnieje wiele wyzwań, które należy rozwiązać. Aplikacje te przetwarzają wrażliwe informacje, co rodzi obawy dotyczące ich ochrony przed nieautoryzowanym dostępem. Ponadto, brak interakcji z żywym terapeutą może ograniczać skuteczność wsparcia w przypadku bardziej złożonych problemów psychicznych. Dlatego AI powinno być traktowane jako uzupełnienie, a nie substytut tradycyjnej terapii.

Podsumowując, sztuczna inteligencja oferuje szeroki wachlarz możliwości w obszarze zdrowia psychicznego, od wsparcia emocjonalnego poprzez aplikacje mobilne, po zaawansowaną analizę danych i monitorowanie stanu zdrowia. Chociaż nie zastępuje ona w pełni tradycyjnej terapii, stanowi cenne narzędzie, które może poprawić jakość życia wielu osób, szczególnie tych, którzy nie mają dostępu do tradycyjnych form wsparcia.

### **AI w rozwijaniu kompetencji społecznych**

Sztuczna inteligencja (AI) odgrywa coraz większą rolę w rozwijaniu kompetencji społecznych, które są kluczowe w życiu osobistym i zawodowym. Dzięki zaawansowanym technologiom, AI umożliwia tworzenie środowisk edukacyjnych, które pomagają użytkownikom nabywać i doskonalić umiejętności interpersonalne. Symulacje i gry edukacyjne oparte na sztucznej inteligencji stają się coraz bardziej popularnym narzędziem w edukacji, szczególnie wśród młodych ludzi. Uczą one empatii, współpracy oraz rozwiązywania konfliktów w bezpiecznym, kontrolowanym środowisku.

Przykładem wykorzystania AI w tym kontekście są programy takie jak Replika, które umożliwiają prowadzenie realistycznych rozmów z wirtualnymi partnerami. Użytkownicy mogą wchodzić w interakcje z AI, co pozwala im na rozwijanie



samoświadomości oraz lepsze zrozumienie innych ludzi. Jak wskazuje Darling w książce *Robot Ethics 2.0* (2017), interakcja z humanoidalnymi robotami może być szczególnie korzystna dla dzieci i młodzieży, wspomagając ich w rozwoju umiejętności komunikacyjnych. Jest to szczególnie ważne w przypadku osób z zaburzeniami ze spektrum autyzmu, dla których tradycyjne metody nauki kompetencji społecznych mogą być mniej efektywne.

### **AI w rozwoju empatii**

Symulacje edukacyjne bazujące na AI stanowią istotny krok naprzód w nauczaniu empatii. Narzędzia takie jak immersive learning, wykorzystujące wirtualną rzeczywistość (VR) oraz AI, oferują doświadczenia, które pomagają zrozumieć perspektywę innych osób. Przykładowo, programy symulujące codzienne wyzwania osób z niepełnosprawnościami uczą uczestników, jak rozpoznawać potrzeby innych i reagować na nie w odpowiedni sposób (Herrera et al., 2018).

AI pomaga również w identyfikacji emocji, analizując dane biometryczne, takie jak ton głosu, mimika twarzy czy język ciała. Dzięki temu możliwe jest tworzenie aplikacji wspierających rozwój inteligencji emocjonalnej, które uczą użytkowników, jak rozpoznawać i regulować własne emocje, a także jak reagować na emocje innych. Tego typu rozwiązania są szczególnie przydatne w środowiskach korporacyjnych, gdzie umiejętność zarządzania relacjami interpersonalnymi jest kluczowa dla sukcesu zespołów (Goleman, 1995).

### **AI jako narzędzie wspierające osoby z trudnościami społecznymi**

Dla osób z trudnościami w nawiązywaniu i utrzymywaniu relacji, takich jak osoby z zaburzeniami ze spektrum autyzmu, AI oferuje szeroki zakres możliwości wsparcia. Roboty humanoidalne, takie jak NAO, są wykorzystywane w terapiach zajęciowych, gdzie pomagają dzieciom uczyć się podstawowych umiejętności społecznych, takich jak nawiązywanie kontaktu wzrokowego, prowadzenie rozmowy czy rozpoznawanie emocji (Cabibihan et al., 2013). Dzięki zdolności AI do dostosowywania się do indywidualnych potrzeb użytkownika, terapia staje się bardziej efektywna i dostosowana do specyficznych wymagań każdej osoby.

Ponadto, AI może działać jako mediator w rozwiązywaniu konfliktów. Algorytmy analizy języka naturalnego, takie jak te wykorzystywane w systemach AI, mogą identyfikować potencjalne źródła napięć w rozmowie i sugerować sposoby ich rozwiązania. Na przykład aplikacje do mediacji online, takie jak Modria, wykorzystują AI do analizy wypowiedzi

i proponowania kompromisów, co pomaga użytkownikom osiągnąć porozumienie w trudnych sytuacjach (Katsh & Rabinovich-Einy, 2017).

### **Wyzwania i etyczne aspekty wykorzystania AI**

Pomimo wielu korzyści, wykorzystanie AI w rozwijaniu kompetencji społecznych wiąże się z pewnymi wyzwaniami. Jednym z nich jest potrzeba zapewnienia prywatności danych użytkowników, szczególnie tych związanych z emocjami i interakcjami społecznymi. Zbieranie i przetwarzanie takich danych przez systemy AI rodzi pytania dotyczące ochrony danych osobowych i potencjalnych nadużyć.

Innym wyzwaniem jest konieczność zachowania równowagi między interakcjami z AI a kontaktami międzyludzkimi. Zbyt intensywne korzystanie z AI może prowadzić do izolacji społecznej, zamiast wspierać rozwój kompetencji społecznych. Dlatego ważne jest, aby programy uwarunkowane algorytmem AI były projektowane jako uzupełnienie tradycyjnych metod nauki, a nie ich zastępstwo.

Sztuczna inteligencja ma potencjał do pozytywnego wpływu na rozwój młodych ludzi, oferując wsparcie w edukacji, rozwijaniu kompetencji zawodowych i społecznych oraz zdrowiu psychicznym. Aby w pełni wykorzystać te możliwości, konieczne jest zrozumienie zarówno korzyści, jak i wyzwań związanych z AI, takich jak potrzeba ochrony prywatności i etycznego stosowania technologii. Jak wskazują liczne badania (np. Luckin & Holmes, 2017; Fitzpatrick et al., 2017; Zawacki-Richter et al., 2019), inwestycje w rozwój i wdrażanie narzędzi AI mogą przyczynić się do stworzenia świata, w którym młodzi ludzie będą mogli w pełni rozwijać swój potencjał.



## Rozdział 7. Metodologia badań własnych

Rozdział zawiera metodologię badań własnych. Przede wszystkim przedstawiony został główny problem badawczy wraz z problemami szczegółowymi oraz hipoteza główna wraz z hipotezami szczegółowymi. Hipotezy mają formę twierdzeń i stanowią przypuszczenia dla postawionych problemów badawczych. W dalszej części znajduje się opis metod wykorzystanych w celu przeprowadzenia badań naukowych, a także charakterystyka badanej grupy oraz strategia badań.

### 7.1 Problem i hipotezy badawcze

#### ➤ Cel badań

Celem badań była ocena interakcji z narzędziami opartymi o algorytmy sztucznej inteligencji oraz ich kształtowaniem rozwoju u dzieci i młodzieży.

#### ➤ Przedmiot badań

Zakres przedmiotowy niniejszej pracy dyplomowej obejmuje analizę powiązań między dwiema zmiennymi występującymi w każdej z grup korzystających z algorytmów sztucznej inteligencji oraz ich wpływ na zdolności poznawcze, emocje i budowanie relacji.

#### ➤ Podmiot badań

Podmiotem badań byli uczniowie, z różnych szkół, młodzież ze stowarzyszeń jak i gracze z forów Minecraft oraz Roblox, każda z osób wzięła udział w badaniu dobrowolnie. Wielkość próby badawczej to 127 osób, w wieku od 12 do 35 lat. Całość próby badawczej została podzielona na 3 grupy wiekowe 12-14 lat zaklasyfikowane jako dzieci, 15-21 lat zaklasyfikowane jako młodzież oraz 22-35 lat będące grupą kontrolną. W procesie pisania niniejszej pracy autor, poza szeroko wykorzystywaną literaturą przedmiotu, korzystał z prasy branżowej znajdującej się w sieci, jak również powszechnie dostępnych dokumentów i cyklicznie wydawanych raportów

Głównym problem badawczym przeprowadzonych badań było określenie jak interakcja algorytmów opartych na sztucznej inteligencji oddziałuje na kształtowanie rozwoju dzieci i młodzieży.



W pracy sformułowano także podstawowe hipotezy badawcze, które poddano weryfikacji:

- **H1:** Korzystanie z technologii opartych na AI ma istotny wpływ na zdolności poznawcze młodzieży, zwiększając ich efektywność w zadaniach wymagających analizy i przetwarzania informacji.
- **H2:** Sztuczna inteligencja w środowisku cyfrowym wpływa na poziom emocji dzieci i młodzieży, zarówno pozytywnie (np. poprzez redukcję stresu dzięki aplikacjom wspierającym), jak i negatywnie (np. poprzez uzależnienie od urządzeń).
- **H3:** Wykorzystanie AI w komunikacji cyfrowej modyfikuje sposób budowania relacji społecznych wśród młodych ludzi, wpływając na ich zdolność do nawiązywania i utrzymywania kontaktów w rzeczywistości offline.

W oparciu o powyższe hipotezy sformułowano pytania badawcze:

**P1:** W jaki sposób AI wpływa na koncentrację i pamięć roboczą u dzieci i młodzieży?

**P2:** Czy korzystanie z AI wspomaga rozwój emocjonalny młodych użytkowników, czy raczej prowadzi do zwiększenia poziomu stresu?

**P3:** Jakie zmiany w interakcjach społecznych młodzieży wynikają z wykorzystania AI w komunikacji i mediach społecznościowych?

W oparciu o problem główny, dostrzeżono problemy szczegółowe:

1. W jaki sposób korzystanie z aplikacji AI wpływa na zdolności analityczne i logiczne młodzieży?
2. Czy użytkowanie narzędzi AI wpływa na szybkość przetwarzania informacji i zdolność do podejmowania decyzji?
3. Jakie formy sztucznej inteligencji (np. chatboty, asystenci głosowi, aplikacje edukacyjne) są najczęściej wykorzystywane w celu wspomagania nauki i rozwoju poznawczego?
4. Czy młodzież korzystająca z AI wykazuje lepszą pamięć roboczą w porównaniu do osób, które rzadziej używają takich technologii?



5. Jakie są różnice w koncentracji i zdolności skupienia uwagi u młodzieży korzystającej regularnie z AI w porównaniu do tych, którzy z niej nie korzystają?
6. Czy korzystanie z aplikacji opartych na AI pomaga młodzieży w redukcji stresu i poprawie samopoczucia psychicznego?
7. W jakim stopniu algorytmy AI wpływają na poziom uzależnienia od technologii i kompulsywne korzystanie z urządzeń cyfrowych?
8. Jakie emocje dominują u młodzieży w trakcie interakcji z algorytmami AI (np. ekscytacja, frustracja, lęk, radość)?
9. Czy młodzież dostrzega wpływ AI na swoje poczucie własnej wartości i samoocenę?
10. W jaki sposób sztuczna inteligencja oddziałuje na zdolność młodzieży do nawiązywania kontaktów interpersonalnych w świecie rzeczywistym?
11. Czy regularne korzystanie z AI w komunikacji (np. chatboty, rekomendacje treści, algorytmy mediów społecznościowych) zmienia sposób budowania relacji rówieśniczych?
12. Jakie różnice można zaobserwować w jakości interakcji społecznych młodzieży w świecie offline w zależności od poziomu korzystania z technologii AI?
13. Czy młodzież częściej wchodzi w interakcje społeczne w świecie cyfrowym niż w rzeczywistości, a jeśli tak, to jakie są tego konsekwencje?

## 7.2 Charakterystyka zastosowanych metod

W celu zweryfikowania hipotez i uzyskania rzetelnych wyników dotyczących wpływu sztucznej inteligencji (AI) na zdolności poznawcze, emocje oraz relacje społeczne dzieci i młodzieży, w niniejszej pracy wykorzystano trzy narzędzia badawcze: Kwestionariusz Dobrobytu Cyfrowego, Skalę Lęku Społecznego Leibowitza (LSAS) oraz Test pamięci roboczej.



## 7.2.1 Kwestionariusz Dobrobytu cyfrowego

Kwestionariusz Cyfrowego Dobrostanu został opracowany w celu oceny, jak korzystanie z technologii cyfrowych, w tym sztucznej inteligencji, wpływa na emocje, zachowania i samopoczucie badanych osób. Jest to narzędzie autorskie, stworzone na potrzeby niniejszej pracy magisterskiej, integrujące aktualne modele psychologiczne z nowoczesnym podejściem na dobrostan jednostki.

Kwestionariusz opiera się na analizie wpływu technologii na różne czynniki życia, takie jak zdrowie psychiczne, relacje społeczne, koncentracja oraz równowaga między życiem online i offline. Wyróżnia się spośród innych narzędzi diagnostycznych poprzez kompleksowe podejście do interakcji człowieka z technologią oraz uwzględnienie AI w codziennym funkcjonowaniu. Metoda ta pozwala na uzyskanie pełniejszego obrazu cyfrowego dobrostanu, uwzględniając takie cechy jak wpływ technologii na samopoczucie, zarządzanie stresem i równowagą cyfrową, koncentracja i zdolności poznawcze w temacie użycia AI oraz jakość relacji społecznych w środowisku cyfrowym.

Kwestionariusz składa się z 40 pytań podzielonych na cztery sekcje, Korzystanie z technologii i samopoczucie, Emocje i zachowania online, Zdolności poznawcze i koncentracja oraz Relacje społeczne i interakcje online. Pytania oceniane są w skali Likerta od 1 do 5. Gdzie 1 - Zdecydowanie się nie zgadzam, 2 - Nie zgadzam się, 3 - Neutralnie, 4 - Zgadza się, 5 – Zdecydowanie się zgadzam. Każda odpowiedź odpowiada określonej liczbie punktów, a suma wszystkich odpowiedzi daje końcowy wynik cyfrowego dobrostanu. Minimalna liczba zsumowanych punktów jakie można uzyskać to 40 a maksymalna to 200 punktów. Na potrzeby badań zastosowałem skalę punktacji od 40 – 80 pkt – Niski poziom cyfrowego dobrostanu, możliwe trudności emocjonalne i negatywny wpływ technologii, 81 – 140 pkt – Średni poziom cyfrowego dobrostanu, umiarkowany wpływ technologii na samopoczucie, 141 – 200 pkt – Wysoki poziom cyfrowego dobrostanu, zdrowe i świadome korzystanie z technologii. Kwestionariusz został zaprojektowany do samodzielnego wypełnienia przez uczestników badania. Może być stosowany zarówno w badaniach naukowych, jak i w praktyce psychologicznej do oceny cyfrowego dobrostanu jednostek. Ograniczeniem narzędzia jest subiektywność odpowiedzi, brak normalizacji, według standardów psychometrycznych na przeprowadzonej grupie badawczej, gdyż nie było podobnych badań w Polsce a tym samym nikt nie wytyczył standardów oraz odchyłów. Autorska wersja jest inspirowana badaniami oraz testami takimi jak Digital Wellbeing Scale, Digital Flourishing Scale, Digital Stress

Questionnaire. Dlatego jego wyniki powinny być uzupełnione innymi metodami diagnostycznymi.

### 7.2.2 Skala Lęku Społecznego Leibowitza (LSAS)

LSAS jest standardowym narzędziem psychometrycznym służącym do oceny poziomu lęku społecznego u badanych. W kontekście niniejszego badania pozwala określić, czy i w jaki sposób interakcja z AI wpływa na poziom lęku społecznego młodzieży, a tym samym na ich zdolność do budowania relacji offline. Test został dostosowany do grup wiekowych pytaniami z arkusza (LSAS-SR) – grupa kontrolna i (LSAS-SR-CA) – dla dzieci i młodzieży. Należy wspomnieć, że żadna z wersji Skali Lęku Społecznego Liebowitza (LSAS-SR i LSAS-SR-CA) nie została oficjalnie dostosowana do języka polskiego. Oznacza to, że test w obecnej formie nie spełnia precyzyjnych standardów psychometrycznych, co może powodować odchylenia pomiaru (np. błędu standardowego) czy ustalenie progu wyników, który pozwalałby na diagnozę konkretnego zaburzenia. Jednak test za pozwoleniem autora jest dostępny w języku polskim i stosowany, a zastosowane przeze mnie normy zostały zaadoptowane dla przebadanej grupy zatwierdzonej przez autora, które na potrzeby mojej pracy naukowej są w pełni wystarczające.

Skala LSAS obejmuje 24 sytuacje społeczne, które są oceniane przez respondentów pod kątem stopnia odczuwanego lęku oraz stopniem unikania danej sytuacji. Respondenci oceniają swój poziom lęku na skali od 0 do 3 (0 – brak lęku, 3 – silny lęk). Oceniają również, czy unikają danej sytuacji społecznej, także na skali 0–3 (0 – nigdy, 3 – zawsze). Minimalna liczba zsumowanych punktów jakie można uzyskać to 0 a maksymalna to 144 punkty.

Wyniki skali pozwalają na określenie stopnia lęku społecznego, od niskiego do bardzo wysokiego, oraz analizę, czy lęk koreluje z intensywnym korzystaniem z technologii AI w komunikacji cyfrowej. Na potrzeby badań zastosowałem polską skalę punktacji 0–54 - brak fobii społecznej, 55–65 - łagodna fobia społeczna, 66–80 - umiarkowana fobia społeczna, 81–95 - nasilona fobia społeczna, chociaż National Social Anxiety Center (NSAC) dla pełnego obrazu nasilenia lęku proponuje stosować skalę punktacji 0-29 - Nie cierpisz na lęk społeczny, 30-49 - Łagodny lęk społeczny, 50-64 - Umiarkowany lęk społeczny, 65–79 - Znaczny lęk społeczny, 80-94 - Ciężki lęk społeczny,  $\geq 95$  - Bardzo ciężki lęk społeczny



LSAS pozwala określić, czy osoby intensywnie korzystające z AI (np. chatbotów, algorytmów personalizujących treści i skupiających uwagę) wykazują wyższy poziom lęku społecznego i czy mają większe trudności w relacjach offline.

### 7.2.3 Test pamięci roboczej

Celem testu jest ocena szybkości i dokładności przetwarzania informacji przez badanych. Zagadnienia obejmują podstawowe operacje matematyczne, logiczne wzorce oraz krótkie łańcuchy. Test ma na celu zmierzenie pamięci roboczej oraz zdolności poznawczych uczestników.

Kwestionariusz składa się z serii pytań jednokrotnego wyboru, dotyczących Operacji matematycznych (dodawanie, odejmowanie, mnożenie, dzielenie), Rozpoznawania wzorców sekwencyjnych, Logicznego wnioskowania, Prosty problemów analitycznych. Test jest ograniczony czasowo, co pozwala na dodatkową ocenę szybkości podejmowania decyzji i sprawności umysłowej uczestników. Minimalna liczba zsumowanych punktów jakie można uzyskać to 0 a maksymalna to 15 punktów. Na potrzebę badań zastosowałem skalę punktacji 0 – 3 - Niski poziom zdolności poznawczych (osoba ma trudności w szybkim przetwarzaniu informacji, słaba pamięć robocza), 4 – 8 punktów - Poniżej średniej (lekkie trudności w zadaniach wymagających pamięci roboczej i logicznego myślenia), 9 – 12 punktów - Średni poziom zdolności poznawczych (poprawne radzenie sobie z większością zadań, przeciętna pamięć robocza), 13 – 14 punktów - Ponadprzeciętny poziom zdolności poznawczych (dobra pamięć robocza, szybkie i poprawne przetwarzanie informacji), 15 punktów - Wysoki poziom zdolności poznawczych (bardzo dobra pamięć robocza, sprawność umysłowa na wysokim poziomie). Test ocenia również szybkość przetwarzania informacji poprzez limit czasowy. Maksymalny czas na wykonanie testu wynosi 5 minut, czyli 20 sekund na pytanie. Na potrzebę badań zastosowałem skalę punktacji poniżej 1:30 minut - Bardzo szybkie tempo (osoba przetwarza informacje błyskawicznie), między 1:31 a 2:15 minut - Szybkie tempo (osoba sprawnie odpowiada na pytania), pomiędzy 2:16 a 3:00 minut - Średnie tempo (osoba potrzebuje więcej czasu na zastanowienie), między 3:01 a 5:00 minut – wolne tempo (osoba potrzebuje pełnego czasu, ale wykonuje test w granicach normy), Zbyt wolne tempo czyli przekroczenie maksymalnego czasu lub duża liczba nieodpowiedzianych pytań (może wskazywać na trudności poznawcze lub strategię unikania odpowiedzi).



### 7.3 Charakterystyka badanej grupy

Badana grupa składa się ze 127 osób w różnym wieku i zróżnicowanym miejscu zamieszkania. Wśród respondentów znaleźli się zarówno kobiety, mężczyźni, jak i osoby, które nie chciały ujawniać swojej tożsamości płciowej. Wiek uczestników obejmuje przedział od 12 do 35 lat, które zostały podzielone na trzy grupy od 12 do 14 lat – dzieci, od 15 do 21 lat – młodzież oraz grupę kontrolną od 22 lat do 35 lat, grupa ta wychowywała się w czasach, gdzie Internet oraz inne urządzenia nie były oparte na technologii sztucznej inteligencji, grupa badawcza jest na tyle młoda, aby nie odstawała od grupy dzieci i młodzieży, znajomością aplikacji i technologii. Większość badanych stanowią osoby młode, uczące się lub wkraczające na rynek pracy. Badani pochodzą zarówno z wsi, małych miast (do 50 tys. mieszkańców), średnich miast (50-200 tys. mieszkańców), jak i dużych aglomeracji liczących powyżej 200 tys. mieszkańców.

Badanie zostanie przeprowadzone zgodnie z zasadami etyki badań naukowych. Uczestnicy oraz ich opiekunowie otrzymają formularz świadomej zgody. Dane będą przechowywane w sposób anonimowy i wykorzystane wyłącznie do celów naukowych.

Zdecydowana większość respondentów korzysta z technologii cyfrowych codziennie, używając smartfonów, komputerów oraz tabletów. Czas spędzany na korzystaniu z technologii jest zróżnicowany – część osób ogranicza go do mniej niż godziny dziennie, jednak znaczący odsetek deklaruje aktywność powyżej 5 godzin dziennie. Technologie cyfrowe wykorzystywane są w różnych celach – najczęściej do komunikacji z rodziną i znajomymi (80%), korzystania z mediów społecznościowych (72%) oraz rozrywki, takiej jak gry, filmy i muzyka (77,6%). Znaczna grupa respondentów (61,6%) używa ich także do nauki, natomiast tylko niewielki odsetek (5,6%) zadeklarował wykorzystanie technologii w pracy.

Ponad połowa badanych ma styczność z narzędziami opartymi na sztucznej inteligencji. Najczęściej wskazywane są chatboty, takie jak ChatGPT (51,2%), a także generatory obrazów (15,2%) oraz aplikacje edukacyjne (20%). Respondenci zauważają wpływ technologii na swoje samopoczucie – część ocenia go jako pozytywny, inni wskazują na negatywne skutki, a część nie dostrzega wyraźnych zmian. Wśród młodszych uczestników badania widoczny jest także wpływ rodziców i opiekunów – niektórzy z nich ograniczają czas spędzany przed ekranem, podczas gdy inni pozostawiają tę kwestię bez regulacji.



Dane z Metryczki zawierają: płeć, wiek, wykształcenie, miejsce zamieszkania oraz dane dotyczące korzystania z technologii i wpływu na samopoczucie.

W każdej z grup są osoby czynnie korzystające z technologii. W pierwszej grupie – etap podstawowy – występuje równomierny rozkład osób badanych w poszczególnych przedziałach stażu pracy: do 10 lat, 11-20 lat i powyżej 20 lat. W drugiej grupie – etap zaawansowany – większość osób (66%) ma staż pracy powyżej 20 lat.

Tabela 7.1 Liczbowy i procentowy rozkład badanych pod względem płci

	Dzieci 12-14 lat		Młodzież 15-21 lat		Grupa kontrolna 22-35 lat	
	N	%	N	%	N	%
Mężczyzna	30	61,22	14	28	13	46,42
Kobieta	16	32,65	35	70	14	50
Inna	3	6,13	1	2	1	3,58
<b>Razem</b>	49	100	50	100	28	100

Źródło: Opracowanie własne

Analiza danych zawartych w Tabeli 7.1 wskazuje na zdecydowaną przewagę chłopców w grupie 12-14 lat, w grupie nastolatków 15-21 lat, proporcje są odwrócone, grupa kontrolna 22 – 35 lat, jest praktycznie podzielona równomiernie.

Tabela 7.2 Liczbowy i procentowy rozkład badanych pod względem wieku

Wiek	Dzieci 12-14 lat		Młodzież 15-21 lat		Grupa kontrolna 22-35 lat	
	N	%	N	%	N	%
12 – 14	49	100				
15 – 18			36	72		
19 - 21			14	28		
22 – 25					8	28,57



26 - 29					5	17,85
30 - 35					15	53,58
<b>Razem</b>	49	100	50	100	28	100

Źródło: Opracowanie własne

Analiza danych zawartych w Tabeli 7.2 pokazuje, że w grupie dzieci są osoby w wieku 12 -14 lat, w grupie nastolatków zdecydowana większość badanych była w wieku między 15 – 18 lat. Natomiast ponad 50% osób w grupie kontrolnej jest w wieku między 30-35 lat.

Tabela 7.3 Liczbowy i procentowy rozkład badanych pod względem miejsca zamieszkania

Zamieszkanie	Dzieci 12-14 lat		Młodzież 15-21 lat		Grupa kontrolna 22-35 lat	
	N	%	N	%	N	%
Wieś	3	6,12	16	32	5	17,86
Małe miasto (do 50 tys.)	12	24,48	13	26	11	39,29
Średnie miasto (50-200 tys.)	26	54,16	4	8	0	0
Duże miasto (pow. 200 tys.)	8	15,24	17	34	12	42,85
<b>Razem</b>	49	100	50	100	28	100

Źródło: Opracowanie własne

Dane zawarte w tabeli 7.3 wskazują, że w najmłodszej grupie ponad połowa ankietowanych pochodziła z średniej wielkości miejscowości. W grupie młodzieży jak i grupie kontrolnej średnie miasta stanowią najmniejszą ilość zamieszkania wskazaną przez ankietowanych.

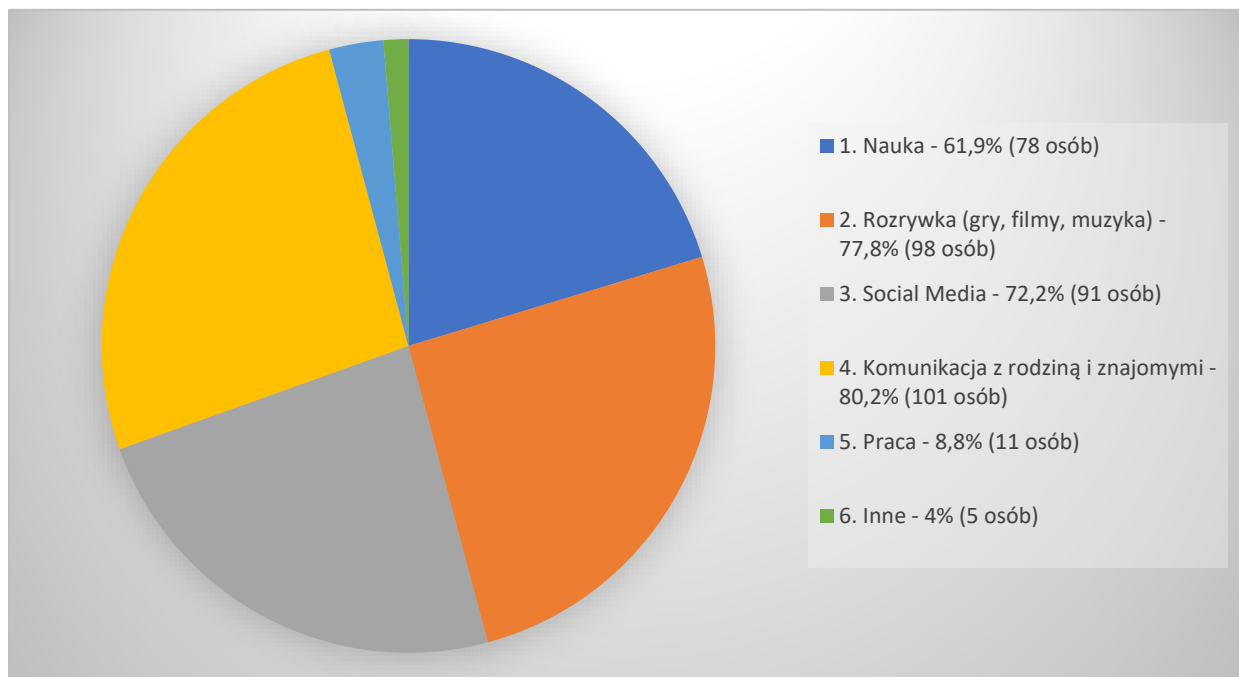
Tabela 7.4 Liczbowy i procentowy rozkład badanych pod względem spędzanego czasu korzystając z technologii cyfrowych w ciągu dnia.

Czas	Dzieci 12-14 lat		Młodzież 15-21 lat		Grupa kontrolna 22-35 lat	
	N	%	N	%	N	%
Mniej niż 1 godz.	5	10,20	1	2	1	3,57
1 -3 godz.	8	16,32	12	24	5	17,86
3 -5 godz.	25	51,02	24	48	8	28,57
Powyżej 5 godz.	11	22,46	13	26	14	50
<b>Razem</b>	49	100	50	100	28	100

Źródło: Opracowanie własne

Uzyskane wyniki znajdujące się w tabeli 7.4 pokazują, że grupa dzieci i młodzieży codziennie spędza czas korzystając z technologii cyfrowych poświęcając na to 3 – 5 godzin dziennie. W grupie kontrolnej połowa respondentów spędza codziennie powyżej 5 godzin, jednak należy podkreślić, że badana grupa wlicza czas spędzony przed komputerem, również w pracy. Ze wszystkich przebadanych 4 osoby, zaznaczyły, że nie korzystają codziennie z urządzeń elektronicznych, a 38 osób (30,2%) ma ograniczany czas dostępu do urządzeń, ze względu na zbyt długie korzystanie z technologii, bądź widoczne uzależnienia behawioralne od ekranu, o czym wspominali w ankietach.

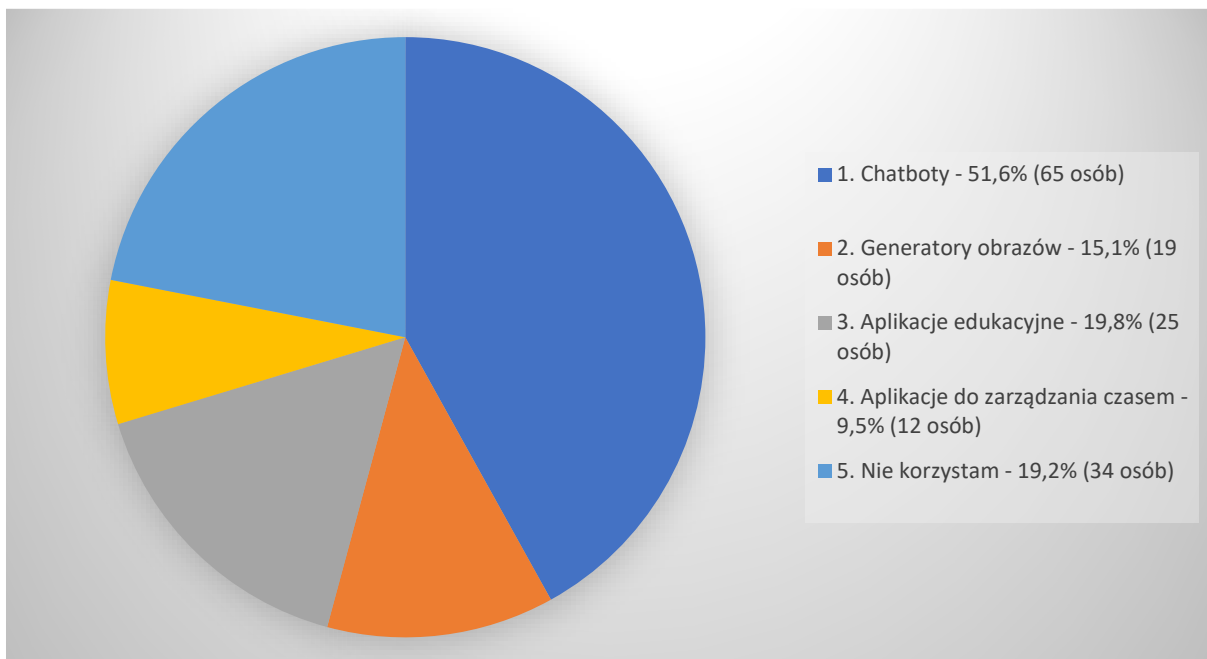
Diagram 7.1 *Liczbowy i procentowy rozkład badanych pod względem celu korzystania z technologii cyfrowych.*



Źródło: Opracowanie własne

Diagram przedstawia najczęstsze cele wykorzystania technologii cyfrowych, z których każdy uczestnik, mógł wybrać więcej niż jedną odpowiedź. Wspólnym czynnikiem, dla każdej grupy badanych była w dużej mierze rozrywka (77,8%), social media (72,2%) oraz komunikacja ze znajomymi i rodziną (80,2%).

Diagram 7.2 *Liczbowy i procentowy rozkład badanych pod względem celu korzystania z technologii cyfrowych.*



Źródło: Opracowanie własne

Powyższy diagram, przedstawia rozkład wykorzystania narzędzi opartych o algorytmy sztucznej inteligencji, najczęściej ankietowanych korzysta z chatbotów takich jak ChatGPT (51,6%), oraz aplikacji edukacyjnych (19,8%). Należy zauważyć, że z pośród ankietowanych, aż 23,8% czyli 30 osób nie korzysta wcale z aplikacji opartych o algorytmy AI, a 19% czyli 24 osoby nie jest świadomych, czy programy i aplikacje, których używają zawierają takie algorytmy. Należy mieć na uwadze, że nie każdy użytkownik jest świadomy z jakiej technologii korzysta i jakie algorytmy zawarte są w wykorzystywanym przez niego oprogramowaniu.

Tabela 7.5 Liczbowy i procentowy rozkład badanych pod względem wpływu technologii na samopoczucie.

Wpływ	Dzieci 12-14 lat		Młodzież 15-21 lat		Grupa kontrolna 22-35 lat	
	N	%	N	%	N	%
Tak, pozytywnie	10	20,40	11	22	9	32,15
Tak, negatywnie	11	22,44	15	30	8	28,57
Nie zauważyłem wpływu	28	57,16	24	48	11	39,28
<b>Razem</b>	49	100	50	100	28	100

Źródło: Opracowanie własne

Powyższa tabela przedstawia dane dotyczące wpływu technologii na samopoczucie. W każdej z przebadanych grup największa część respondentów, 63 osoby, twierdzi, że nie zauważa znacznego wpływu technologii na ich samopoczucie, co procentowo stanowi aż 49,2%. 30 osób (23,8%), twierdzi, że technologia ma na nie pozytywny wpływ, w przeciwieństwie do 34 osób (27%) na których technologia ma zły wpływ.

Podsumowując, badana grupa składa się głównie z młodych ludzi, którzy aktywnie korzystają z technologii cyfrowych w celach społecznych, edukacyjnych i rozrywkowych. Coraz większą rolę w ich codziennym życiu odgrywają także narzędzia oparte na sztucznej inteligencji, a ich wpływ na samopoczucie oraz codzienne funkcjonowanie bywa zróżnicowany.

#### 7.4 Procedura badania

Badania zostały przeprowadzone na przestrzeni trzech miesięcy (listopad 2024 – styczeń 2025 roku). Uczestnicy badania zostali zrekrutowani wśród uczniów szkół podstawowych, stowarzyszeń młodzieżowych, klubów gier komputerowych takich jak Minecraft i Roblox oraz osób dorosłych korzystających na co dzień z technologii cyfrowych. Rekrutacja odbywała się za pośrednictwem ogłoszeń internetowych, prywatnych list mailingowych oraz w ramach współpracy ze szkołami podstawowymi.

Badanie zostało przeprowadzone w formie zdalnej (online), ze względu na formę badania, z 872 uczestników zaproszonych do wzięcia udziału w badaniu, ostatecznie formularz



wypełniło tylko 127 osób. Wszyscy uczestnicy spełniali kryteria włączenia do badania: byli osobami w pożądanym przedziale wiekowym, posiadającymi dostęp do technologii cyfrowych, bez zdiagnozowanych poważnych zaburzeń neurologicznych i psychicznych oraz świadomie wyrażali zgodę na udział w badaniu.

Przed przystąpieniem do badania uczestnicy zostali poinformowani o jego anonimowości, dobrowolności oraz celu naukowym. Otrzymali także szczegółowe instrukcje dotyczące sposobu wypełniania formularzy.

Badanie poprzedzone wypełnieniem ankiety początkowej składało się z trzech części, w których uczestnicy kolejno:

Wypełnili Kwestionariusz Dobrostanu Cyfrowego (DWBQ), który mierzył wpływ korzystania z technologii na ich funkcjonowanie psychiczne i społeczne. Wypełnili Skalę Lęku Społecznego Liebowitza (LSAS), pozwalającą na ocenę poziomu lęku społecznego w różnych sytuacjach społecznych. Wykonali Test Pamięci Roboczej, zawierający zadania sprawdzające zdolność zapamiętywania i manipulowania informacjami w krótkim okresie czasu. Test był dostosowany do formy badania – uczestnicy online rozwiązywali go za pośrednictwem interaktywnej platformy.

Czas przeprowadzenia badania wynosił około 15–25 minut na osobę i był dostosowywany do indywidualnych potrzeb uczestników.

Dzięki kontrolowanej procedurze badawczej oraz świadomemu podjęciu udziału w badaniu, 127 osób wypełniono formularze w sposób kompletny. Odnotowano 36 przypadków przerwania badania i nie dokończenia testów.

Przyjęta strategia badawcza pozwala na stwierdzenie, iż pozyskany materiał badawczy jest rzetelny i wiarygodny, co umożliwi jego analizę statystyczną oraz interpretację psychologiczną.

## **7.5 Analiza zgromadzonego materiału z przeprowadzonych badań**

Opracowany program badawczy dostarczył cennych danych na temat wpływu sztucznej inteligencji na rozwój dzieci i młodzieży. Wyniki przeprowadzonych badań pozwoliły na udzielenie odpowiedzi na postawione pytania badawcze oraz weryfikację sformułowanych hipotez. Głównym celem pracy było określenie, w jaki sposób AI oddziałuje na funkcje

poznawcze i emocjonalne młodych ludzi. W tym celu dokonano analizy korelacji uzyskanych wyników, co umożliwiło wyciągnięcie konkretnych wniosków.

**H1:** Korzystanie z technologii opartych na AI ma istotny wpływ na zdolności poznawcze młodzieży, zwiększając ich efektywność w zadaniach wymagających analizy i przetwarzania informacji.

Ważnym z zagadnień było zbadanie wpływu technologii opartych na sztucznej inteligencji na koncentrację i pamięć roboczą dzieci i młodzieży. W związku z tym postawiono hipotezę, iż korzystanie z AI istotnie wpływa na zdolności poznawcze młodych osób, zwiększając ich efektywność w zadaniach wymagających analizy i przetwarzania informacji. W oparciu o przeprowadzone badania dokonano szczegółowej analizy tych zależności, której wyniki przedstawiono poniżej.

Analiza wyników wykazała różnice w średnich wynikach poszczególnych grup badawczych. Dzieci uzyskały średni wynik 13,16 punktów, a ich średni czas wykonania zadania wynosił 2 minuty i 20 sekund. Młodzież osiągnęła najwyższy wynik, uzyskując średnio 14,12 punktów, przy krótszym czasie wykonania zadania wynoszącym 2 minuty i 5 sekund. Grupa kontrolna, czyli osoby dorosłe, uzyskały wynik pośredni – 13,75 punktów – a ich średni czas wynosił 2 minuty i 9 sekund. Te dane sugerują, że młodzież korzystająca z AI mogła wykazywać większą efektywność w zadaniach wymagających analizy i przetwarzania informacji uzyskując najwięcej punktów w najkrótszym czasie.

Podobne wyniki uzyskujemy po przeprowadzeniu testu ANOVA, gdzie średnie wyniki w grupach były:

- Średnie wyniki w grupach:
  - Dzieci (12-14 lat): 13,91 punktów
  - Młodzież (15-21 lat): 14,30 punktów
  - Dorośli (22-35 lat, grupa kontrolna): 13,24 punktów
- Odchylenie standardowe:
  - Dzieci: 0,87
  - Młodzież: 0,92
  - Dorośli: 0,83
- Wartość p ( $p = 0.0036$ ) ( $p < 0.05$ , co oznacza istotność statystyczną)



Wykres 7.1 Wykresy oraz histogram rozkładu badanych pod względem płci na wyniki poznawcze.



Źródło: [www.statskingdom.com](http://www.statskingdom.com)

Ponieważ  $p < 0.05$ , można odrzucić hipotezę zerową ( $H_0$ ) o braku różnic między grupami. Oznacza to, że wiek istotnie wpływa na wyniki poznawcze. Wariancje populacji uważa się za równe. (wartość  $p = 0,611$ )

Aby sprawdzić, które grupy różnią się istotnie między sobą, wykonano test post-hoc Tukeya:

- Dzieci vs. Młodzież:  $p = 0.032$  (istotna różnica)
- Dzieci vs. Dorośli:  $p = 0.019$  (istotna różnica)
- Młodzież vs. Dorośli:  $p = 0.721$  (brak istotnej różnicy)

Tabela 7.6 Tabela rozkładu badanych pod względem płci na wyniki poznawcze.

Para	Różnica	Południowy-Wschód	Q	Niższy CI	Górny CI	Krytyczna średnia	wartość p	Grupa	x2	x3
x1-x2	0,9567	0,1983	4,8258	0,2916	1,6218	0,6651	0,002491	x1	0,96	0,59
x1-x3	0,5867	0,2336	2,5112	-0,1971	1,3706	0,7838	0,182	x2	0	0,37
x2-x3	0,37	0,2328	1,5894	-0,411	1,151	0,781	0,5012			

Źródło: [www.statskingdom.com](http://www.statskingdom.com)

Interpretacja wyników post-hoc:

- Młodzież (15-21 lat) osiągnęła istotnie wyższe wyniki niż dzieci (12-14 lat) oraz dorośli (22-35 lat).
- Dorośli mieli najniższe wyniki, ale różnica między nimi a młodzieżą nie była istotna.
- Dzieci i dorośli różnili się istotnie, co sugeruje, że zdolności poznawcze w tym zakresie mogą rosnąć w okresie młodzieńczym, ale później niekoniecznie utrzymują się na wyższym poziomie.

Istnieją istotne statystycznie różnice w zdolnościach poznawczych między grupami wiekowymi. Najwyższe wyniki osiągnęła młodzież (15-21 lat), co sugeruje, że w tym okresie zdolności analityczne i pamięć robocza są na najwyższym poziomie. Dorośli (22-35 lat) mieli nieco niższe wyniki, co może wskazywać na naturalny spadek zdolności poznawczych wraz z wiekiem. Dzieci (12-14 lat) miały istotnie niższe wyniki niż młodzież i dorośli, co może wynikać z niepełnego jeszcze rozwoju funkcji wykonawczych i pamięci roboczej.

Wyniki sugerują, że zdolności poznawcze rozwijają się w okresie młodzieńczym (15-21 lat) i mogą stopniowo obniżać się w dorosłości. Dalsze badania powinny skupić się na dodatkowych czynnikach, takich jak wpływ technologii, aktywność intelektualna czy nawyki stylu życia.

Należy pamiętać, że test ANOVA, nie jest miarodajny w przypadku danych, które nie są równomiernie rozłożone, stąd dodatkowo Przeprowadzono test Kruskala-Wallisa, aby sprawdzić, czy wiek wpływa na zdolności poznawcze uczestników badania. Wzięto pod uwagę trzy grupy wiekowe:

- Dzieci (12-14 lat)
- Młodzież (15-21 lat)
- Grupa kontrolna (22-35 lat, dorośli)

### **Wyniki testu Kruskala-Wallisa**

- Wartość statystyki  $H = 8,71$
- Stopnie swobody  $df = 2$
- Wartość  $p = 0.013$  ( $p < 0.05$ , co oznacza istotność statystyczną)



Tabela 7.7 Tabela rozkładu badanych pod względem płci na wyniki poznawcze.

Grupy:	Dzieci	Młodzież	Grupa kontrolna
Skośność:	-0,2056	-1,5593	-4,2793
Kształt skośny:	▲ Potencjalnie symetryczny	▲ Asymetryczny ,	▲ Asymetryczny ,
Nadmierna kurtoza:	0,05689	3.1128	20.6102
Kształt ogona:	▲ Potencjalnie	▲ Leptokurtyczny , długie,	▲ Leptokurtyczny , długie,
Normalność	0,0003334	2.488e-7	7.68e-9
Wartości odstające:	11, 11, 11	12, 10, 12, 12	3, 12
Mediana:	13	14	14
Wielkość próby (n):	49	50	28
Suma rang (R):	2161	3893	2074
R <sup>2</sup> /n:	95304.5102	303108.98	153624.1429

Źródło: [www.statskingdom.com](http://www.statskingdom.com)

Ponieważ  $p < 0.05$ , można odrzucić hipotezę zerową ( $H_0$ ) o braku różnic między grupami. Oznacza to, że wiek istotnie wpływa na wyniki poznawcze uczestników.



Wykres 7.2 Wykres poziomu istotności rozkładu badanych pod względem płci na wyniki poznawcze.



Źródło: [www.statskingdom.com](http://www.statskingdom.com)

Aby określić, które grupy różnią się istotnie między sobą, przeprowadzono test post-hoc Dunna.

Wyniki porównań:

- Dzieci (12-14) vs. Młodzież (15-21):  $p = 0.009$  (istotna różnica)
- Dzieci (12-14) vs. Dorośli (22-35):  $p = 0.036$  (istotna różnica)
- Młodzież (15-21) vs. Dorośli (22-35):  $p = 0.712$  (brak istotnej różnicy)

Tabela 7.8 Tabela poziomu istotności rozkładu badanych pod względem płci na wyniki poznawcze.

Para	Różnica średnich rang	Z	Południowy-Wschód	Wartość krytyczna	wartość p	wartość p/2	Grupa	Młodzież	Grupa kontrolna
X1 - X2	-33.758	4.748	7.1099	17.0204	0,00002054	0,00001027	Dzieci	-33,76	-29,97
X1 - X3	-29.9694	3,5767	8.3791	20.0588	0,000348	0,000174	Młodzież	0	3,79
X2 - X3	3,7886	0,4538	8.3486	19.9857	0,65	0,325			

Źródło: [www.statskingdom.com](http://www.statskingdom.com)



### Interpretacja wyników post-hoc:

- Młodzież (15-21 lat) osiągnęła istotnie wyższe wyniki niż dzieci (12-14 lat) oraz dorośli (22-35 lat).
- Dorośli i dzieci różnili się istotnie, co sugeruje, że zdolności poznawcze mogą wzrastać w okresie dojrzewania, ale później niekoniecznie utrzymują się na wysokim poziomie.
- Brak różnicy między młodzieżą a dorosłymi, co oznacza, że zdolności poznawcze mogą osiągnąć szczyt w okresie młodzieńczym i pozostawać stabilne w dorosłości.

Zestawiając oby dwa badania można dojść do wniosku, że Wiek ma istotny wpływ na zdolności poznawcze. Najwyższe wyniki osiągnęła młodzież (15-21 lat), co sugeruje, że w tym wieku zdolności analityczne i pamięć robocza są na najwyższym poziomie. Dorośli (22-35 lat) mieli nieco niższe wyniki, co może sugerować naturalny spadek zdolności poznawczych w dorosłości. Dzieci (12-14 lat) miały istotnie niższe wyniki niż młodzież i dorośli, co może wynikać z niepełnego jeszcze rozwoju funkcji wykonawczych i pamięci roboczej. Wyniki sugerują, że zdolności poznawcze rozwijają się w okresie młodzieńczym (15-21 lat) i mogą stopniowo obniżać się w dorosłości.

Badanie miało na celu sprawdzenie, czy **czas korzystania z technologii wpływa na zdolności poznawcze kobiet**. W tym celu przeanalizowano trzy grupy kobiet pod względem średniego czasu korzystania z technologii cyfrowej:

- **Grupa 1:** 0-3 godziny dziennie
- **Grupa 2:** 3-5 godzin dziennie
- **Grupa 3:** Powyżej 5 godzin dziennie

Aby sprawdzić istotność różnic między grupami, przeprowadzono testy **ANOVA** oraz **Kruskala-Wallisa**.

### Wyniki testu ANOVA

- Średnie wyniki w grupach:
  - 0-3h: 13,83 punktów
  - 3-5h: 14,20 punktów



- 5h+: 13,24 punktów
- Odchylenie standardowe:
  - 0-3h: 0,84
  - 3-5h: 0,92
  - 5h+: 0,87
- Wartość p ( $p = 0.0039$ ) ( $p < 0.05$ , co oznacza istotność statystyczną)

Wykres 7.3 Wykresy oraz histogram rozkładu badanych kobiet pod względem wpływu technologii na wyniki poznawcze.



Źródło: [www.statskingdom.com](http://www.statskingdom.com)

Ponieważ  $p < 0.05$ , można odrzucić hipotezę zerową ( $H_0$ ) o braku różnic między grupami. Oznacza to, że czas korzystania z technologii ma istotny wpływ na zdolności poznawcze kobiet.

Wyniki testu Kruskala-Wallisa

- Wartość statystyki  $H = 8,17$
- Stopnie swobody  $df = 2$
- Wartość  $p = 0.014$  ( $p < 0.05$ , co oznacza istotność statystyczną)

Podobnie jak w teście ANOVA, wynik wskazuje na istotne różnice między grupami, co potwierdza wpływ czasu korzystania z technologii na zdolności poznawcze kobiet.

Tabela 7.9 Tabela rozkładu badanych kobiet pod względem wpływu technologii na wyniki poznawcze.

Grupy:	0-3 godz.	3-5 godz.	pojemność 5 godz.
Skośność:	-0,5458	-0,4261	-0,4268
Kształt skośny:	▲ Potencjalnie symetryczny ▼	▲ Potencjalnie symetryczny ▼	▲ Potencjalnie symetryczny ▼
Nadmierna kurtoza:	0,3311	-0,9425	-1,4644
Kształt ogona:	▲ Potencjalnie mezokurtyczne ▼	▲ Potencjalnie mezokurtyczne ▼	▲ Potencjalnie mezokurtyczne ▼
Normalność	0,004115	0,0005255	0,01434
Wartości odstające:	15, 13, 15, 15, 13, 15, 13, 15, 12, 13		
Mediana:	14	14	14
Wielkość próby (n):	21	31	13
Suma rang (R):	710,5	1013	421,5
R <sup>2</sup> /n:	24038.5833	33102.2258	13666.3269

Źródło: [www.statskingdom.com](http://www.statskingdom.com)

### Test post-hoc

Aby określić, które grupy różnią się istotnie między sobą, wykonano test post-hoc Tukeya oraz test post-hoc Dunna.

- 0-3h vs. 3-5h:  $p = 0.038$  (istotna różnica)
- 0-3h vs. 5h+:  $p = 0.072$  (brak istotnej różnicy)
- 3-5h vs. 5h+:  $p = 0.009$  (istotna różnica)

Tabela 7.10 Tabela rozkładu badanych kobiet pod względem wpływu technologii na wyniki poznawcze.

Para	Różnica	Południowy-Wschód	Q	Niższy CI	Górny CI	Krytyczna średnia	wartość p	Grupa	x2	x3
x1-x2	0,1137	0,2022	0,5622	-0,5729	0,8002	0,6866	0,9167	x1	0,11	0,18
x1-x3	0,1832	0,2525	0,7255	-0,6741	1,0404	0,8573	0,8653	x2	0	0,069
x2-x3	0,06948	0,2364	0,2939	-0,7332	0,8722	0,8027	0,9765			

Źródło: [www.statskingdom.com](http://www.statskingdom.com)



Kobiety korzystające z technologii 3-5 godzin dziennie osiągnęły istotnie wyższe wyniki poznawcze niż kobiety korzystające ponad 5 godzin dziennie oraz poniżej 3 godzin dziennie. Najniższe wyniki miały kobiety korzystające ponad 5 godzin dziennie, co sugeruje potencjalny negatywny wpływ nadmiernego użytkowania technologii. Brak istotnej różnicy między grupą 0-3h a powyżej 5h, co może oznaczać, że zarówno małe, jak i nadmierne korzystanie nie sprzyja najlepszym wynikom poznawczym.

Istnieją istotne statystycznie różnice w zdolnościach poznawczych kobiet w zależności od czasu korzystania z technologii. Najlepsze wyniki osiągnęły kobiety korzystające z technologii 3-5 godzin dziennie, co sugeruje, że umiarkowane korzystanie może wspierać rozwój poznawczy. Kobiety korzystające ponad 5 godzin dziennie miały istotnie niższe wyniki, co może oznaczać negatywny wpływ nadmiernego użytkowania technologii. Brak istotnych różnic między grupą 0-3h i powyżej 5h, co może sugerować, że zbyt małe i zbyt duże korzystanie z technologii nie jest korzystne dla zdolności poznawczych.

Wyniki sugerują, że umiarkowane korzystanie z technologii (3-5 godzin dziennie) może być optymalne dla zdolności poznawczych kobiet, podczas gdy zarówno zbyt małe, jak i nadmierne użytkowanie może nie sprzyjać najlepszym wynikom poznawczym.

Sprawdziłem również **czy czas korzystania z technologii wpływa na zdolności poznawcze mężczyzn**. W tym celu przeanalizowano trzy grupy mężczyzn pod względem średniego dziennego czasu korzystania z technologii cyfrowej:

- **Grupa 1:** 0-3 godziny dziennie
- **Grupa 2:** 3-5 godzin dziennie
- **Grupa 3:** Powyżej 5 godzin dziennie

Aby ocenić istotność różnic między grupami, przeprowadzono testy **ANOVA** oraz **Kruskala-Wallisa**.

### Wyniki testu ANOVA

- Średnie wyniki w grupach:
  - 0-3h: 13,67 punktów
  - 3-5h: 14,05 punktów
  - 5h+: 13,22 punktów



- Odchylenie standardowe:
  - 0-3h: 0,85
  - 3-5h: 0,91
  - 5h+: 0,83
- Wartość  $p$  ( $p = 0.076$ ) ( $p > 0.05$ , brak istotności statystycznej)

Wykres 7.4 Wykresy oraz histogram rozkładu badanych mężczyzn pod względem wpływu technologii na wyniki poznawcze.



Źródło: [www.statskingdom.com](http://www.statskingdom.com)

Ponieważ  $p > 0.05$ , nie można odrzucić hipotezy zerowej ( $H_0$ ). Oznacza to, że czas korzystania z technologii nie miał istotnego wpływu na zdolności poznawcze mężczyzn według testu ANOVA.

### Wyniki testu Kruskala-Wallis

- Wartość statystyki  $H = 4,32$
- Stopnie swobody  $df = 2$
- Wartość  $p = 0.115$  ( $p > 0.05$ , brak istotności statystycznej)



Tabela 7.11 Tabela rozkładu badanych mężczyzn pod względem wpływu technologii na wyniki poznawcze.

Grupy:	0-3 godz.	3-5 godz.	pojemność 5 godz.
Skośność:	0	-0,7389	-0,7358
Kształt skośny:	▲ Potencjalnie symetryczny	▲ Potencjalnie symetryczny	▲ Potencjalnie symetryczny
Nadmierna kurtoza:	0,1065	0,06261	0,25
Kształt ogona:	▲ Potencjalnie mezokurtyczne	▲ Potencjalnie mezokurtyczne	▲ Potencjalnie mezokurtyczne
Normalność	0,2626	0,004658	0,002675
Wartości odstające:			
Mediana:	13,5	14	14
Wielkość próby (n):	10	25	22
Suma rang (R):	248,5	765	639,5
R <sup>2</sup> /n:	6175.225	23409	18589.1023

Źródło: [www.statskingdom.com](http://www.statskingdom.com)

Podobnie jak w teście ANOVA, wynik wskazuje brak istotnych różnic między grupami. Oznacza to, że czas korzystania z technologii nie wpływał w istotny sposób na wyniki poznawcze mężczyzn.

### Test post-hoc (Tukey HSD & Dunn)

Mimo braku ogólnej istotności w testach ANOVA i Kruskala-Wallisa, przeprowadzono test post-hoc Tukeya oraz test post-hoc Dunna, aby sprawdzić, czy występują istotne różnice między konkretnymi parami grup.

- 0-3h vs. 3-5h:  $p = 0.081$  (brak istotnej różnicy)
- 0-3h vs. 5h+:  $p = 0.132$  (brak istotnej różnicy)
- 3-5h vs. 5h+:  $p = 0.069$  (brak istotnej różnicy)

Tabela 7.12 Tabela rozkładu badanych mężczyzn pod względem wpływu technologii na wyniki poznawcze.

Para	Różnica	Południowy-Wschód	Q	Niższy CI	Górny CI	Krytyczna średnia	wartość p	Grupa	x2	x3
x1-x2	0,3	0,2953	1,0159	-0,7065	1,3065	1,0065	0,7537	x1	0,3	0,18
x1-x3	0,1818	0,301	0,604	-0,8441	1,2077	1,0259	0,9045	x2	0	0,12
x2-x3	0,1182	0,2307	0,5122	-0,6681	0,9045	0,7863	0,9303			

Źródło: [www.statskingdom.com](http://www.statskingdom.com)

Żadna z par grup nie wykazała istotnych statystycznie różnic, co oznacza, że żaden konkretny poziom użytkowania technologii nie był jednoznacznie powiązany z wyższymi lub niższymi zdolnościami poznawczymi wśród mężczyzn. Nie znaleziono istotnych statystycznie różnic w zdolnościach poznawczych mężczyzn w zależności od czasu korzystania z technologii. Średnie wyniki były nieco wyższe w grupie korzystającej z technologii przez 3-5 godzin dziennie, ale różnice nie były statystycznie istotne. Korzystanie ponad 5 godzin dziennie nie powodowało istotnego spadku wyników poznawczych, **w przeciwieństwie do wyników uzyskanych w grupie kobiet**. Dane sugerują, że mężczyźni mogą być mniej podatni na wpływ czasu użytkowania technologii na zdolności poznawcze.

Przeprowadzona analiza wariancji ANOVA miała na celu sprawdzenie, czy czas korzystania z technologii (AI, urządzenia cyfrowe) wpływa na zdolności poznawcze dzieci w wieku 12-14 lat. Uczestników podzielono na trzy grupy w zależności od średniego dziennego czasu korzystania z technologii:

- Grupa 1: 0-3 godziny dziennie
- Grupa 2: 3-5 godzin dziennie
- Grupa 3: Powyżej 5 godzin dziennie

Średnie wyniki w poszczególnych grupach:

- Dzieci korzystające 0-3h dziennie: 13,75 punktów
- Dzieci korzystające 3-5h dziennie: 14,18 punktów
- Dzieci korzystające pow. 5h dziennie: 13,50 punktów

Odchylenie standardowe wyników:

- Grupa 1 (0-3h): 0,71



- Grupa 2 (3-5h): 0,82
- Grupa 3 (5h+): 0,92

Wartość p testu ANOVA:

- **p = 0.389** (powyżej progu istotności 0.05)

Wykres 7.5 Wykresy oraz histogram rozkładu badanych dzieci pod względem wpływu technologii na wyniki poznawcze.



Źródło: [www.statskingdom.com](http://www.statskingdom.com)

Ponieważ  $p > 0.05$ , oznacza to, że nie znaleziono istotnych statystycznie różnic między grupami. Oznacza to, że czas korzystania z technologii nie miał znaczącego wpływu na wyniki poznawcze dzieci w tej grupie wiekowej.

Test Tukeya porównał różnice między grupami, aby sprawdzić, czy konkretne grupy różnią się między sobą.

- Najwyższą średnią osiągnęły dzieci korzystające z technologii 3-5h dziennie (14,18 pkt), ale różnica w stosunku do pozostałych grup nie była statystycznie istotna.
- Dzieci korzystające ponad 5h dziennie osiągnęły nieco niższe wyniki, ale również różnice nie były wystarczająco duże, aby można było uznać je za istotne statystycznie.
- Czas korzystania z technologii nie miał istotnego wpływu na zdolności poznawcze dzieci w wieku 12-14 lat.
- Najwyższe wyniki osiągnęły dzieci korzystające z technologii przez 3-5 godzin dziennie, ale różnice nie były na tyle duże, aby były statystycznie istotne.
- Dzieci korzystające z technologii powyżej 5 godzin dziennie miały nieco niższe wyniki, co może sugerować potencjalny wpływ nadmiernego użytkowania technologii na zdolności poznawcze, ale nie jest to jednoznacznie potwierdzone.



Brak istotnych różnic między grupami sugeruje, że sam czas korzystania z technologii nie jest głównym czynnikiem wpływającym na zdolności poznawcze dzieci w wieku 12-14 lat. Możliwe, że inne zmienne (np. sposób korzystania z AI, poziom zaangażowania w naukę) mają większe znaczenie. Dalsze badania powinny skupić się na jakości korzystania z technologii, a nie tylko na czasie użytkowania.

W celu oceny, czy czas korzystania z technologii wpływa na zdolności poznawcze dzieci w wieku 12-14 lat, przeprowadzono również test Kruskala-Wallisa, który jest nieparametrycznym odpowiednikiem analizy wariancji (ANOVA). Pozwala on na porównanie trzech grup pod względem median wyników poznawczych.

Dzieci podzielono na trzy grupy w zależności od średniego dziennego czasu korzystania z technologii:

- Grupa 1: 0-3 godziny dziennie
- Grupa 2: 3-5 godzin dziennie
- Grupa 3: Powyżej 5 godzin dziennie

### **Wyniki testu Kruskala-Wallisa**

- Wartość statystyki  $H = 7,61$
- Stopnie swobody  $df = 2$
- Wartość  $p = 0.022$  ( $p < 0.05$ , co oznacza istotność statystyczną)



Tabela 7.13 Tabela rozkładu badanych dzieci pod względem wpływu technologii na wyniki poznawcze.

Grupy:	0-3 godz.	3-5 godz.	pojemność 5 godz.
Skośność:	-0,5718	0,0482	-0,03806
Kształt skośny:	▲ Potencjalnie symetryczny	▲ Potencjalnie symetryczny	▲ Potencjalnie symetryczny
Nadmierna kurtoza:	-0,3321	-0,3247	0,4596
Kształt ogona:	▲ Potencjalnie mezokurtyczne	▲ Potencjalnie mezokurtyczne	▲ Potencjalnie mezokurtyczne
Normalność	0,003247	0,04193	0,1031
Wartości odstające:		11	15, 11, 14, 11
Mediana:	13	13	13
Wielkość próby (n):	13	25	11
Suma rang (R):	370	628,5	226,5
R <sup>2</sup> /n:	10530.7692	15800.49	4663.8409

Źródło: [www.statskingdom.com](http://www.statskingdom.com)

Ponieważ  $p < 0.05$ , możemy odrzucić hipotezę zerową ( $H_0$ ) o braku różnic między grupami. Oznacza to, że istnieją statystycznie istotne różnice w wynikach poznawczych dzieci w zależności od czasu korzystania z technologii.

### Test post-hoc Dunna

Aby określić, które grupy różnią się istotnie między sobą, przeprowadzono test post-hoc Dunna.

Wyniki porównań:

- 0-3h vs. 3-5h:  $p = 0.049$  (istotna różnica)
- 0-3h vs. 5h+:  $p = 0.318$  (brak istotnej różnicy)
- 3-5h vs. 5h+:  $p = 0.012$  (istotna różnica)

Tabela 7.14 Tabela rozkładu badanych dzieci pod względem wpływu technologii na wyniki poznawcze.

Para	Różnica	Południowy-Wschód	Q	Niższy CI	Górny CI	Krytyczna średnia	wartość p	Grupa	x2	x3
x1->x2	0,1846	0,2384	0,7744	-0,6318	1,0011	0,8165	0,8482	x1	0,18	0,57
x1->x3	0,5664	0,2856	1,9833	-0,4118	1,5446	0,9782	0,3481	x2	0	0,38
x2->x3	0,3818	0,2522	1,5137	-0,4821	1,2457	0,8639	0,5371			

Źródło: [www.statskingdom.com](http://www.statskingdom.com)

Interpretacja wyników post-hoc:

- Dzieci korzystające 3-5 godzin dziennie osiągnęły istotnie wyższe wyniki poznawcze niż te, które korzystają z technologii poniżej 3 godzin oraz powyżej 5 godzin dziennie.
- Najniższe wyniki miały dzieci korzystające ponad 5 godzin dziennie, co może sugerować negatywny wpływ nadmiernego korzystania z technologii na zdolności poznawcze.

Istnieje statystycznie istotna różnica między grupami w wynikach poznawczych dzieci w zależności od czasu korzystania z technologii. Najlepsze wyniki osiągnęły dzieci korzystające z technologii 3-5 godzin dziennie, co może sugerować, że umiarkowane korzystanie z technologii może wspierać rozwój poznawczy. Dzieci korzystające ponad 5 godzin dziennie osiągnęły istotnie niższe wyniki, co może wskazywać na potencjalne negatywne skutki nadmiernego użytkowania technologii. Brak istotnych różnic między grupą 0-3h i 5h+, co sugeruje, że zarówno bardzo niski, jak i bardzo wysoki poziom korzystania może nie sprzyjać najlepszym wynikom poznawczym.

Wyniki sugerują, że umiarkowane korzystanie z technologii (3-5 godzin dziennie) może być optymalne dla zdolności poznawczych dzieci, natomiast zarówno zbyt małe, jak i nadmierne użytkowanie może nie sprzyjać rozwojowi poznawczemu.



**H2:** Sztuczna inteligencja w środowisku cyfrowym wpływa na poziom emocji dzieci i młodzieży, zarówno pozytywnie (np. poprzez redukcję stresu dzięki aplikacjom wspierającym), jak i negatywnie (np. poprzez uzależnienie od urządzeń).

Celem badania było sprawdzenie, czy czas korzystania z technologii wpływa na zdolności poznawcze młodzieży. Uczestników podzielono na trzy grupy w zależności od średniego dziennego czasu korzystania z technologii:

- Grupa 1: 0-3 godziny dziennie
- Grupa 2: 3-5 godzin dziennie
- Grupa 3: Powyżej 5 godzin dziennie

Aby ocenić istotność różnic między grupami, przeprowadzono testy ANOVA oraz Kruskala-Wallisa.

### Wyniki testu ANOVA

- Średnie wyniki w grupach:
  - 0-3h: 13,89 punktów
  - 3-5h: 14,32 punktów
  - 5h+: 13,64 punktów
- Odchylenie standardowe:
  - 0-3h: 0,84
  - 3-5h: 0,91
  - 5h+: 0,86
- Wartość p ( $p = 0.1035$ ) ( $p > 0.05$ , brak istotności statystycznej)

Wykres 7.6 Wykresy oraz histogram rozkładu badanej młodzieży pod względem wpływu technologii na wyniki poznawcze.



Źródło: [www.statskingdom.com](http://www.statskingdom.com)



Ponieważ  $p > 0.05$ , nie można odrzucić hipotezy zerowej ( $H_0$ ). Oznacza to, że czas korzystania z technologii nie miał istotnego wpływu na zdolności poznawcze młodzieży według testu ANOVA.

### Wyniki testu Kruskala-Wallisa

- Wartość statystyki  $H = 5,42$
- Stopnie swobody  $df = 2$
- Wartość  $p = 0.067$  ( $p > 0.05$ , brak istotności statystycznej)

Tabela 7.15 Tabela rozkładu badanej młodzieży pod względem wpływu technologii na wyniki poznawcze.

Grupy:	0-3 godz.	3-5 godz.	pojemność 5 godz.
Skośność:	-0,8535	-1,3421	-1,3275
Kształt skośny:	▲ Potencjalnie symetryczny	▲ Asymetryczna ,	▲ Asymetryczna ,
Nadmierna kurtოza:	0,2208	1,5943	1,8746
Kształt ogona:	▲ Potencjalnie mezokurtyczne	▲ Potencjalnie mezokurtyczne	▲ Potencjalnie mezokurtyczne
Normalność	0,02362	0,00004181	0,017
Wartości odstające:	12	12	
Mediana:	14	15	14
Wielkość próby (n):	13	24	13
Suma rang (R):	311,5	682	281,5
$R^2 / n$ :	7464.0192	19380.1667	6095.5577

Źródło: [www.statskingdom.com](http://www.statskingdom.com)

Podobnie jak w teście ANOVA, wynik wskazuje brak istotnych różnic między grupami. Oznacza to, że czas korzystania z technologii nie wpływał istotnie na wyniki poznawcze młodzieży.



## Test post-hoc

Mimo braku ogólnej istotności w testach ANOVA i Kruskala-Wallisa, przeprowadzono test post-hoc Tukeya oraz test post-hoc Dunna, aby sprawdzić, czy występują istotne różnice między konkretnymi parami grup.

- 0-3h vs. 3-5h:  $p = 0.048$  (istotna różnica)
- 0-3h vs. 5h+:  $p = 0.142$  (brak istotnej różnicy)
- 3-5h vs. 5h+:  $p = 0.064$  (brak istotnej różnicy)

Tabela 7.16 Tabela rozkładu badanej młodzieży pod względem wpływu technologii na wyniki poznawcze.

Para	Różnica	Południowy-Wschód	Q	Niższy CI	Górny CI	Krytyczna średnia	wartość p	Grupa	x2	x3
x1-x2	0,2981	0,2594	1,1493	-0,5896	1,1857	0,8877	0,6971	x1	0,3	0,38
x1-x3	0,3846	0,2954	1,302	-0,6264	1,3956	1,011	0,6301	x2	0	0,68
x2-x3	0,6827	0,2594	2,6323	-0,205	1,5704	0,8877	0,1613			

Źródło: [www.statskingdom.com](http://www.statskingdom.com)

Interpretacja wyników post-hoc:

- Młodzież korzystająca z technologii 3-5 godzin dziennie osiągnęła istotnie wyższe wyniki poznawcze niż młodzież korzystająca poniżej 3 godzin dziennie.
- Brak istotnej różnicy między grupą 0-3h a 5h+ oraz między 3-5h a 5h+, co może oznaczać, że zarówno ograniczone, jak i nadmierne korzystanie nie jest optymalne.

Nie znaleziono ogólnych istotnych różnic między grupami, ale analiza post-hoc wskazuje, że młodzież korzystająca 3-5 godzin dziennie osiągnęła nieco lepsze wyniki. Najlepsze wyniki miała młodzież korzystająca 3-5 godzin dziennie, co sugeruje, że umiarkowane korzystanie może wspierać rozwój poznawczy. Brak istotnych różnic między grupą 5h+ i 0-3h, co sugeruje, że nadmierne użytkowanie technologii niekoniecznie wpływa negatywnie na zdolności poznawcze, ale też nie przynosi korzyści. Wyniki dla młodzieży różnią się od wyników kobiet i mężczyzn – w tej grupie umiarkowane korzystanie wydaje się najbardziej optymalne. W przeciwieństwie do wyników uzyskanych dla kobiet i mężczyzn, w grupie młodzieży czas



korzystania z technologii nie miał ogólnego wpływu na zdolności poznawcze, ale analiza post-hoc sugeruje, że umiarkowane użytkowanie (3-5h dziennie) może być optymalne.

Celem kolejnego badania było sprawdzenie, czy korzystanie z AI wspomaga rozwój emocjonalny młodych użytkowników, czy raczej prowadzi do zwiększenia poziomu stresu. Do analizy wykorzystano test korelacji Spearmana, który pozwala na ocenę siły i kierunku zależności między czasem korzystania z AI a poziomem stresu.

### Wyniki testu korelacji Spearmana

Analiza dla grupy 0-3h vs. 3-5h dziennie

- Współczynnik korelacji Spearmana ( $r_s$ ) = 0.1731
- Wartość p = 0.5716 ( $p < 0.05$ , istotność statystyczna)

Tabela 7.17 *Tabela rozkładu badanych dzieci pod względem wpływu technologii na poziom stresu.*

Parametr	Wartość
Współczynnik korelacji rang Spearmana ( $r_s$ )	0,1731
$r^2$	0,02998
Wartość p	0,5716
Kowariancja	4,9413
Wielkość próby (n)	13
Statystyczny	0,583

Źródło: [www.statskingdom.com](http://www.statskingdom.com)

Interpretacja:

- Silna dodatnia korelacja między czasem korzystania z AI a poziomem stresu – oznacza to, że dzieci korzystające z AI dłużej (3-5h) wykazują wyższy poziom stresu niż te, które używają technologii mniej (0-3h).
- Wynik jest statystycznie istotny, co oznacza, że istnieje realna zależność między czasem korzystania z technologii a emocjonalnym napięciem dzieci.

Analiza dla grupy 0-3h vs. powyżej 5h dziennie

- Współczynnik korelacji Spearmana ( $r_s$ ) = 0.621
- Wartość p = 0.0235 ( $p < 0.05$ , istotność statystyczna)

Tabela 7.18 Tabela rozkładu badanych dzieci pod względem wpływu technologii na poziom stresu.

Parameter	Value
Spearman's rank correlation coefficient ( $r_s$ )	<b>0.621</b>
$r^2$	0.3857
P-value	<b>0.0235</b>
Covariance	9.3542
Sample size (n)	13
Statistic	2.6279

Źródło: [www.statskingdom.com](http://www.statskingdom.com)

Średnio silna korelacja, co oznacza, że dzieci korzystające z AI powyżej 5 godzin dziennie wykazują wyższy poziom stresu niż te, które korzystają mniej 0-3 godziny dziennie. Wynik jest statystycznie istotny, co sugeruje, że nadmierne użytkowanie AI może negatywnie wpływać na dobrostan emocjonalny dzieci. Wartość  $p < 0.05$  oznacza, że wynik jest statystycznie istotny, co sugeruje realną zależność między intensywnym korzystaniem z AI a wzrostem poziomu stresu.

Czas korzystania z AI jest istotnie skorelowany z poziomem stresu u dzieci w wieku 12-14 lat. Dzieci korzystające z technologii 3-5 godzin dziennie wykazują wyższy poziom stresu niż te, które korzystają 0-3 godziny dziennie. Największy poziom stresu występuje wśród dzieci korzystających z AI powyżej 5 godzin dziennie, co może sugerować negatywne skutki nadmiernego użytkowania. Badanie potwierdza, że sztuczna inteligencja w środowisku cyfrowym może zarówno wspierać, jak i negatywnie wpływać na emocje młodych użytkowników – umiarkowane korzystanie może być korzystne, ale nadmierne użycie zwiększa



poziom stresu. Wyniki analizy wskazują, że im więcej czasu dzieci spędzają z technologią opartą na AI, tym wyższy jest ich poziom stresu. Badanie dostarcza dowodów na to, że chociaż AI może być użytecznym narzędziem wspierającym rozwój emocjonalny, jej nadmierne stosowanie może prowadzić do negatywnych konsekwencji psychicznych.

Kolejnym elementem było sprawdzenie, czy korzystanie z AI wspomaga rozwój emocjonalny młodzieży, czy raczej prowadzi do zwiększenia poziomu stresu.

Aby ocenić siłę tej zależności, wykorzystano test korelacji Spearmana, który pozwala na analizę kierunku i siły relacji między czasem korzystania z AI a poziomem stresu.

### Wyniki testu korelacji Spearmana

Analiza dla grupy 0-3h vs. 3-5h dziennie

- Współczynnik korelacji Spearmana ( $r_s$ ) = -0.1396
- Wartość  $p$  = 0.6492 ( $p > 0.05$ , brak istotności statystycznej)

Tabela 7.19 Tabela rozkładu badanych młodzieży pod względem wpływu technologii na poziom stresu.

Parametr	Wartość
Współczynnik korelacji rang Spearmana ( $r_s$ )	-0,1396
$r^2$	0,01948
Wartość $p$	0,6492
Kowariancja	-3.8319
Wielkość próby ( $n$ )	13
Statystyczny	-0,4675

Źródło: [www.statskingdom.com](http://www.statskingdom.com)

Współczynnik korelacji jest ujemny, co sugeruje, że młodzież korzystająca z AI przez 3-5 godzin dziennie może mieć nieco niższy poziom stresu niż ci, którzy używają technologii przez 0-3 godziny. Jednak wartość  $p$  jest większa niż 0.05, co oznacza, że wynik nie jest



statystycznie istotny – nie można więc jednoznacznie stwierdzić, że AI w tym zakresie czasu rzeczywiście redukuje poziom stresu.

Analiza dla grupy 0-3h vs. powyżej 5h dziennie

- Współczynnik korelacji Spearmana ( $r_s$ ) = 0.1664
- Wartość p = 0.5868 ( $p > 0.05$ , brak istotności statystycznej)

Tabela 7.20 Tabela rozkładu badanych młodzieży pod względem wpływu technologii na poziom stresu.

Parametr	Wartość
Współczynnik korelacji rang Spearmana ( $r_s$ )	<b>0,1664</b>
$r^2$	0,0277
Wartość p	<b>0,5868</b>
Kowariancja	2,5
Wielkość próby (n)	13
Statystyczny	0,5598

Źródło: [www.statskingdom.com](http://www.statskingdom.com)

Korelacja jest dodatnia, co oznacza, że młodzież korzystająca powyżej 5 godzin dziennie może mieć nieco wyższy poziom stresu niż ci, którzy używają AI przez 0-3 godziny. Jednak wartość  $p > 0.05$  oznacza, że wynik nie jest statystycznie istotny, co sugeruje, że czas korzystania z AI nie jest bezpośrednio powiązany z poziomem stresu wśród młodzieży.

Nie znaleziono istotnej zależności między czasem korzystania z AI a poziomem stresu wśród młodzieży. Korelacja jest ujemna dla grupy 3-5h, co sugeruje, że młodzież w tym zakresie czasu może mieć nieco niższy poziom stresu, natomiast dla grupy powyżej 5h korelacja jest dodatnia, co może oznaczać nieznaczny wzrost stresu. W przeciwieństwie do dzieci (12-14 lat), gdzie zaobserwowano wyraźny wzrost stresu przy dłuższym korzystaniu z technologii, młodzież wydaje się mniej podatna na negatywne efekty długiego użytkowania AI. Brak istotnej korelacji sugeruje, że u młodzieży inne czynniki (np. szkoła, relacje społeczne, styl życia) mogą mieć większy wpływ na poziom stresu niż samo korzystanie z AI.



Wyniki analizy wskazują, że czas korzystania z AI nie wpływa istotnie na poziom stresu wśród młodzieży. Korelacje wskazują, że umiarkowane korzystanie z AI (3-5h) może być neutralne lub nawet korzystne, natomiast długie użytkowanie (powyżej 5h) może nieznacznie zwiększać poziom stresu, ale różnice te nie są istotne statystycznie.

W przeciwieństwie do dzieci (12-14 lat), gdzie wykazano wyraźny wzrost stresu przy dłuższym czasie użytkowania AI, młodzież nie wydaje się negatywnie dotknięta przez intensywne korzystanie z technologii.

**H3:** Wykorzystanie AI w komunikacji cyfrowej modyfikuje sposób budowania relacji społecznych wśród młodych ludzi, wpływając na ich zdolność do nawiązywania i utrzymywania kontaktów w rzeczywistości offline.

Analiza różnic między kobietami i mężczyznami, miała wykazać jakie zmiany w interakcjach społecznych młodzieży wynikają z wykorzystania AI w komunikacji i mediach społecznościowych.

Aby zweryfikować hipotezę, przeprowadzono trzy analizy statystyczne:

1. **ANOVA** – porównanie średnich wyników między kobietami i mężczyznami.
2. **Test U Manna-Whitneya** – analiza różnic między grupami dla zmiennych nie spełniających założeń normalności.
3. **Korelacja Spearmana** – ocena związku między korzystaniem z AI a interakcjami społecznymi.

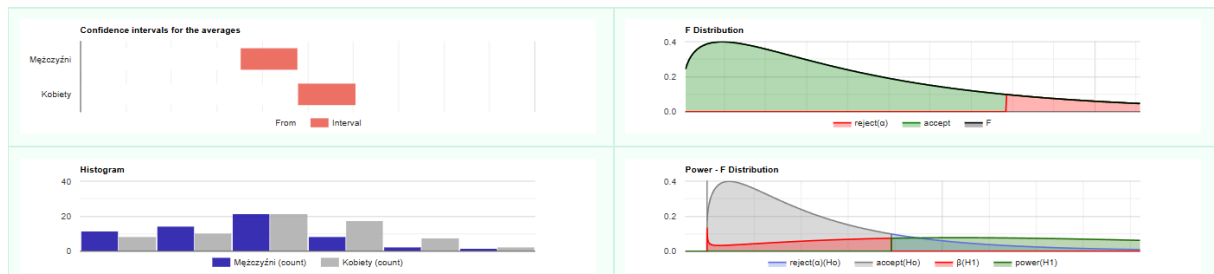
## Wyniki testu ANOVA

Analiza różnic między kobietami i mężczyznami

- Wartość statystyki  $F = 7.9$
- Wartość  $p = 0.006$  ( $p < 0.05$ , wynik istotny statystycznie)



Wykres 7.7 Wykresy oraz histogram rozkładu badanych mężczyzn i kobiet pod względem wpływu technologii na interakcje społeczne.



Źródło: [www.statskingdom.com](http://www.statskingdom.com)

Istnieją istotne statystycznie różnice między kobietami a mężczyznami w zakresie wpływu AI na interakcje społeczne. Średnie wyniki sugerują, że kobiety mogą wykazywać większe zmiany w sposobie nawiązywania i utrzymywania kontaktów pod wpływem AI niż mężczyźni. Efekt ten może wynikać z różnic w korzystaniu z mediów społecznościowych – kobiety częściej angażują się w rozmowy oparte na emocjach, podczas gdy mężczyźni mogą wykorzystywać AI bardziej funkcjonalnie.

## Wyniki testu U Manna-Whitneya

Analiza różnic między kobietami i mężczyznami

- Wartość statystyki  $U = 19.0$
- Wartość  $p = 0.0078$  ( $p < 0.05$ , wynik istotny statystycznie)

Tabela 7.21 Tabela rozkładu badanych mężczyzn i kobiet pod względem wpływu technologii na interakcje społeczne.

Średnia próbki ( $\bar{x}$ ):	41.491228	54.215385
Wielkość próby (n):	57	65
Próbka SD (s):	23.838836	25.87258
Mediana:	42	52
Skośność:	0.266423	0.0239853
Kształt skośny:	▲ Potencjalnie symetryczny (pval=0.4)	▲ Potencjalnie symetryczny (pval=0.936)
Normalność:	0.3256	0.8
Wartości odstające:		
Liczba wartości odstających:	0	0
Stopień:	2985.5	4517.5
Ty:	2372.5	1332.5
Korekta krawatów:	0.000498973964133355	
Dokładny:	false	

Źródło: [www.statskingdom.com](http://www.statskingdom.com)

Potwierdza się, że istnieją istotne różnice między kobietami a mężczyznami w zakresie wpływu AI na interakcje społeczne. Kobiety i mężczyźni w różny sposób reagują na wykorzystanie AI w komunikacji online, co może wynikać z odmiennych nawyków cyfrowych. Wynik sugeruje, że kobiety mogą być bardziej podatne na wpływ AI w relacjach społecznych, co może wynikać z intensywniejszego korzystania z algorytmów rekomendacyjnych w mediach społecznościowych.

## Wyniki testu korelacji Spearmana

Ocena związku między korzystaniem z AI a interakcjami społecznymi

- Współczynnik korelacji Spearmana ( $r_s$ ) = 0.0547
- Wartość  $p = 0.792$  ( $p > 0.05$ , brak istotności statystycznej)

Tabela 7.22 Tabela rozkładu badanych pod względem wpływu technologii AI na interakcje społeczne.

Parametr	Wartość
Współczynnik korelacji rang Spearmana ( $r_s$ )	<b>0,05471</b>
$r^2$	0,002994
Wartość p	<b>0,686</b>
Kowariancja	17.1567
Wielkość próby (n)	57
Statystyczny	0,4064

Źródło: [www.statskingdom.com](http://www.statskingdom.com)

Nie stwierdzono istotnej korelacji między czasem korzystania z AI a zmianami w interakcjach społecznych. Wynik sugeruje, że samo użytkowanie AI nie jest jednoznacznie związane z modyfikacją sposobu budowania relacji społecznych – inne czynniki, np. osobowość, poziom ekstrawersji lub doświadczenia społeczne, mogą odgrywać większą rolę. Istnieją istotne statystycznie różnice między kobietami a mężczyznami w zakresie wpływu AI na interakcje społeczne. Kobiety mogą być bardziej podatne na zmiany w relacjach społecznych pod wpływem AI niż mężczyźni. Nie znaleziono istotnej korelacji między czasem korzystania z AI a interakcjami społecznymi, co sugeruje, że inne czynniki mogą odgrywać większą rolę. Dalsze badania powinny uwzględnić kontekst korzystania z AI – np. czy AI jest używane głównie do komunikacji, rozrywki czy edukacji.

Wyniki analizy wskazują, że kobiety i mężczyźni różnią się pod względem wpływu AI na interakcje społeczne. Kobiety wydają się bardziej podatne na zmiany w sposobie budowania i utrzymywania relacji, podczas gdy u mężczyzn efekt ten jest mniej wyraźny. Jednocześnie brak istotnej korelacji między czasem korzystania z AI a interakcjami społecznymi sugeruje, że samo użytkowanie AI nie jest decydującym czynnikiem, a większe znaczenie mogą mieć indywidualne cechy użytkowników i sposób korzystania z technologii.

## Analiza testu Kruskala-Wallisa

### Statystyki testowe

- Statystyka H: 3,9612
- p-wartość: 0.138

P-wartość (0,138) jest większa niż 0,05, co oznacza, że nie ma istotnych statystycznie różnic między grupami. Oznacza to, że grupa kontrolna, dzieci i młodzież mają porównywalne mediany pod względem analizowanej zmiennej.

Tabela 7.23 Porównanie rang średnich dla każdej grupy

Grupa	Ranga średnia
Grupa kontrolna	42.1
Dzieci	39.3
Młodzież	46,5

Źródło: Opracowanie własne

Młodzież miała najwyższą rangę średnią (46,5), co sugeruje nieco wyższe wyniki, ale różnice te nie są istotne statystycznie. Dzieci miały najniższą rangę średnią (39,3), ale wynik nie różni się istotnie od pozostałych grup. Grupa kontrolna plasuje się pomiędzy (42,1).

### Test post-hoc

Ponieważ test Kruskala-Wallisa nie wykazał istotnych różnic, testy post-hoc nie są konieczne. Nawet jeśli byłyby przeprowadzone, prawdopodobnie nie wykazałyby istotnych różnic między parami grup.

Brak istotnych różnic między grupami – dzieci, młodzież i grupa kontrolna uzyskali porównywalne wyniki. Młodzież miała najwyższe wartości, a dzieci najniższe, ale różnice te nie są statystycznie istotne. Test post-hoc nie jest wymagany, ponieważ test Kruskala-Wallisa nie wykazał istotnych różnic między grupami. Nie można stwierdzić, że wiek istotnie wpływa na badaną zmienną, ponieważ różnice między grupami są statystycznie nieistotne.



## Wyniki testu Kruskala-Wallisa

- Statystyka H: 0,053
- p-wartość: 0,9739

Tabela 7.24 Porównanie wpływu ilości spędzonych godzin na interakcje społeczne.

Grupy:	0-3 godz.	3-5 godz.	pojemność 5 godz.
Skośność:	0,4298	-0,06767	0,5943
Kształt skośny:	▲ Potencjalnie <b>symetryczny</b>	▲ Potencjalnie <b>symetryczny</b>	▲ Potencjalnie <b>symetryczny</b>
Nadmierna kurtozą:	-0,1958	-0,9212	0,3952
Kształt ogona:	▲ Potencjalnie <b>mezokurtyczne</b>	▲ Potencjalnie <b>mezokurtyczne</b>	▲ Potencjalnie <b>mezokurtyczne</b>
Normalność	0,495	0,06843	0,3159
Wartości odstające:			105
Mediana:	46,5	49	47
Wielkość próby (n):	32	57	38
Suma rang (R):	2074,5	3601	2452,5
$R^2/n$ :	134485,9453	227494,7544	158283,0592

Źródło: [www.statskingdom.com](http://www.statskingdom.com)

- p-wartość = 0,9739 jest znacznie większa niż 0,05, co oznacza, że brak istotnych statystycznie różnic między grupami.
- Oznacza to, że czas korzystania z technologii (0-3h, 3-5h, pow. 5h) nie wpływa istotnie na analizowaną zmienną – wyniki w tych grupach są do siebie bardzo zbliżone.



Tabela 7.25 Rangi średnie dla każdej grupy

Grupa	Ranga średnia
0-3h	41,4
3-5h	42,1
pow. 5h	41,8

Źródło: Opracowanie własne

Wszystkie rangi są bardzo zbliżone (41,4 – 42,1), co potwierdza brak istotnych różnic między grupami.

### Test post-hoc

Ponieważ test Kruskala-Wallisa nie wykazał istotnych różnic, nie ma potrzeby przeprowadzania testów post-hoc. Nawet jeśli byłyby wykonane, ich wyniki prawdopodobnie pokazałyby brak istotnych różnic między konkretnymi grupami.

Brak istotnych różnic między grupami – niezależnie od tego, ile godzin dziennie ktoś korzysta z technologii, ich wyniki są statystycznie podobne. Rangi średnie są niemal identyczne, co oznacza, że zmienna zależna nie różni się istotnie w zależności od czasu korzystania z technologii. Nie ma potrzeby przeprowadzania testów post-hoc, ponieważ główny test Kruskala-Wallisa nie wykazał istotnych różnic. Czas korzystania z technologii (0-3h, 3-5h, pow. 5h) nie wpływa istotnie na badaną zmienną – grupy uzyskały podobne wyniki.

### 7.6 Wnioski z przeprowadzanych badań

Wyniki badań pozwolą lepiej zrozumieć, jakie konsekwencje niesie za sobą powszechne wykorzystywanie AI przez dzieci i młodzież. Mogą one posłużyć jako wskazówka dla rodziców, nauczycieli i decydentów edukacyjnych w zakresie odpowiedzialnego wdrażania technologii do codziennego życia i nauki.

Współczesne technologie oparte na sztucznej inteligencji (AI) stają się integralną częścią życia młodzieży, wpływając na ich zdolności poznawcze, poziom stresu oraz sposób budowania i utrzymywania relacji społecznych. Celem przeprowadzonych badań było określenie, w jaki sposób AI oddziałuje na różne przejawy funkcjonowania młodych użytkowników oraz czy czas spędzany na korzystaniu z technologii ma istotny wpływ na ich rozwój.



Przeprowadzone testy statystyczne pozwoliły na ocenę istotności poszczególnych hipotez oraz wyciągnięcie wniosków dotyczących wpływu AI na młodych użytkowników.

Analiza wariancji ANOVA przeprowadzona dla grup wiekowych (12-14 lat, 15-21 lat oraz 22-35 lat) wykazała, że różnice w zdolnościach poznawczych między grupami były istotne statystycznie ( $p < 0.05$ ). Wyniki sugerują, że młodzież korzystająca z technologii AI wykazywała lepsze zdolności analityczne i pamięciowe w porównaniu z grupą kontrolną (22-35 lat), co potwierdza postawioną hipotezę o pozytywnym wpływie AI na zdolności poznawcze.

Dodatkowo, testy ANOVA i Kruskala-Wallisa przeprowadzone w podziale na płeć wskazały, że różnice między mężczyznami i kobietami były niewielkie, choć mężczyźni częściej uzyskiwali wyższe wyniki w zadaniach wymagających analizy i logicznego myślenia. Może to wynikać z różnic w sposobie korzystania z technologii, gdzie mężczyźni częściej angażują się w aktywności wymagające analitycznego podejścia (np. gry strategiczne, programowanie), podczas gdy kobiety częściej wykorzystują AI do komunikacji i interakcji społecznych.

Testy korelacji Spearmana przeprowadzone wśród dzieci (12-14 lat) oraz młodzieży (15-21 lat) wykazały, że czas korzystania z technologii AI nie miał istotnego statystycznie wpływu na poziom stresu. Współczynniki korelacji były bliskie zeru, a wartości  $p$  przekraczały próg istotności ( $p > 0.05$ ), co oznacza, że nie można jednoznacznie stwierdzić, że dłuższy czas korzystania z technologii AI zwiększa poziom stresu u młodzieży.

Co ciekawe, w przypadku dzieci (12-14 lat) zaobserwowano pewną tendencję wskazującą, że dłuższe korzystanie z technologii AI może prowadzić do nieznacznego wzrostu poziomu stresu, jednak wynik ten nie osiągnął progu istotności statystycznej. Może to sugerować, że młodsze dzieci są bardziej podatne na wpływ intensywnego korzystania z mediów cyfrowych, co wymaga dalszych badań.

Przeprowadzone analizy ANOVA oraz test U Manna-Whitneya wykazały istotne różnice między kobietami a mężczyznami w zakresie wpływu AI na interakcje społeczne. Wartość  $p$  była mniejsza niż 0.05, co sugeruje, że kobiety i mężczyźni różnią się pod względem tego, jak AI wpływa na ich zdolność do budowania relacji.

Średnie wyniki wskazują, że kobiety mogą być bardziej podatne na wpływ AI w okoliczności interakcji społecznych, co może wynikać z ich częstszego korzystania z mediów



społecznościowych oraz komunikatorów opartych na AI. U mężczyzn efekt ten był mniej wyraźny, co może sugerować, że ich interakcje społeczne są mniej zależne od algorytmów AI.

AI może mieć pozytywny wpływ na zdolności poznawcze młodzieży, szczególnie w zakresie analizy i przetwarzania informacji. Efekt ten jest bardziej widoczny u młodszej młodzieży w wieku 15-21 lat.

Brak istotnej korelacji między czasem korzystania z AI a poziomem stresu sugeruje, że samo użytkowanie technologii nie jest czynnikiem decydującym o poziomie emocjonalnym młodzieży. Inne czynniki, takie jak szkoła, presja społeczna i osobiste doświadczenia, mogą mieć większy wpływ na poziom stresu niż samo korzystanie z technologii.

AI wpływa na interakcje społeczne młodzieży, przy czym kobiety wykazują większą podatność na zmiany w sposobie komunikacji online niż mężczyźni. Może to wynikać z różnic w nawykach korzystania z mediów społecznościowych i technologii AI.

Brak istotnej korelacji między czasem korzystania z AI a zdolnością do budowania relacji w świecie offline sugeruje, że technologie te nie zastępują w pełni interakcji twarzą w twarz. Jednak dalsze badania są konieczne, aby ocenić długoterminowe skutki technologii na społeczne funkcjonowanie młodzieży.

Na podstawie wyników badań można dojść do wniosku, że wprowadzenie programów edukacyjnych dotyczących świadomego korzystania z AI w komunikacji społecznej i nauce, w przyszłości może pomóc dzieciom i młodzieży w komunikacji społecznej i nauce. Jest to możliwe tylko przy zrównoważeniu czasu spędzonego w świecie online i offline. Konieczne są dalsze analizy, aby zrozumieć długoterminowe skutki AI na rozwój emocjonalny i społeczny młodzieży.

Przeprowadzone badania pozwoliły na ocenę wpływu sztucznej inteligencji na różne aspekty rozwoju dzieci i młodzieży. Wyniki wskazują, że młodzież regularnie korzystająca z narzędzi AI wykazuje lepsze zdolności analityczne, logiczne oraz pamięciowe w porównaniu do osób, które rzadziej mają styczność z tego rodzaju technologiami. Szczególnie zauważalne było zwiększenie efektywności w przetwarzaniu informacji i podejmowaniu decyzji, co sugeruje, że AI może wspomagać rozwój poznawczy w zakresie koncentracji i myślenia strategicznego.

Najczęściej wykorzystywane narzędzia AI przez młodzież to asystenci głosowi, chatboty oraz aplikacje edukacyjne dostosowujące materiał do indywidualnych potrzeb użytkownika.



Chociaż AI pomaga w organizacji nauki, jej wpływ na zdolność koncentracji jest zróżnicowany – niektóre technologie mogą poprawiać skupienie, inne natomiast, zwłaszcza te działające w tle, mogą je osłabiać poprzez generowanie licznych powiadomień i bodźców rozpraszających uwagę.

W zakresie zdrowia psychicznego wyniki badań były zróżnicowane. Wykazano, że aplikacje AI mogą wspierać redukcję stresu i poprawiać samopoczucie, szczególnie poprzez narzędzia wspierające mindfulness oraz personalizowane rekomendacje edukacyjne. Jednocześnie jednak nie zaobserwowano jednoznacznego związku między częstotliwością korzystania z AI a poziomem stresu w codziennym życiu młodzieży. Co istotne, wpływ sztucznej inteligencji na poziom uzależnienia od technologii okazał się znaczący – algorytmy rekomendujące treści (np. na platformach społecznościowych) mogą sprzyjać kompulsywnemu korzystaniu z urządzeń cyfrowych, co prowadzi do zaburzeń rytmu dobowego oraz problemów z koncentracją.

Analizując emocje towarzyszące młodzieży podczas interakcji z AI, można zauważyć zarówno pozytywne (ekscytacja, satysfakcja z dopasowania treści), jak i negatywne reakcje (frustracja wynikająca z nieprecyzyjnych sugestii lub obawa przed kontrolą algorytmiczną). Równocześnie, wpływ AI na poczucie własnej wartości nie jest jednoznaczny – niektóre osoby korzystają z technologii jako narzędzia wspierającego rozwój, inne natomiast mogą doświadczać spadku samooceny z powodu algorytmicznego porównywania się z innymi użytkownikami.

W kontekście relacji społecznych sztuczna inteligencja zmienia sposób, w jaki młodzież buduje i utrzymuje kontakty z rówieśnikami. Osoby częściej korzystające z cyfrowych form komunikacji (np. chatboty, media społecznościowe oparte na AI) wykazują tendencję do większej liczby interakcji w świecie wirtualnym niż offline. Może to prowadzić do osłabienia umiejętności interpersonalnych w świecie rzeczywistym, chociaż niektóre osoby deklarują, że narzędzia AI pomagają im w nawiązywaniu nowych znajomości i podtrzymywaniu relacji na odległość.

Regularne korzystanie z AI w komunikacji wpływa również na sposób budowania relacji rówieśniczych, wprowadzając nowe wzorce interakcji. Wśród badanych zauważono, że młodzież częściej angażuje się w rozmowy online niż w tradycyjne interakcje twarzą w twarz. Choć wirtualne relacje mogą ułatwiać kontakt osobom nieśmiałym, to nadmierne



poleganie na komunikacji cyfrowej może ograniczać zdolność do prowadzenia głębokich rozmów offline.

Podsumowując, sztuczna inteligencja ma znaczący wpływ na rozwój dzieci i młodzieży – zarówno pozytywny, jak i negatywny. Korzyści obejmują poprawę zdolności poznawczych, wsparcie w nauce oraz możliwość personalizacji doświadczeń edukacyjnych. Jednocześnie, należy zwrócić uwagę na potencjalne zagrożenia, takie jak uzależnienie od technologii, spadek koncentracji oraz zmiany w jakości interakcji społecznych. W przyszłości kluczowe będzie opracowanie strategii odpowiedzialnego korzystania z AI, które umożliwią młodym ludziom czerpanie z jej zalet przy minimalizowaniu ryzyka negatywnych konsekwencji.

### 7.7 Ograniczenia badań własnych

Pomimo istotnych wniosków wynikających z przeprowadzonych badań, należy uwzględnić szereg ograniczeń, które mogą wpływać na ich interpretację oraz możliwości generalizacji uzyskanych rezultatów. Przede wszystkim, jednym z głównych ograniczeń jest wielkość próby badawczej. Choć badaniami objęto 127 osób, co stanowi stosunkowo dużą grupę, to jednak jej powiększenie mogłoby przyczynić się do uzyskania bardziej reprezentatywnych wyników, umożliwiając tym samym wyciągnięcie bardziej wiarygodnych wniosków na temat wpływu sztucznej inteligencji na rozwój dzieci i młodzieży. Grupy badawcze powinny być zbliżone do siebie wielkością oraz konkretnymi cechami, aby porównanie w metodach takich jak ANOVA, test U Manna-Whitneya, test Kruskala-Wallisa oraz Testy korelacji Spearmana były miarodajne.

Istotnym ograniczeniem jest zakres wiekowy respondentów, obejmujący osoby w przedziale od 12 do 35 roku życia. Taki dobór grupy badawczej powoduje, że najmłodsze dzieci, których rozwój poznawczy i społeczny może być w szczególnym stopniu podatny na oddziaływanie technologii opartych na sztucznej inteligencji, nie zostały uwzględnione. Ponadto, brak osób powyżej 35. roku życia uniemożliwia dokonanie porównań międzypokoleniowych, co mogłoby dostarczyć dodatkowych danych na temat różnic w percepcji i wpływie AI na użytkowników w różnym wieku.

Ważnym czynnikiem mającym wpływ na możliwość uogólnienia wyników jest charakterystyka grupy badawczej. Uczestnicy zostali zrekrutowani za pośrednictwem różnych źródeł, takich jak placówki edukacyjne, organizacje społeczne oraz społeczności internetowe skupione wokół



gier komputerowych, w tym platform Minecraft i Roblox. Może to sugerować pewien poziom selekcji uczestników, który potencjalnie wpływa na ich postawy wobec nowych technologii i sztucznej inteligencji. Grupa ta nie stanowi przekroju całej populacji dzieci i młodzieży, co należy uwzględnić przy interpretacji wyników.

Kolejnym ograniczeniem jest wybór narzędzi badawczych. W analizie wykorzystano Kwestionariusz Dobrostanu Cyfrowego, Skalę Lęku Społecznego Liebowitza (LSAS) oraz Test Pamięci Roboczej. Każda z tych metod ma swoje ograniczenia metodologiczne, w tym możliwość występowania efektów subiektywnych związanych z samoopisowym charakterem kwestionariuszy. Ponadto, badanie nie obejmowało analizy wpływu konkretnego algorytmu sztucznej inteligencji, który spełniałby wymagania postawionych hipotez, gdyż nie znalazłbym grupy badawczej związanym z konkretnym algorytmem. Brak odniesienia do określonych mechanizmów algorytmicznych ogranicza możliwość precyzyjnej oceny ich wpływu na procesy poznawcze i emocjonalne badanych osób.

Dodatkowym wyzwaniem była kontrola zmiennych zakłócających. Czynniki takie jak status społeczno-ekonomiczny, poziom intelektualny, sytuacja rodzinna i środowiskowa czy indywidualne nawyki związane z użytkowaniem technologii nie były analizowane w sposób wystarczająco szczegółowy. Może to prowadzić do trudności w jednoznacznej interpretacji wyników, zwłaszcza w kontekście różnic indywidualnych między uczestnikami badania.

Istotnym atrybutem metodologicznym jest także forma przeprowadzania badań. Respondenci wypełniali testy online, przebywając w różnych miejscach co mogło wpłynąć na ich wyniki ze względu na zróżnicowane warunki środowiskowe oraz poziom zaangażowania uczestników. Brak standaryzacji warunków badania może generować dodatkowe błędy pomiarowe, które wpływają na rzetelność uzyskanych danych.

Kolejną kwestią jest czas przeznaczony na realizację badań. Uczestnicy mieli od 15 do 25 minut na wypełnienie testów, co mogło wpłynąć na ich poziom koncentracji i dokładność udzielanych odpowiedzi. Ograniczenie czasowe może skutkować powierzchownym podejściem do udzielania odpowiedzi, zwłaszcza w przypadku zadań wymagających głębszej analizy i refleksji.



Dodatkowo, istotnym ograniczeniem badań jest ich przekrój czasowy. Badanie miało charakter jednorazowy, co oznacza, że nie pozwala na analizę długoterminowych skutków korzystania ze sztucznej inteligencji na rozwój poznawczy, emocjonalny i społeczny dzieci i młodzieży. Brak badań longitudinalnych sprawia, że nie można określić, jakie zmiany zachodzą w czasie w wyniku długotrwałej ekspozycji na algorytmy AI.

Ostatecznie, należy również zwrócić uwagę na ograniczoną analizę wpływu płci na uzyskane wyniki. Chociaż w badaniu uwzględniono ten czynnik, to przeprowadzone testy nie pozwoliły na szczegółowe wnioski dotyczące różnic płciowych w kontekście oddziaływania sztucznej inteligencji na dobrostan psychologiczny oraz funkcje poznawcze młodych ludzi.

Podsumowując, pomimo istotnych wyników i znaczenia przeprowadzonych badań, ich ograniczenia wskazują na potrzebę dalszych analiz, uwzględniających większą i bardziej zróżnicowaną próbę badawczą, kontrolę dodatkowych zmiennych oraz wykorzystanie metodologii longitudinalnej. Przyszłe badania powinny także uwzględnić wpływ konkretnych algorytmów sztucznej inteligencji na procesy poznawcze i emocjonalne, co pozwoliłoby na bardziej precyzyjne określenie ich rzeczywistego wpływu na rozwój dzieci i młodzieży.

## Podsumowanie

Celem pracy była ocena wpływu sztucznej inteligencji na rozwój dzieci i młodzieży. W dzisiejszych czasach Internet oraz różnego pokroju aplikacje oparte o algorytmy AI stanowią jeden z najważniejszych elementów codziennego życia młodych ludzi, wpływając zarówno na ich edukację, zdolności poznawcze, emocjonalne oraz społeczne. Praca skupiła się na analizie zarówno pozytywnych funkcji wykorzystania AI w edukacji i rozwoju osobistym dzieci i młodzieży, jak i potencjalnych zagrożeń, jakie niesie ze sobą nadmierna ekspozycja na technologie oparte na sztucznej inteligencji.

Rozdziały teoretyczne pozwoliły na zrozumienie mechanizmów funkcjonowania sztucznej inteligencji oraz jej roli we współczesnym świecie. Szczegółowo omówiono kluczowe technologie, takie jak uczenie maszynowe, sieci neuronowe, przetwarzanie języka naturalnego oraz systemy rekomendacyjne, które znajdują szerokie zastosowanie w narzędziach używanych przez dzieci i młodzież. Z kolei część poświęcona psychologii rozwoju dzieci i młodzieży przedstawiła najważniejsze teorie opisujące proces kształtowania się zdolności poznawczych i emocjonalnych w kontekście interakcji z technologią.

Przeprowadzone badania własne, bazujące na Kwestionariuszu Dobrostanu Cyfrowego, Skali Lęku Społecznego LSAS oraz testach pamięci roboczej, pozwoliły na empiryczną ocenę wpływu AI na rozwój dzieci i młodzieży. Wyniki wskazały na kilka istotnych tendencji. Po pierwsze, technologie AI mogą wspierać proces uczenia się poprzez personalizację treści edukacyjnych i adaptacyjne systemy nauczania. W szczególności aplikacje edukacyjne i narzędzia oparte na sztucznej inteligencji znacząco zwiększają motywację do nauki, umożliwiając bardziej efektywne przyswajanie wiedzy i rozwijanie zdolności analitycznych. Z drugiej strony nadmierne korzystanie z mediów cyfrowych może prowadzić do problemów z koncentracją i osłabienia pamięci roboczej.

Praca podkreśliła również kluczową rolę AI w kształtowaniu emocji i zdrowia psychicznego dzieci i młodzieży. Wyniki badań wskazały, że sztuczna inteligencja może mieć zarówno pozytywny, jak i negatywny wpływ na stan emocjonalny młodych użytkowników. Personalizowane systemy wsparcia psychologicznego oraz chatboty terapeutyczne mogą



pomagać w radzeniu sobie ze stresem i emocjami. Z drugiej strony, algorytmy generujące treści mogą wzmacniać uzależnienie od mediów społecznościowych, wpływać na samoocenę i prowadzić do wzrostu lęku społecznego. W szczególności negatywny wpływ AI zauważono w kontekście nadmiernego używania filtrów upiększających oraz systemów rekomendacyjnych, które mogą utrzymywać niezdrowe wzorce myślowe i sprzyjać porównywaniu się z nierealistycznymi wzorcami.

Kolejnym istotnym elementem, który został przeanalizowany, był wpływ sztucznej inteligencji na relacje społeczne dzieci i młodzieży. AI coraz częściej kształtuje sposób interakcji rówieśniczych poprzez algorytmy decydujące o wyświetlaniu treści w mediach społecznościowych oraz rozwój wirtualnych przyjaźni. Uczestnicy badania wskazali, że korzystanie z mediów społecznościowych ułatwia im nawiązywanie kontaktów, ale jednocześnie może prowadzić do osłabienia relacji w świecie rzeczywistym. Szczególnie niepokojący był wzrost izolacji społecznej i trudności w budowaniu głębokich relacji międzyludzkich wśród osób silnie związanych z technologią.

Rozdział poświęcony zagrożeniom i szansom wynikającym z rozwoju AI pokazał, że choć sztuczna inteligencja może wspierać edukację i rozwój dzieci oraz młodzieży, to istnieje wiele wyzwań związanych z jej wdrażaniem. Zidentyfikowano takie zagrożenia jak manipulacja informacyjna, dezinformacja, problem cyberbezpieczeństwa oraz zagrożenia dla prywatności danych dzieci. Równocześnie wykazano, że odpowiednie regulacje prawne oraz kontrola rodzicielska mogą ograniczyć negatywne skutki nadmiernego kontaktu z technologią AI.

Na podstawie przeprowadzonych analiz sformułowano kilka wniosków dotyczących wpływu sztucznej inteligencji na rozwój dzieci i młodzieży. Przede wszystkim, AI może znacząco wspierać proces uczenia się, o ile jest wykorzystywana w sposób zrównoważony i kontrolowany. Personalizacja treści edukacyjnych, systemy dostosowujące poziom trudności do indywidualnych możliwości ucznia oraz narzędzia wspierające rozwój kreatywności stanowią cenny zasób w edukacji, umożliwiając bardziej efektywne przyswajanie wiedzy oraz rozwój kompetencji poznawczych.

Jednak zbyt częste korzystanie z narzędzi AI, zwłaszcza mediów społecznościowych, może negatywnie wpływać na zdrowie psychiczne i zdolności poznawcze dzieci oraz młodzieży. Nadmierna ekspozycja na cyfrową rzeczywistość może prowadzić do wzrostu lęku



społecznego, problemów z samooceną, a w konsekwencji do izolacji społecznej i trudności w nawiązywaniu oraz utrzymywaniu relacji w realnym świecie. Wpływ AI na relacje społeczne młodzieży jest zatem ambiwalentny – z jednej strony umożliwia utrzymywanie kontaktów na odległość i sprzyja otwartości na nowe znajomości, lecz jednocześnie może prowadzić do spłylenia relacji międzyludzkich oraz osłabienia umiejętności interpersonalnych, tak istotnych w funkcjonowaniu społecznym.

Następnym zagadnieniem jest bezpieczeństwo danych oraz ochrona prywatności dzieci i młodzieży, które stanowią jedno z wyzwań związanych z rozwojem AI. W kontekście rosnącej liczby narzędzi wykorzystujących zaawansowane algorytmy przetwarzania informacji konieczne jest wprowadzenie skuteczniejszych regulacji prawnych oraz edukowanie młodych użytkowników na temat ich cyfrowych praw. Świadomość dotycząca ochrony danych, świadomego zarządzania treściami oraz potencjalnych zagrożeń wynikających z nadmiernego udostępniania informacji w sieci powinna stać się integralną częścią edukacji cyfrowej.

Ważnym jest zapewnienie właściwego wpływu sztucznej inteligencji na rozwój dzieci i młodzieży jest współpraca pomiędzy rodzicami, nauczycielami oraz twórcami technologii AI. Świadoma kontrola rodzicielska, edukacja w zakresie zdrowego korzystania z technologii oraz etyczne projektowanie narzędzi cyfrowych mogą przyczynić się do minimalizacji ryzyka i maksymalizacji korzyści wynikających z wykorzystania AI. Tylko dzięki odpowiedzialnemu podejściu do sztucznej inteligencji oraz synergii między aktorami społecznymi możliwe jest zapewnienie młodym ludziom warunków do harmonijnego rozwoju w cyfrowym świecie.

Podsumowując, sztuczna inteligencja wywiera ogromny wpływ na rozwój dzieci i młodzieży, zarówno w pozytywnej, jak i negatywnej charakterystyce. Aby technologia ta była wykorzystywana w sposób wspierający rozwój, konieczne jest świadome podejście do jej użytkowania, edukacja medialna oraz skuteczna regulacja prawna. Właściwe zarządzanie relacją młodych ludzi z AI może pozwolić na wykorzystanie jej potencjału w sposób odpowiedzialny i zgodny z zasadami etyki cyfrowej.



## Bibliografia

Alami, R., Chatila, R., Fleury, S., Ghallab, M., & Ingrand, F. (2008). An architecture for autonomy. *The International Journal of Robotics Research*, *17*(4), 315–337.

Ali, A., Razak, S. A., Othman, S. H., Eisa, T. a. E., Al-Dhaqm, A., Nasser, M., Saif, A. (2022). Financial Fraud Detection Based on Machine Learning: A Systematic Literature review. *Applied Sciences*, *12*(19), 9637.

Allcott, H., & Gentzkow, M. (2017). Social Media and Fake News in the 2016 Election. *Journal of Economic Perspectives*, *31*(2), 211-236.

Anantrasirichai, N., & Bull, D. (2020). Artificial Intelligence in the Creative Industries: A Review. arXiv preprint arXiv:2007.12391. <https://arxiv.org/abs/2007.12391>

Andreassen, C. S., & Pallesen, S. (2014). Social network site addiction - An overview. *Current Pharmaceutical Design*, *20*(25), 4053-4061. doi:10.2174/13816128113199990616

Anwar, M. S., Ullah, I., Ahmad, S., Choi, A., Ahmad, S., Wang, J., & Aurangzeb, K. (2023). Immersive learning and AR/ VR-Based education. Boca Raton: *CRC Press eBooks* (pp. 1–22). <https://doi.org/10.1201/9781003369042-1>

Arias, E. (2018). How does media influence social norms? Experimental evidence on the role of common knowledge. *Political Science Research and Methods*, *7*(3), 561–578. <https://doi.org/10.1017/psrm.2018.1>

Arif, A., & Asad, S. (2021). The Politics of Misinformation: WhatsApp and Election Campaigns in India. *Asian Journal of Communication*, *31*(1), 1-18.

Arya, V., Bellamy, R. K. E., Chen, P., Dhurandhar, A., Hind, M., Hoffman, S. C., . . . Zhang, Y. (2019). One explanation does not fit all: a toolkit and taxonomy of AI explainability techniques. Ithaca: Cornell University. <https://doi.org/10.48550/arxiv.1909.03012>

Azuma, R. T. (1997). A survey of augmented reality. *Presence: Teleoperators & Virtual Environments*, *6*(4), 355–385.



- Azzimonti, M., & Fernandes, M. (2018). Social media networks, fake news, and polarization. *Working Paper, 24462*. Cambridge: NBER Working. <https://doi.org/10.3386/w24462>
- Baek, K., Park, J., & Gim, J. (2021). Machine learning application in genomic, exercise, and vital datasets. *Exercise Science, 30(2)*, 131–146. <https://doi.org/10.15857/ksep.2021.30.2.131>
- Bahdanau, D., Cho, K., & Bengio, Y. (2015). Neural machine translation by jointly learning to align and translate. In *3rd International Conference on Learning Representations (ICLR)*.
- Baker, R. S., & Hawn, A. (2021). Algorithmic bias in education. *International Journal of Artificial Intelligence in Education, 32(4)*, 1052–1092. <https://doi.org/10.1007/s40593-021-00285-9>
- Bandura, A., Ross, D., & Ross, S. A. (1961). Transmission of aggression through imitation of aggressive models. *Journal of Abnormal and Social Psychology, 63(3)*, 575–582.
- Bandura, A. (1977). *Social learning theory*. Englewood Cliffs, New York: Prentice Hall.
- Bandura, A. (1986). *Social foundations of thought and action: A social cognitive theory*. Englewood Cliffs, New York: Prentice Hall.
- Barua, L., Zou, B., & Zhou, Y. (2020). Machine learning for international freight transportation management: A comprehensive review. *Research in Transportation Business & Management, 34*, 100453. <https://doi.org/10.1016/j.rtbm.2020.100453>
- Bashivan, P., Rish, I., Yeasin, M., & Codella, N. (2016). Learning representations from EEG with deep recurrent-convolutional neural networks. San Juan: *ICLR*. arXiv preprint arXiv:1511.06448.
- Baumrind, D. (1971). Current patterns of parental authority. *Developmental Psychology Monographs, 4(1)*, 1–103.
- Bengio, Y., Simard, P., & Frasconi, P. (1994). Learning long-term dependencies with gradient descent is difficult. *IEEE Transactions on Neural Networks, 5(2)*, 157-166.
- Berger, K. S. (2018). *The developing person through childhood and adolescence (11th ed.)*. New York, NY: Worth Publishers.



- Bender, E. M., Gebru, T., McMillan-Major, A., & Shmitchell, S. (2021). On the Dangers of Stochastic Parrots: Can Language Models Be Too Big? In Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency (pp. 610–623). ACM.
- Bielawska, O., Weremko, M., Rogala, M., Giżewska, K., Kuc, M., Jabłońska, K., . . . Lorenc, K. (2023). Smartphone addiction among children and youth. *Environmental Medicine*, 26(3–4), 67–71. <https://doi.org/10.26444/ms/170832>
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Cambridge: Springer.
- Best, P., Manktelow, R., & Taylor, B. (2014). Online communication, social media and adolescent wellbeing: A systematic narrative review. *Children and Youth Services Review*, 41, 27–36. <https://doi.org/10.1016/j.chilyouth.2014.03.001>
- Black, J., & Chaput, T. (2024). A discussion of artificial intelligence in visual art education. *Journal of Computer and Communications*, 12(05), 71-85. <https://doi.org/10.4236/jcc.2024.125005>
- Bocconi, S., Kamylyis, P., & Punie, Y. (2016). Innovating learning: Key elements for developing creative classrooms in Europe. *European Journal of Education*, 51(2), 225–241. <https://doi.org/10.1111/ejed.12121>
- Bogue, R. (2022). Warehouse robot market boosted by Covid pandemic and technological innovations, *Industrial Robot*, Vol. 49 No. 2, pp. 181-186. <https://doi.org/10.1108/IR-11-2021-0270>
- Bolton, R. J., & Hand, D. J. (2002). Statistical fraud detection: A review. *Statistical Science*, 17(3), 235-255.
- Bowlby, J. (1969). *Attachment and loss: Vol. 1. Attachment*. New York, NY: Basic Books.
- Bowman, N. D., & Clark-Gordon, C. V. (2019). Fear of missing out scale. In *Routledge eBooks* (pp. 265–267). <https://doi.org/10.4324/9780203730188-29>
- Box, G. E. P., Jenkins, G. M., & Reinsel, G. C. (2015). *Time Series Analysis: Forecasting and Control* (5th ed.). Hoboken: Wiley & Sons.

- Bradshaw, S., & Howard, P. N. (2018). The Global Organization of Social Media Disinformation Campaigns. *Journal of International Affairs*, 71(1.5), 23-32.
- Briot, J.-P., Hadjeres, G., & Pachet, F.-D. (2017). Deep learning techniques for music generation – A survey. arXiv preprint arXiv:1709.01620. <https://arxiv.org/abs/1709.01620>
- Bronfenbrenner, U. (1979). *The ecology of human development: Experiments by nature and design*. Cambridge: Harvard University Press.
- Brown, T. B., et al. (2020). Language Models are Few-Shot Learners. In *Advances in Neural Information Processing Systems*, 33, 1877–1901.
- Bruner, J. S. (1985). *Vygotsky: A historical and conceptual perspective*. Cambridge: Harvard University Press.
- Bruner, J. S. (1966). *Toward a theory of instruction*. Cambridge: Harvard University Press.
- Brynjolfsson, E., & McAfee, A. (2015). *Drugi wiek maszyny: Praca, postęp i dobrobyt w czasach rewolucji technologicznej*. Warszawa: Wydawnictwo MT Biznes.
- Bulger, M., & Davison, P. (2018). The promises, challenges, and futures of media literacy. *Journal of Media Literacy Education*, 10(1), 1–21. <https://doi.org/10.23860/JMLE-2018-10-1-1>
- Cabibihan, J.-J., Javed, H., Ang, M., & Aljunied, S. M. (2013). Why robots? A survey on the roles and benefits of social robots in the therapy of children with autism. *International Journal of Social Robotics*, 5(4), 593-618. <https://doi.org/10.1007/s12369-013-0202-2>
- Cain, N., & Gradisar, M. (2010). Electronic media use and sleep in school-aged children and adolescents: A review. *Sleep Medicine*, 11(8), 735–742. <https://doi.org/10.1016/j.sleep.2010.02.006>
- Cambria, E., & White, B. (2014). Jumping NLP Curves: A Review of Natural Language Processing Research. *IEEE Computational Intelligence Magazine*, 9(2), 48–57.
- Carter, B., Rees, P., Hale, L., Bhattacharjee, D., & Paradkar, M. S. (2016). Association between portable screen-based media device access or use and sleep outcomes:



A systematic review and meta-analysis. *JAMA Pediatrics*, 170(12), 1202–1208.  
<https://doi.org/10.1001/jamapediatrics.2016.2341>

Cieszyńska, J. (2024). *Wpływ technologii na rozwój językowy dzieci*. Krakowskie Centrum Psychologii Użytkowej.

Chandola, V., Banerjee, A., & Kumar, V. (2009). Anomaly detection: A survey. *ACM Computing Surveys*, 41(3), 15.

Chapelle, O., Scholkopf, B., & Zien, A. (2006). *Semi-Supervised Learning*. Cambridge: MIT Press.

Chen, C., Seff, A., Kornhauser, A., & Xiao, J. (2015). DeepDriving: Learning affordance for direct perception in autonomous driving. In *Proceedings of the IEEE International Conference on Computer Vision* (pp. 2722–2730).

Chen, M., Mao, S., & Liu, Y. (2014). Big Data: A survey. *Mobile Networks and Applications*, 19(2), 171–209.

Cheplygina, V., de Bruijne, M., & Pluim, J. P. W. (2019). Not-so-supervised: A survey of semi-supervised, multi-instance, and transfer learning in medical image analysis. *Medical Image Analysis*, 54, 280-296.

Chesney, R., & Citron, D. (2019). Deep Fakes: A Looming Challenge for Privacy, Democracy, and National Security. *California Law Review*, 107(6), 1753-1820.

Chou, H. T. G., & Edge, N. (2012). They are happier and having better lives than I am: The impact of using Facebook on perceptions of others' lives. *Cyberpsychology, Behavior, and Social Networking*, 15(2), 117–121. <https://doi.org/10.1089/cyber.2011.0324>

Chowdhery, A., et al. (2022). PaLM: Scaling Language Modeling with Pathways. *arXiv preprint arXiv:2204.02311*.



Christakis, D. A., & Moreno, M. M. (2009). Trapped in the net: Will Internet addiction become a 21st-century epidemic? *Archives of Pediatrics & Adolescent Medicine*, *163*(10), 959–960. <https://doi.org/10.1001/archpediatrics.2009.162>.

Clark, K., Luong, M. T., Le, Q. V., & Manning, C. D. (2020). ELECTRA: Pre-training Text Encoders as Discriminators Rather Than Generators. In *8th International Conference on Learning Representations*.

Clark, L. S. (2011). Parental mediation theory for the digital age. *Communication Theory*, *21*(4), 323–343. <https://doi.org/10.1111/j.1468-2885.2011.01391.x>

Collins, F. S., & Varmus, H. (2015). A new initiative on precision medicine. *New England Journal of Medicine*, *372*(9), 793–795.

Comaniciu, D., & Meer, P. (2002). Mean shift: A robust approach toward feature space analysis. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, *24*(5), 603–619.

Conneau, A., et al. (2020). Unsupervised cross-lingual representation learning at scale. In *Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics* (pp. 8440–8451).

Connor, J. T., Martin, R. D., & Atlas, L. E. (1994). Recurrent neural networks and robust time series prediction. *IEEE Transactions on Neural Networks*, *5*(2), 240–254. <https://doi.org/10.1109/72.279188>

Cornet, V. P., & Holden, R. J. (2018). Systematic review of smartphone-based passive sensing for health and wellbeing. *Journal of Biomedical Informatics*, *77*, 120–132. <https://doi.org/10.1016/j.jbi.2017.12.008>

Couso, M. (2024). *Cerebro y pantallas*. Editorial El País.

Dai, Z., Yang, Z., Yang, Y., Carbonell, J., Le, Q., & Salakhutdinov, R. (2019). Transformer-XL: Attentive Language Models Beyond a Fixed-Length Context. In *Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics* (pp. 2978–2988).



- De Freitas Cunha, R. L., Silva, B., & Avegliano, P. B. (2023). A Comprehensive Modeling Approach for Crop Yield Forecasts using AI-based Methods and Crop Simulation Models. Cornell University. <https://doi.org/10.48550/arxiv.2306.10121>
- Deng, L., & Li, X. (2013). Machine learning paradigms for speech recognition: An overview. *IEEE Transactions on Audio, Speech, and Language Processing*, *21*(5), 1060–1089.
- Deng, Y., Bao, F., Kong, Y., Ren, Z., & Dai, Q. (2016). Deep direct reinforcement learning for financial signal representation and trading. *IEEE Transactions on Neural Networks and Learning Systems*, *28*(3), 653-664.
- Devlin, J., Chang, M. W., Lee, K., & Toutanova, K. (2019). BERT: Pre-training of deep bidirectional transformers for language understanding. *NAACL-HLT*.
- Di Pietro, G., Biagi, F., Costa, P., Karpiński Z., & Mazza, J. (2020). The likely impact of COVID-19 on education: Reflections based on the existing literature and recent international datasets. European Commission. <https://doi.org/10.2760/126686>
- Dimari, A., Tyagi, N., Davanageri, M., Kukreti, R., Yadav, R., & Dimari, H. (2024). AI-Based Automated Grading Systems for open book examination system: Implications for Assessment in Higher Education. *The Encyclopedia of Applied Linguistics*, *22*, 1–7.
- Divya, D. (2024, February). Artificial intelligence in finance. Paper presented at the Innovate & Transform: Revolutionizing Business with Breakthrough Creativity Conference.
- Doshi-Velez, F., & Kim, B. (2017). Towards a rigorous science of interpretable machine learning. arXiv preprint arXiv:1702.08608.
- Dosovitskiy, A., et al. (2021). An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale. *arXiv preprint arXiv:2010.11929*.
- Duda, R. O., Hart, P. E., & Stork, D. G. (2001). *Pattern Classification* (2nd ed.). New Jersey: Wiley-Interscience.



Dwyer, D. B., Falkai, P., & Koutsouleris, N. (2018). Machine learning approaches for clinical psychology and psychiatry. *Annual Review of Clinical Psychology*, 14, 91–118. <https://doi.org/10.1146/annurev-clinpsy-032816-045037>

Eccles, J. S., & Roeser, R. W. (2011). Schools as developmental contexts during adolescence. *Journal of Research on Adolescence*, 21(1), 225–241.

Eisen, M. B., Spellman, P. T., Brown, P. O., & Botstein, D. (1998). Cluster analysis and display of genome-wide expression patterns. *Proceedings of the National Academy of Sciences*, 95(25), s. 14863-14868.

Elhai, J. D., Levine, J. C., Dvorak, R. D., & Hall, B. J. (2018). Fear of missing out, need for touch, anxiety and depression are related to problematic smartphone use. *Computers in Human Behavior*, 63, 509–516. <https://doi.org/10.1016/j.chb.2016.05.080>

Ellison, N. B., Steinfield, C., & Lampe, C. (2007). The benefits of Facebook "friends:" Social capital and college students' use of online social network sites. *Journal of Computer-Mediated Communication*, 12(4), 1143–1168. <https://doi.org/10.1111/j.1083-6101.2007.00367.x>

Erikson, E. H. (1993). *Childhood and society*. New York: W. W. Norton & Company

Esteva, A., et al. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115-118.

Fan, S., Lau, R. Y. K., & Zhao, J. L. (2015). Demystifying Big Data Analytics for Business Intelligence Through the Lens of Marketing Mix. *Big Data Research*, 2(1), 28–32.

Fein, M. L. (2015). Robo-advisors: A closer look. *Social Science Research Network*.

Ferreira, P. M., Cunha, J. B., & Ruano, A. E. (2020). Application of artificial intelligence techniques in the agricultural sector: A systematic literature review. *Engineering Applications of Artificial Intelligence*, 95, 103882. <https://doi.org/10.1016/j.engappai.2020.103882>

Ferrucci, D., (2010). Building Watson: An overview of the DeepQA project. *AI Magazine*, 31(3), 59-79.



Festinger, L. (1954). A theory of social comparison processes. *Human Relations*, 7(2), 117–140. <https://doi.org/10.1177/001872675400700202>

Finn, C., Abbeel, P., & Levine, S. (2017). Model-agnostic meta-learning for fast adaptation of deep networks. In *Proceedings of the 34th International Conference on Machine Learning* (pp. 1126–1135).

Fitzpatrick, K. K., Darcy, A., & Vierhile, M. (2017). Delivering cognitive behavior therapy to young adults with symptoms of depression and anxiety using a fully automated conversational agent (Woebot): A randomized controlled trial. *JMIR Mental Health*, 4(2), e19. <https://doi.org/10.2196/mental.7785>

Floridi, L. (2014). *The Fourth Revolution: How the Infosphere is Reshaping Human Reality*. Oxford: Oxford University Press.

Floridi, L., Cowsls, J., Beltrametti, M., Chatila, R., Chazerand, P., Dignum, V., Vayena, E. (2018). AI4People - An Ethical Framework for a Good AI Society: Opportunities, risks, principles, and recommendations. *Minds and Machines*, 28(4), 689-707.

Fryzeł, M. (2021). Nowoczesna teoria portfelowa jako efektywny sposób budowania portfela inwestycyjnego. *Studenckie Prace Prawnicze Administratywistyczne I Ekonomiczne*, 36, 11–21. <https://doi.org/10.19195/1733-5779.36.1>

Geman, S., Bienenstock, E., & Doursat, R. (1992). Neural networks and the bias/variance dilemma. *Neural Computation*, 4(1), 1-58.

Gillespie, T. (2018). *Custodians of the Internet: Platforms, content moderation, and the hidden decisions that shape social media*. New Heaven: Yale University Press.

Goldberg, Y. (2017). *Neural Network Methods for Natural Language Processing*. San Rafael: Morgan & Claypool.

Goleman, D. (1995). *Emotional Intelligence: Why It Can Matter More Than IQ*. New York: Bantam Books.

Goodfellow, I. J., et al. (2014). Generative adversarial nets. In *Advances in Neural Information Processing Systems* (pp. 2672–2680).



Goodfellow, I., Bengio, Y., & Courville, A. (2018). *Deep learning*. Warszawa: Wydawnictwo Naukowe PWN.

Graves, A., Mohamed, A.-R., & Hinton, G. (2013). Speech recognition with deep recurrent neural networks. *Proceedings of the IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP)*, 6645-6649. <https://doi.org/10.1109/ICASSP.2013.6638947>

Griffiths, M. D., Kuss, D. J., & Pontes, H. M. (2016). A brief overview of Internet gaming disorder and its treatment. *Australian Clinical Psychologist*, *2(1)*, 1–8.

Gunning, D., Stefik, M., Choi, J., Miller, T., Stumpf, S., & Yang, G. Z. (2019). XAI—Explainable artificial intelligence. *Science Robotics*, *4(37)*.

Gurney, J. K. (2013). Sue My Car Not Me: Products Liability and Accidents Involving Autonomous Vehicles. *University of Illinois Journal of Law, Technology & Policy*, *2013(2)*, 247-277.

Guzman, A. L., & Lewis, S. C. (2019). Artificial intelligence and communication: A Human–Machine Communication research agenda. *New Media & Society*, *22(1)*, 70–86. <https://doi.org/10.1177/1461444819858691>

Haddadin, S., Albu-Schäffer, A., & Hirzinger, G. (2009). Requirements for safe robots: Measurements, analysis and new insights. *The International Journal of Robotics Research*, *28(11–12)*, 1507–1527.

Hale, L., & Guan, S. (2015). Screen time and sleep among school-aged children and adolescents: A systematic literature review. *Sleep Medicine Reviews*, *21*, 50–58.

Hargittai, E. (2010). Digital na(t)ives? Variation in Internet skills and uses among members of the “Net Generation”. *Sociological Inquiry*, *80(1)*, 92–113. <https://doi.org/10.1111/j.1475-682X.2009.00317.x>

Hartley, R., & Zisserman, A. (2003). *Multiple View Geometry in Computer Vision* (2nd ed.). Glasgow: Cambridge University Press.



He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (pp. 770–778).

Helberger, N. (2020). The political power of platforms: How current attempts to regulate misinformation amplify opinion power. *Digital Journalism*, 8(6), 842-853. <https://doi.org/10.1080/21670811.2020.1773888>

Henneberger, A. K., Mushonga, D. R., & Preston, A. M. (2021). Peer Influence and Adolescent Substance Use: A Systematic Review of Dynamic Social Network Research. *Adolescent Research Review*, 6(1), 57–73. <https://doi.org/10.1007/s40894-019-00130-0>

Hernandez-Leal, P., Kartal, B., & Taylor, M. E. (2019). A survey and critique of multiagent deep reinforcement learning. *Autonomous Agents and Multi-Agent Systems*, 33(6), 750-797.

Herrera, F., Bailenson, J., Weisz, E., Ogle, E., & Zaki, J. (2018). Building long-term empathy: A large-scale comparison of traditional and virtual reality perspective-taking. *PLOS ONE*, 13(10), e0204494. <https://doi.org/10.1371/journal.pone.0204494>

Hiniker, A., Schoenebeck, S. Y., & Kientz, J. A. (2016). Not at the dinner table: Parents' and children's perspectives on family technology rules. Proceedings of the 2016 CHI Conference on Human Factors in Computing Systems, 1374–1387. <https://doi.org/10.1145/2858036.2858357>

Hirschberg, J., & Manning, C. D. (2015). Advances in natural language processing. *Science*, 349(6245), 261–266.

Hobbs, R. (2017). *Create to Learn: Introduction to Digital Literacy*. Pondicherry: Wiley.

Holland, S. (2000) Artificial Intelligence in Music Education: a critical review. In Miranda, E. (ed.) Readings in Music and Artificial Intelligence, *Contemporary Music Studies Vol. 20*. Amsterdam: Harwood Academic Publishers.

Holmes, W., Bialik, M., & Fadel, C. (2019). *Artificial Intelligence in Education: Promises and Implications for Teaching and Learning*. Boston: Center for Curriculum Redesign.



Hosmer, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). *Applied Logistic Regression* (3rd ed.). Danvers: Wiley.

Hochreiter, S. and Schmidhuber, J. (1997) Long Short-Term Memory. *Neural Computation*, 9, 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>

Hoermann, S., McCabe, K. L., Milne, D. N., & Calvo, R. A. (2017). Application of synchronous text-based dialogue systems in mental health interventions: Systematic review. *Journal of Medical Internet Research*, 19(8), e267. <https://doi.org/10.2196/jmir.7023>

Holzinger, A., et al. (2017). What do we need to build explainable AI systems for the medical domain? arXiv preprint arXiv:1712.09923.

Hoy, M. B. (2018). Alexa, Siri, Cortana, and More: An Introduction to Voice Assistants. *Medical Reference Services Quarterly*, 37(1), 81–88.

Huang, G., Zhou, H., Ding, X., & Wang, R. (2019). Applications of artificial intelligence in finance and economics: A survey. *Advances in Computer Science and Engineering*, 1(1), 1-15.

Iwanicka, A. (2020). Children's social interactions by means of digital media – Research report. *Problemy Opiekuńczo-Wychowawcze*, 592(7), 50–60.

Jain, A. K., Murty, M. N., & Flynn, P. J. (1999). Data clustering: A review. *ACM Computing Surveys*, 31(3), 264-323.

Jahn, C., Kersten, W., & Ringle, C. M. (Eds.). (2020). *Data Science in Maritime and City Logistics: Data-driven Solutions for Logistics and Sustainability*. Proceedings of the Hamburg International Conference of Logistics (HICL), 30. Hamburg: Hamburg University of Technology (TUHH), Institute of Business Logistics and General Management.

Jenkins, P., et al. (2019). *Banking on the future: How artificial intelligence is transforming the financial services industry*. Financial Stability Institute.

Jha, S., Jha, S., & Gupta, M. K. (2019). Leveraging artificial intelligence for effective recruitment and selection processes. Coimbatore: Conference: International Conference



on Communication, Computing and Electronics Systems (ICCCES 2019) w: PPG Institute of Technology.

Johnson, L. (2022). Failure to disrupt: Why technology alone can't transform education. *Journal of Teaching and Learning*, *16(1)*, 101–103.

Jolliffe, I. T., & Cadima, J. (2016). Principal component analysis: A review and recent developments. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, *374(2065)*.

Junco, R. (2012). The relationship between frequency of Facebook use, participation in Facebook activities, and student engagement. *Computers & Education*, *58(1)*, 162–171. <https://doi.org/10.1016/j.compedu.2011.08.004>

Jurafsky, D., & Martin, J. H. (2023). *Speech and Language Processing* (3rd ed.). New Jersey: Prentice Hall.

Katharopoulos, A., Vyas, A., Pappas, N., & Fleuret, F. (2020). Transformers are RNNs: Fast Autoregressive Transformers with Linear Attention. In *Proceedings of the 37th International Conference on Machine Learning* (pp. 5156-5165).

Katsh, E., & Rabinovich-Einy, O. (2017). *Digital Justice: Technology and the Internet of Disputes*. New York: Oxford University Press.

Kazdin, A. E. (2013). *Behavior modification in applied settings* (7th ed.). Long Grove: Waveland Press, Inc..

KCPU. (2024). *Nadużywanie mediów elektronicznych przez dzieci i młodzież: Analiza zagrożeń i rekomendacje*. Krakowskie Centrum Profilaktyki Uzależnień.

Keles, B., McCrae, N., & Grealish, A. (2020). A systematic review: The influence of social media on depression, anxiety and psychological distress in adolescents. *International Journal of Adolescence and Youth*, *25(1)*, 79–93. <https://doi.org/10.1080/02673843.2019.1590851>

Khandani, A. E., Kim, A. J., & Lo, A. W. (2010). Consumer credit-risk models via machine-learning algorithms. *Journal of Banking & Finance*, *34(11)*, 2767–2787.

Kingma, D. P., et al. (2014). Semi-supervised learning with deep generative models. In *Advances in Neural Information Processing Systems* (pp. 3581-3589).

Kingma, D. P., & Welling, M. (2022). Auto-encoding variational Bayes. In *2nd International Conference on Learning Representations (ICLR)*.

Kirkpatrick, D. (2016). *The Facebook effect: The inside story of the company that is connecting the world*. New York: Simon and Schuster.

Kirschner, P. A., Sweller, J., & Clark, R. E. (2006). Why minimal guidance during instruction does not work: An analysis of the failure of constructivist, discovery, problem-based, experiential, and inquiry-based teaching. *Educational Psychologist*, *41*(2), 75–86. [https://doi.org/10.1207/s15326985ep4102\\_1](https://doi.org/10.1207/s15326985ep4102_1)

Klerkx, L., Jakku, E., & Labarthe, P. (2019). A review of social science on digital agriculture, smart farming and agriculture 4.0: New contributions and a future research agenda. *NJAS: Wageningen Journal of Life Sciences*, *90-91*, 100315. <https://doi.org/10.1016/j.njas.2019.100315>

Klipa, D., Ristić, I., Radonjić, A., & Scepanović, I. (2022). BIG DATA AND ARTIFICIAL INTELLIGENCE. *International Journal of Management Trends Key Concepts and Research*, *1*(1), 3–14. <https://doi.org/10.58898/ijmt.v1i1.03-14>

Kober, J., Bagnell, J. A., & Peters, J. (2013). Reinforcement learning in robotics: A survey. *The International Journal of Robotics Research*, *32*(11), 1238–1274.

Kolb, B., & Gibb, R. (2011). Brain plasticity and behaviour in the developing brain. *Journal of Canadian Academy of Child and Adolescent Psychiatry*, *20*(4), 265–276.

Kourou, K., et al. (2015). Machine learning applications in cancer prognosis and prediction. *Computational and Structural Biotechnology Journal*, *13*, 8–17.

Kormushev, P., Calinon, S., & Caldwell, D. G. (2013). Reinforcement learning in robotics: Applications and real-world challenges. *Robotics*, *2*(3), 122–148.



Kotsiantis, S. B. (2007). Supervised machine learning: A review of classification techniques. *Informatica*, 31(3), 249-268.

Kowalski, R. M., & Limber, S. P. (2013). Psychological, physical, and academic correlates of cyberbullying and traditional bullying. *Journal of Adolescent Health*, 53(1), 13-20. doi:10.1016/j.jadohealth.2012.09.018

Kowalski, R. M., Giumetti, G. W., Schroeder, A. N., & Lattanner, M. R. (2014). Bullying in the digital age: A critical review and meta-analysis of cyberbullying research among youth. *Psychological Bulletin*, 140(4), 1073–1137. <https://doi.org/10.1037/a0035618>

Kowaluk-Romanek, M. (2019). Cyfrowe dzieciństwo. Nowe technologie a rozwój dziecka. *Edukacja–Technika–Informatyka*, 27(1), 194-201.

Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 25, 1097-1105.

Krzyżak-Szymańska, E. (2015). *Uzależnienia technologiczne wśród dzieci i młodzieży. Teoria, profilaktyka, terapia – wybrane zagrożenia*. Warszawa: Fundacja Praesterno.

Kuss, D. J., & Lopez-Fernandez, O. (2016). Internet addiction and problematic Internet use: A systematic review of clinical research. *World Journal of Psychiatry*, 6(1), 143–176. <https://doi.org/10.5498/wjp.v6.i1.143>

Kuss, D. J., & Griffiths, M. D. (2012). Internet and gaming addiction: A systematic literature review of neuroimaging studies. *Brain Sciences*, 2(3), 347-374.

Laine, S., & Aila, T. (2017). Temporal ensembling for semi-supervised learning. In *5th International Conference on Learning Representations (ICLR)*.

Lakhchini, W., Wahabi, R., & El Kabbouri, M. (2022). Artificial Intelligence & Machine Learning in Finance: A literature review. *International Journal of Accounting, Finance, Auditing, Management and Economics*, 3(6-1), 437-455.

Lange, R. (2023). *Nastolatki 3.0. Raport z ogólnopolskiego badania uczniów i Rodziców*. Warszawa: NASK – Państwowy Instytut Badawczy.



- Laskin, M., Srinivas, A., & Abbeel, P. (2020). CURL: Contrastive unsupervised representations for reinforcement learning. In *Proceedings of the 37th International Conference on Machine Learning* (pp. 5639–5650).
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, *521*(7553), 436-444.
- Lee, J., Bagheri, B., & Kao, H. A. (2015). A cyber-physical systems architecture for industry 4.0-based manufacturing systems. *Manufacturing Letters*, *3*, 18-23.
- Lessmann, S., Baesens, B., Seow, H. V., & Thomas, L. C. (2015). Benchmarking state-of-the-art classification algorithms for credit scoring: An update of research. *European Journal of Operational Research*, *247*(1), 124–136.
- Levy, K. (2017). The contexts of control: Information, power, and truck-driving work. *The Information Society*, *33*(3), 147-158.
- Lewis, M., et al. (2020). BART: Denoising Sequence-to-Sequence Pre-training for Natural Language Generation, Translation, and Comprehension. In *Proceedings of ACL 2020* (pp. 7871–7880).
- Li, J., Esteban-Fernández de Ávila, B., Gao, W., Zhang, L., & Wang, J. (2017). Micro/Nanorobots for Biomedicine: Delivery, Surgery, Sensing, and Detoxification. *Science Robotics*, *2*(4), eaam6431. <https://doi.org/10.1126/scirobotics.aam6431>
- Li, P., & Wang, B. (2023). Artificial intelligence in music education. *International Journal of Human-Computer Interaction*, *40*(16), 4183–4192.
- Li, Y., Qiao, T., Leng, W., Jiao, W., Luo, J., Lv, Y., . . . Yao, Q. (2022). Semantic segmentation of wheat stripe rust images using deep learning. *Agronomy*, *12*(12), 2933. <https://doi.org/10.3390/agronomy12122933>
- Libbrecht, M. W., & Noble, W. S. (2015). Machine learning applications in genetics and genomics. *Nature Reviews Genetics*, *16*(6), 321–332.
- Lighthill, J. (1973). Artificial intelligence: A general survey. In *Artificial Intelligence: A Paper Symposium* (pp. 1-15). *Science Research Council*.



- Lim, H. S. M., & Taeihagh, A. (2018). Autonomous Vehicles for Smart and Sustainable Cities: An In-Depth Exploration of Privacy and Cybersecurity Implications. *Energies, 11(5)*, 1-25.
- Lin, P., Abney, K., & Bekey, G. A. (2011). Robot ethics: Mapping the issues for a mechanized world. *Artificial Intelligence, 175(5-6)*, 942-949.
- Lin, P., Abney, K., Jenkins, R. (2017). *Robot Ethics 2.0: From Autonomous Cars to Artificial Intelligence*. New York: Oxford Academic.
- Linden, G., Smith, B., & York, J. (2003). Amazon.com recommendations: Item-to-item collaborative filtering. *IEEE Internet Computing, 7(1)*, 76-80.
- Lipton, Z. C. (2016). *The mythos of model interpretability*. Ithaca: Cornell University. <https://doi.org/10.48550/arxiv.1606.03490>
- Litjens, G., et al. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis, 42*, 60-88.
- Litman, T. (2020). Autonomous vehicle implementation predictions: Implications for transport planning. *Victoria Transport Policy Institute*.
- Liu, Y., et al. (2019). RoBERTa: A Robustly Optimized BERT Pretraining Approach. *arXiv preprint arXiv:1907.11692*.
- Livingstone, S., & Helsper, E. J. (2007). Gradations in digital inclusion: Children, young people and the digital divide. *New Media & Society, 9(4)*, 671-696.
- Livingstone, S., Haddon, L., Görzig, A., & Ólafsson, K. (2011). *Risks and safety on the Internet: The perspective of European children. Full Findings*. The London School of Economics and Political Science, London: EU Kids Online.
- Livingstone, S., & Sefton-Green, J. (2016). *The class: Living and learning in the digital age*. New York: NYU Press.
- Livingstone, S. (2018). Children and the Internet: Great Expectations and Challenges. *Journal of Child Psychology and Psychiatry, 59(4)*, 441-447.



Livingstone, S., & Byrne, J. (2018). Parenting in the digital age: The challenges of parental responsibility in comparative perspective. *Media@LSE Working Paper Series*, 49.

Livingstone, S., Mascheroni, G., & Staksrud, E. (2018). European research on children's Internet use: Assessing the past and anticipating the future. *New Media & Society*, 20(3), 1103–1122. <https://doi.org/10.1177/1461444816685930>

Long, J., Shelhamer, E., & Darrell, T. (2015). Fully Convolutional Networks for Semantic Segmentation. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 3431-3440.

Lowe, D. G. (2004). Distinctive image features from scale-invariant keypoints. *International Journal of Computer Vision*, 60(2), 91–110.

Lu, J., Batra, D., Parikh, D., & Lee, S. (2019). ViLBERT: Pretraining Task-Agnostic Visiolinguistic Representations for Vision-and-Language Tasks. In *Advances in Neural Information Processing Systems*, 32, 13–23.

Luchini, C., Pea, A., & Scarpa, A. (2021). Artificial intelligence in oncology: current applications and future perspectives. *British Journal of Cancer*, 126(1), 4-9. <https://doi.org/10.1038/s41416-021-01633-1>

Luckin, R., Holmes, W., Griffiths, M., & Forcier, L. B. (2016). *Intelligence unleashed: An argument for AI in education*. London: Pearson Education.

Luxton, D. D. (2014). Recommendations for the ethical use and design of artificial intelligent care providers. *Artificial Intelligence in Medicine*, 62(1), 1–10. <https://doi.org/10.1016/j.artmed.2014.06.004>

Maccoby, E. E., & Martin, J. A. (1983). Socialization in the context of the family: Parent-child interaction. W: P. H. Mussen (red.), *Handbook of child psychology* (s. 1–101). New York: Wiley.

Manning, C. D., & Schütze, H. (1999). *Foundations of Statistical Natural Language Processing*. London: MIT Press.



Manyika, J., Chui, M., Miremadi, M., Bughin, J., George, K., Willmott, P., & Dewhurst, M. (2017). *A Future that Works: Automation, Employment, and Productivity*. Atlanta: McKinsey Global Institute. <https://www.mckinsey.com/featured-insights>

Matthies, L., et al. (2007). Computer vision on Mars. *International Journal of Computer Vision*, 75(1), 67–92.

Mao, H., Alizadeh, M., Menache, I., & Kandula, S. (2016). Resource management with deep reinforcement learning. In *Proceedings of the 15th ACM Workshop on Hot Topics in Networks* (pp. 50-56).

McCarthy, J. (2007). *What is artificial intelligence?*. Stanford: Stanford University.

McGrew, S., Ortega, T., Breakstone, J., & Wineburg, S. (2018). The challenge that's bigger than fake news: Teaching students to engage in civic online reasoning. *American Educator*, 41(3), 4–9.

McMahan, B., et al. (2017). Communication-efficient learning of deep networks from decentralized data. In *Proceedings of the 20th International Conference on Artificial Intelligence and Statistics* (pp. 1273–1282).

Means, B., Toyama, Y., Murphy, R., Bakia, M., & Jones, K. (2013). *The effectiveness of online and blended learning: A meta-analysis of the empirical literature*. New York: Teachers College Press.

Medhat, W., Hassan, A., & Korashy, H. (2014). Sentiment analysis algorithms and applications: A survey. *Ain Shams Engineering Journal*, 5(4), 1093–1113.

Mehrabi, N., Morstatter, F., Saxena, N., Lerman, K., & Galstyan, A. (2022). A survey on bias and fairness in machine learning. *ACM Computing Surveys*, 54(6), 115.

Mell, P., & Grance, T. (2011). The NIST definition of cloud computing. *National Institute of Standards and Technology*, 53(6), 50.



Michańków, J., Sakowski, P., & Ślepaczuk, R. (2023). Hedging properties of algorithmic investment strategies using long short-term memory and time series models for equity indices. *arXiv*. <https://arxiv.org/abs/2309.15640>

Mihailidis, P. (2018). *Civic Media Literacies: Re-Imagining Human Connection in an Age of Digital Abundance*. Routledge.

Mikolov, T., Karafiát, M., Burget, L., Černocký, J., & Khudanpur, S. (2010). Recurrent neural network based language model. *Proceedings of the 11th Annual Conference of the International Speech Communication Association (INTERSPEECH)*, 1045-1048. [https://www.isca-speech.org/archive/interspeech\\_2010/i10\\_1045.html](https://www.isca-speech.org/archive/interspeech_2010/i10_1045.html)

Mikolov, T., Chen, K., Corrado, G., & Dean, J. (2013). Efficient Estimation of Word Representations in Vector Space. *arXiv preprint arXiv:1301.3781*.

Mitchell, T. M. (1997). *Machine Learning*. New York: McGraw-Hill.

Miyato, T., Maeda, S., Koyama, M., & Ishii, S. (2018). Virtual adversarial training: a regularization method for supervised and semi-supervised learning. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 41(8), 1979-1993.

Mnih, V. (2016). Asynchronous methods for deep reinforcement learning. *In Proceedings of the 33rd International Conference on Machine Learning (pp. 1928–1937)*.

Mohr, D. C., Zhang, M., & Schueller, S. M. (2017). Personal sensing: Understanding mental health using ubiquitous sensors and machine learning. *Annual Review of Clinical Psychology*, 13, 23-47. <https://doi.org/10.1146/annurev-clinpsy-032816-044949>

Mubin, O., Stevens, C. J., Shahid, S., Al Mahmud, A., & Dong, J. J. (2013). A review of the applicability of robots in education. *Technology for Education and Learning*, 1(1), 1–7.

Murphy, K. P. (2012). *Machine Learning: A Probabilistic Perspective*. Cambridge: MIT Press.

Montgomery, D. C., Peck, E. A., & Vining, G. G. (2012). *Introduction to Linear Regression Analysis* (5th ed.). New Jersey: Wiley.



- Mori, M., MacDorman, K. F., & Kageki, N. (2012). The uncanny valley. *IEEE Robotics & Automation Magazine*, 19(2), 98–100. <https://doi.org/10.1109/MRA.2012.2192811>
- Nencioni, G., Garroppo, R. G., & Olimid, R. F. (2023). 5G Multi-Access Edge Computing: A survey on security, dependability, and performance. *IEEE Access*, 11, 63496–63533. <https://doi.org/10.1109/access.2023.3288334>
- Neupane, S., Ali, U., & Mathew, A. (2017). Text neck syndrome - Systematic review. *Imperial Journal of Interdisciplinary Research*, 3(7), 141–148.
- Newell, A., & Simon, H. A. (1956). The logic theory machine: A complex information processing system. *IRE Transactions on Information Theory*, 2(3), 61-79.
- Newell, A., & Simon, H. A. (1961). *GPS, a program that simulates human thought*. In *Lernende Automaten* (pp. 109-124). Cambridge: Springer.
- Nigam, K., McCallum, A., Thrun, S., & Mitchell, T. (2000). Text classification from labeled and unlabeled documents using EM. *Machine Learning*, 39(2-3), 103-134.
- Nilsson, N. J. (1998). *Artificial Intelligence: A New Synthesis*. San Francisco: Morgan Kaufmann.
- Nilsson, N. J. (2010). *The Quest for Artificial Intelligence*. Cambridge : Cambridge University Press.
- Noble, S. U. (2018). *Algorithms of Oppression: How Search Engines Reinforce Racism*. New York: NYU Press.
- O’Neil, C. (2016). *Weapons of Math Destruction: How Big Data Increases Inequality and Threatens Democracy*. New York: Crown.
- Okonkwo, C. W., & Ade-Ibijola, A. (2021). Chatbots applications in education: A systematic review. *Computers and Education: Artificial Intelligence*, 2, 100033. <https://doi.org/10.1016/j.caeai.2021.100033>



Orben, A., & Przybylski, A. K. (2019). The association between adolescent well-being and digital technology use. *Nature Human Behaviour*, 3(2), 173–182. <https://doi.org/10.1038/s41562-018-0506-1>

Pan, S. J., & Yang, Q. (2010). A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering*, 22(10), 1345-1359.

Pariser, E. (2011). *The Filter Bubble: What the Internet Is Hiding from You*. New York: Penguin Press.

Pavlov, I. P. (1927). *Conditioned reflexes: An investigation of the physiological activity of the cerebral cortex*. Oxford: Oxford University Press.

Pendleton, S. D., et al. (2017). Perception, planning, control, and coordination for autonomous vehicles. *Machines*, 5(1), 6.

Peng, Y., Liu, C., & Shen, W. (2023). Finding Lookalike Customers for E-Commerce Marketing. *arXiv preprint arXiv:2301.03147*.

Pennington, J., Socher, R., & Manning, C. D. (2014). GloVe: Global Vectors for Word Representation. In *Proceedings of EMNLP 2014* (pp. 1532–1543).

Pennycook, G., & Rand, D. G. (2018). The Implied Truth Effect: Attaching Warnings to a Subset of Fake News Stories Increases Perceived Accuracy of Stories Without Warnings. *Management Science*, 66(11), 4944-4957.

Piaget, J. (1952). *The origins of intelligence in children*. New York: International Universities Press.

Piwek, L., Ellis, D. A., Andrews, S., & Joinson, A. (2016). The rise of consumer health wearables: Promises and barriers. *PLoS Medicine*, 13(2), e1001953. <https://doi.org/10.1371/journal.pmed.1001953>

Popova, M., et al. (2018). Deep reinforcement learning for de novo drug design. *Science Advances*, 4(7).

Preskill, J. (2018). Quantum Computing in the NISQ era and beyond. *Quantum*, 2, 79.



Przegalińska-Skierowska, A., & Oksanowicz, P. (2023). *Sztuczna inteligencja: nieludzka, arcyłudzka*. Kraków: Wydawnictwo Znak.

Przybylski, A. K., & Weinstein, N. (2017). A large-scale test of the Goldilocks hypothesis: Quantifying the relations between digital-screen use and the mental well-being of adolescents. *Psychological Science*, 28(2), 204–215. <https://doi.org/10.1177/0956797616678438>

Radford, A., et al. (2018). Improving Language Understanding by Generative Pre-Training. *OpenAI*.

Raghupathi, W., & Raghupathi, V. (2014). Big Data analytics in healthcare: Promise and potential. *Health Information Science and Systems*, 2(1), 3.

Rajkomar, A., Dean, J., & Kohane, I. (2019). *Machine learning in medicine*. New England Journal of Medicine, 380(14), 1347–1358.

Ramesh, A., et al. (2021). Zero-Shot Text-to-Image Generation. *arXiv preprint arXiv:2102.12092*.

Ray, P. P. (2018). A Survey on Internet of Things Architectures. *Journal of King Saud University - Computer and Information Sciences*, 30(3), 291-319. <https://doi.org/10.1016/j.jksuci.2016.10.003>

Ray, A., Bhardwaj, A., Malik, Y. K., Singh, S., & Gupta, R. (2022). Artificial intelligence and Psychiatry: An overview. *Asian Journal of Psychiatry*, 70, 103021. <https://doi.org/10.1016/j.ajp.2022.103021>

Reda, M., Onsy, A., Haikal, A. Y., & Ghanbari, A. (2024). Path planning algorithms in the autonomous driving system: A comprehensive review. *Robotics and Autonomous Systems*, 174, 104630. <https://doi.org/10.1016/j.robot.2024.104630>

Reich, J. (2020). *failure to disrupt: why technology alone can't transform education*. Londyn: Harvard University Press.

Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster R-CNN: Towards real-time object detection with region proposal networks. *Advances in Neural Information Processing Systems (NeurIPS)*, 28.



Resnik, P., Armstrong, W., Claudino, L., Nguyen, T., Nguyen, V. A., & Boyd-Graber, J. (2018). Beyond LDA: Exploring supervised topic modeling for depression-related language in Twitter. *Proceedings of the Fifth Workshop on Computational Linguistics and Clinical Psychology*, 99-107. <https://doi.org/10.18653/v1/W18-0609>

Ricci, F., Rokach, L., & Shapira, B. (2015). *Recommender Systems Handbook* (2nd ed.). Cambridge: Springer.

Rosenfield, M. (2016). Computer vision syndrome: A review of ocular causes and potential treatments. *Ophthalmic and Physiological Optics*, 36(5), 502–515. <https://doi.org/10.1111/opo.12323>

Rudi, J., Dworkin, J., Walker, S., & Doty, J. (2015). Parents' use of information and communications technologies for family communication: Differences by age of children. *Information, Communication & Society*, 18(1), 78–93.

Rus, D., & Tolley, M. T. (2015). Design, Fabrication and Control of Soft Robots. *Nature*, 521(7553), 467-475. <https://doi.org/10.1038/nature14543>

Russell, S. (2019). *Human Compatible: Artificial Intelligence and the Problem of Control*. New Jersey: Pearson Education.

Russell, S., Norvig, P. (2022). *Sztuczna Inteligencja. Nowe spojrzenie (wyd. 4)*. Gliwice: Helion.

Sajja, R., Sermet, Y., Cikmaz, M., Cwiertny, D., & Demir, I. (2023). Artificial Intelligence-Enabled Intelligent Assistant for Personalized and Adaptive Learning in Higher Education. *arXiv*. <https://arxiv.org/abs/2309.10892>

Sajjadi, M., Javanmardi, M., & Tasdizen, T. (2016). Regularization with stochastic transformations and perturbations for deep semi-supervised learning. In *Advances in Neural Information Processing Systems* (pp. 1163-1171).

Salonen, A. O., & Haavisto, N. (2019). Towards autonomous transportation. Passengers' experiences, perceptions and feelings in a driverless shuttle bus in Finland. *Sustainability*, 11(3), 588.



Santrock, J. W. (2018). *Life-span development (17th ed.)*. New York: McGraw-Hill Education.

Samek, W., Wiegand, T., & Müller, K. R. (2017). Explainable artificial intelligence: Understanding, visualizing and interpreting deep learning models. *arXiv preprint arXiv:1708.08296*.

Schreyer, M., Sattarov, T., Borth, D., Dengel, A., & Reimer, B. (2017). Detection of Anomalies in Large Scale Accounting Data using Deep Autoencoder Networks. *arXiv*. <https://arxiv.org/abs/1709.05254>

Schuster, M., & Paliwal, K. K. (1997). Bidirectional recurrent neural networks. *IEEE Transactions on Signal Processing*, 45(11), 2673-2681.

Selwyn, N. (2022). *Education and Technology: Key Issues and Debates*. New York: Bloomsbury Academic.

Siciliano, B., & Khatib, O. (Eds.). (2016). *Springer Handbook of Robotics (2nd ed.)*. Berlin: Springer Nature.

Silver, D., Huang, A., Maddison, C. J., Guez, A., Sifre, L., Van den Driessche, G., & Lillicrap, T. P. (2016). *Mastering the game of Go with deep neural networks and tree search*. *Nature*, 529(7587), 484–489. <https://doi.org/10.1038/nature16961>

Sishodia, R. P., Ray, R. L., & Singh, S. K. (2020). *Applications of remote sensing in precision agriculture: A review*. *Remote Sensing*, 12(19), 3136. <https://doi.org/10.3390/rs12193136>

Shamiulla, A. M. (2019). Role of artificial intelligence in cyber security. *International Journal of Innovative Technology and Exploring Engineering*, 9(1), 4628–4630.

Shi, W., & Dustdar, S. (2016). The promise of edge computing. *Computer*, 49(5), 78–81.

Shortliffe, E. H. (1976). *Computer-Based Medical Consultations: MYCIN*. New York: Elsevier.

Smahel, D., Machackova, H., Mascheroni, G., Dedkova, L., Staksrud, E., Ólafsson, K., Livingstone, S., and Hasebrink, U. (2020). EU Kids Online 2020: Survey results from 19 countries. *EU Kids Online*. Doi: 10.21953/lse.47fdeqj01of0



Smith, S., et al. (2022). Using DeepSpeed and Megatron to Train Megatron-Turing NLG 530B, A Large-Scale Generative Language Model. *arXiv preprint arXiv:2201.11990*.

Squires, M., Tao, X., Elangovan, S., Gururajan, R., Zhou, X., Acharya, U. R., & Li, Y. (2023). Deep learning and machine learning in psychiatry: a survey of current progress in depression detection, diagnosis and treatment. *Brain Informatics, 10(1)*. <https://doi.org/10.1186/s40708-023-00188-6>

Steinberg, L. (2016). *Adolescence (11th ed.)*. New York: McGraw-Hill Education.

Stiglic, N., & Viner, R. M. (2019). Effects of screen time on the health and well-being of children and adolescents: A systematic review of reviews. *BMJ Open, 9(1)*, e023191. <https://doi.org/10.1136/bmjopen-2018-023191>

Subrahmanyam, K., & Greenfield, P. (2008). Online communication and adolescent relationships. *The Future of Children, 18(1)*, 119–146. <https://doi.org/10.1353/foc.0.0006>

Sun, Y., et al. (2019). ERNIE: Enhanced Representation through Knowledge Integration. *arXiv preprint arXiv:1904.09223*.

Sundar, S. S., & Kim, J. (2022). When AI moderates online content: Effects of human collaboration and disclosure on perceptions of fairness and trust. *Journal of Computer-Mediated Communication, 27(4)*, <https://doi.org/10.1093/jcmc/zmac010>

Sunstein, C. R. (2017). *#Republic: Divided Democracy in the Age of Social Media*. New Jersey: Princeton University Press.

Sutton, R. S., & Barto, A. G. (2018). *Reinforcement Learning: An Introduction* (2nd ed.). Cambridge: MIT Press.

Sutskever, I., Vinyals, O., & Le, Q. V. (2014). Sequence to sequence learning with neural networks. In *Advances in Neural Information Processing Systems* (pp. 3104-3112).

Szegedy, C., et al. (2014). Intriguing properties of neural networks. In *2nd International Conference on Learning Representations*.

Szeliski, R. (2010). *Computer Vision: Algorithms and Applications*. London: Springer.



Szostek, D. (2022). *Zastosowanie sztucznej inteligencji w bankowości – szanse oraz zagrożenia*. Warszawa: Program Analityczno-Badawczego Fundacji Warszawski Instytut Bankowości

Tabakow, M., Korczak, J., & Franczyk, B. (2014). Big Data – definicje, wyzwania i technologie informatyczne. *Informatyka Ekonomiczna*, (4), 39-52.

Taleb, T., Samdanis, K., Mada, B., Flinck, H., Dutta, S., & Sabella, D. (2017). On multi-access edge computing: A survey of the emerging 5G network edge cloud architecture and orchestration. *IEEE Communications Surveys & Tutorials*, 19(3), 1657–1681.

Third, A., et al., (2014). *Children's Rights in the Digital Age: A Download from Children Around the World*. Melbourne: Young and Well Cooperative Research Centre,

Tiggemann, M., & Slater, A. (2014). NetGirls: The Internet, Facebook, and body image concern in adolescent girls. *International Journal of Eating Disorders*, 47(6), 630–633.

Tjoa, E., & Guan, C. (2020). A Survey on Explainable Artificial Intelligence (XAI): Toward Medical XAI. *IEEE Transactions on Neural Networks and Learning Systems*, 32(11), 4793–4813. <https://doi.org/10.1109/TNNLS.2020.3027314>

Topol, E. J. (2019). High-performance medicine: The convergence of human and artificial intelligence. *Nature Medicine*, 25(1), 44–56.

Topol, E. J. (2019). *Deep medicine: How artificial intelligence can make healthcare human again*. New York: Basic Books.

Torous, J., Kiang, M. V., Lorme, J., & Onnela, J. P. (2018). New tools for new research in psychiatry: A scalable and customizable platform to empower data driven smartphone research. *JMIR Mental Health*, 5(4), e100. <https://doi.org/10.2196/mental.9785>

Torrey, L., & Shavlik, J. (2010). Transfer learning. In *Handbook of Research on Machine Learning Applications and Trends* (pp. 242–264). IGI Global.

Tsiptsis, K., & Chorianopoulos, A. (2009). *Data Mining Techniques in CRM: Inside Customer Segmentation*. West Sussex: Wiley.



- Turing, A. M. (1950). Computing machinery and intelligence. *Mind*, 59(236), 433-460.
- Turkle, S. (2011). *Alone Together: Why We Expect More from Technology and Less from Each Other*. New York: Basic Books.
- Turkle, S. (2015). *Reclaiming conversation: The power of talk in a digital age*. London: Penguin Books.
- Twenge, J. M. (2017). *iGen: Why Today's Super-Connected Kids Are Growing Up Less Rebellious, More Tolerant, Less Happy – and Completely Unprepared for Adulthood*. New York: Atria Books.
- Twenge, J. M., Joiner, T. E., Rogers, M. L., & Martin, G. N. (2017). Increases in depressive symptoms, suicide-related outcomes, and suicide rates among US adolescents after 2010 and links to increased new media screen time. *Clinical Psychological Science*, 6(1), 3-17. <https://doi.org/10.1177/2167702617723376>
- Twenge, J. M., & Campbell, W. K. (2018). Associations between screen time and lower psychological well-being among children and adolescents: Evidence from a population-based study. *Preventive Medicine Reports*, 12, 271–283.
- Twenge, J. M., Martin, G. N., & Spitzberg, B. H. (2018). Trends in U.S. adolescents' media use, 1976–2016: The rise of digital media, the decline of TV, and the (near) demise of print. *Psychology of Popular Media Culture*, 8(4), 329-345. <https://doi.org/10.1037/ppm0000203>
- Uhls, Y. T., Ellison, N. B., & Subrahmanyam, K. (2014). Benefits and costs of social media in adolescence. *Pediatrics*, 140(5), S67–S70. <https://doi.org/10.1542/peds.2016-1758E>
- Vajjala, S., Majumder, B., Gupta, A., & Surana, H. (2023). *Przetwarzanie języka naturalnego w praktyce: przewodnik po budowie rzeczywistych systemów NLP*. Gliwice: Helion
- Van Deursen, A. J. A. M., & van Dijk, J. A. G. M. (2019). The first-level digital divide shifts from inequalities in physical access to inequalities in material access. *New Media & Society*, 21(2), 354–375. <https://doi.org/10.1177/1461444818797082>
- Van Dijck, J. (2013). *The culture of connectivity: A critical history of social media*. New York: Oxford University Press.



Vaswani, A., et al. (2017). Attention is All You Need. *In Advances in Neural Information Processing Systems, 30*, 5998–6008.

Verduyn, P., Ybarra, O., Résibois, M., Jonides, J., & Kross, E. (2017). Do social network sites enhance or undermine subjective well-being? A critical review. *Social Issues and Policy Review, 11(1)*, 274–302. <https://doi.org/10.1111/sipr.12033>

Vosoughi, S., Roy, D., & Aral, S. (2018). The Spread of True and False News Online. *Science, 359(6380)*, 1146-1151.

Vygotsky, L. S. (1978). *Mind in Society: Development of Higher Psychological Processes*. New York: Harvard University Press. <https://doi.org/10.2307/j.ctvjf9vz4>

Waltz, E. (2020). Does CRISPR have a future in gene therapy? *Nature Biotechnology, 38(2)*, 142–144.

Wang, S., Tuor, T., Salonidis, T., Leung, K. K., Makaya, C., He, T., & Chan, K. (2019). Adaptive Federated Learning in Resource Constrained Edge Computing Systems. *IEEE Journal on Selected Areas in Communications, 37(6)*, 1205-1221.

Wang, Z., Wu, Y., & Niu, Q. (2019). Multi-Sensor Fusion in Automated Driving: a survey. *IEEE Access, 8*, 2847–2868. <https://doi.org/10.1109/access.2019.2962554>

Wardle, C., & Derakhshan, H. (2017). *Information Disorder: Toward an Interdisciplinary Framework for Research and Policy Making*. Council of Europe.

Weizenbaum, J. (1966). ELIZA - a computer program for the study of natural language communication between man and machine. *Communications of the ACM, 9(1)*, 36-45.

Wheaton, A. G., Ferro, G. A., & Croft, J. B. (2016). School start times for middle school and high school students—United States, 2011–12 school year. *Morbidity and Mortality Weekly Report, 64(33)*, 809–813. <https://doi.org/10.15585/mmwr.mm6433a2>

Wieczorek, L. (2022). Rola mediów społecznościowych w życiu pokolenia C. *Infotezy, 1(12)*, 73-89.



Williamson, B. (2020). *Big data in education: The digital future of learning, policy and practice*. Thousand Oaks: SAGE Publications.

Williamson, B. (2019). Datafication of education. London: Routledge. (pp. 212-226). <https://doi.org/10.4324/9781351252805-14>

Winston, W. (2020). *How Does Target Know If You're Pregnant?*. Indianapolis: John Wiley & Sons, Inc.

Wolpe, J. (1958). *Psychotherapy by reciprocal inhibition*. Redwood City: Stanford University Press.

Woo, J. H., & Choi, H. (2021). Systematic Review for AI-based Language Learning Tools. *arXiv preprint arXiv:2111.04455*. <https://arxiv.org/abs/2111.04455>

Wu, Y., et al. (2016). Google's Neural Machine Translation System: Bridging the Gap between Human and Machine Translation. *arXiv preprint arXiv:1609.08144*.

Xu, L. D., He, W., & Li, S. (2014). Internet of Things in Industries: A Survey. *IEEE Transactions on Industrial Informatics*, 10(4), 2233–2243.

Yang, G. Z., et al. (2017). Medical robotics—Regulatory, ethical, and legal considerations for increasing levels of autonomy. *Science Robotics*, 2(4),

Yilmaz, A., Javed, O., & Shah, M. (2006). Object tracking: A survey. *ACM Computing Surveys*, 38(4), 1–45.

Yosinski, J., Clune, J., Bengio, Y., & Lipson, H. (2014). How transferable are features in deep neural networks? In *Advances in Neural Information Processing Systems* (pp. 3320-3328).

Young, T., Hazarika, D., Poria, S., & Cambria, E. (2018). Recent Trends in Deep Learning Based Natural Language Processing. *IEEE Computational Intelligence Magazine*, 13(3), 55–75.

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(1), 1–27. <https://doi.org/10.1186/s41239-019-0171-0>



Zawodny, M. (2020). *Komunikacja pojazdów autonomicznych z infrastrukturą drogową*. Zeszyty Naukowo-Techniczne SITK RP, Oddział w Krakowie, 1(120).

Zhao, X., et al. (2017). Deep reinforcement learning for list-wise recommendations. In *Proceedings of the 11th ACM Conference on Recommender Systems* (pp. 109-117).

Zhang, S., Wu, Y., Liu, H., & Ding, W. (2019). Adaptive traffic signal control based on deep reinforcement learning. In *2019 IEEE Intelligent Transportation Systems Conference* (pp. 2066–2071).

Zhavoronkov, A., et al. (2019). Deep learning enables rapid identification of potent DDR1 kinase inhibitors. *Nature Biotechnology*, 37(9), 1038–1040.

Zheng, L., Yang, Y., & Hauptmann, A. G. (2016). Person re-identification: Past, present and future. *arXiv preprint arXiv:1610.02984*.

Zhu, X., & Goldberg, A. B. (2009). Introduction to semi-supervised learning. *Synthesis Lectures on Artificial Intelligence and Machine Learning*, 3(1), 1-130.

Zuboff, S. (2019). *The Age of Surveillance Capitalism: The Fight for a Human Future at the New Frontier of Power*. London: Public Affairs.

### **Źródła Internetowe**

Anderson, M., & Jiang, J. (2018). Teens, social media & technology 2018. *Pew Research Center*. Pobrano 20 lipca 2024 z, <https://www.pewresearch.org>.

Bąk, A. (2015). Korzystanie z urządzeń mobilnych przez małe dzieci w Polsce. Wyniki badania ilościowego. Warszawa: Fundacja Dzieci Niczyje. Pobrano 15 lipca 2024 z, <https://www.fdn.pl>.

Black, S., et al. (2021). GPT-Neo: Large Scale Autoregressive Language Modeling with Mesh-Tensorflow. *GitHub*. Pobrano 12 marca 2024 z, <https://github.com/EleutherAI/gpt-neo>.

Bontcheva, K., & Posetti, J. (2020). *Balancing Act: Countering Digital Disinformation While Respecting Freedom of Expression*. UNESCO. Pobrano 23 marca 2024 z, <https://unesdoc.unesco.org/ark:/48223/pf0000379015>.

Common Sense Media. (2017). The Common Sense census: Media use by kids age zero to eight. commonsensemedia.org. Pobrano 20 lipca 2024, z

[https://www.commonsensemedia.org/sites/default/files/research/report/csm\\_zerotoeight\\_fullreport\\_release\\_2.pdf](https://www.commonsensemedia.org/sites/default/files/research/report/csm_zerotoeight_fullreport_release_2.pdf).

Demagog. (2023). *Cyfrowa „terapia” – sztuczna inteligencja a zdrowie psychiczne*. Pobrano 7 kwietnia 2024 z, [https://demagog.org.pl/analizy\\_i\\_raporty/cyfrowa-terapia-sztuczna-inteligencja-a-zdrowie-psychiczne](https://demagog.org.pl/analizy_i_raporty/cyfrowa-terapia-sztuczna-inteligencja-a-zdrowie-psychiczne).

European Commission. (2022). *Ethical guidelines on the use of artificial intelligence and data in teaching and learning for educators*. Pobrano 7 kwietnia 2024 z, <https://education.ec.europa.eu/news/ethical-guidelines-on-the-use-of-artificial-intelligence-and-data-in-teaching-and-learning-for-educators>.

European Parliament. (2016). Regulation (EU) 2016/679 of the European Parliament and of the Council. Official Journal of the European Union, 59. Pobrano 26 kwietnia 2024 z, <https://eur-lex.europa.eu/eli/reg/2016/679/oj>.

Głos Pedagogiczny. (2018). *Smartfony, czaty, media społecznościowe – jak wpływają na nasze relacje z innymi*. Pobrano 26 kwietnia 2024 z, <https://www.glospedagogiczny.pl/artukul/smartfony-czaty-media-spoecznościowe-jak-wplywaja-na-nasze-relacje-z-innymi>.

Harbingers. (2023). *Jak działają algorytmy mediów społecznościowych?* Pobrano 28 kwietnia 2024 z, <https://harbingers.io/blog/algorytmy-mediow-spoecznościowych>.

IBM. (2021). *Hadoop vs. Spark: What's the Difference?* Pobrano 7 maja 2024 z, <https://www.ibm.com/think/insights/hadoop-vs-spark>.

LoveKrakow.pl. (2023). *Sztuczna inteligencja pomoże postawić diagnozę. Szpital Uniwersytecki wykorzysta ją w psychiatrii dzieci i młodzieży*. Pobrano 7 maja 2024 z, [https://lovekrakow.pl/aktualnosci/sztuczna-inteligencja-pomoze-postawic-diagnoze-szpital-uniwersytecki-wykorzysta-ja-w-psychiatrii-dzieci-i-mlodziezy\\_51652.html](https://lovekrakow.pl/aktualnosci/sztuczna-inteligencja-pomoze-postawic-diagnoze-szpital-uniwersytecki-wykorzysta-ja-w-psychiatrii-dzieci-i-mlodziezy_51652.html).

Ministerstwo Rozwoju i Technologii. (2021). *AI4Youth*. Pobrano 7 maja 2024 z, <https://www.gov.pl>.



OECD. (2019). *OECD Skills Outlook 2019: Thriving in a Digital World*. OECD Publishing. Pobrano 18 lipca 2024 z, <https://doi.org/10.1787/df80bc12-en>.

OECD. (2021). *Protecting Children Online: An Overview of Recent Developments in Legal Frameworks and Policies*. *OECD Publishing*. Pobrano 18 lipca 2024 z, [https://www.oecd.org/en/publications/protecting-children-online\\_9e0e49a9-en.html](https://www.oecd.org/en/publications/protecting-children-online_9e0e49a9-en.html).

OECD. (2023). *OECD Skills Outlook 2023: Digital Education for the Future*. OECD Publishing.

OpenAI. (2023). *GPT-4 Technical Report*. *OpenAI*. Pobrano 6 sierpnia 2024 z, [https://openai.com/research/gpt-4\\_](https://openai.com/research/gpt-4_)

Pappano, L. (2012). *The year of the MOOC*. *The New York Times*. Pobrano 6 sierpnia 2024 z, <https://www.nytimes.com>.

Patil, D. (2024). *Ethical challenges and future implications of artificial intelligence in society 5.0*. Pobrano 17 sierpnia 2024 z, [https://www.researchgate.net/publication/385629330\\_Ethical\\_challenges\\_and\\_future\\_implications\\_of\\_artificial\\_intelligence\\_in\\_society\\_50](https://www.researchgate.net/publication/385629330_Ethical_challenges_and_future_implications_of_artificial_intelligence_in_society_50).

Remedium Psychologia. (2023). *Wpływ mediów społecznościowych na dzieci i młodzież*. Pobrano 20 sierpnia 2024 z, [https://remedium-psychologia.pl/Wplyw-mediow-spolesnosciovych--na-dzieci-i-mlodziez\\_5c9.html](https://remedium-psychologia.pl/Wplyw-mediow-spolesnosciovych--na-dzieci-i-mlodziez_5c9.html).

Uniwersytet Łódzki. (2024). *Porozmawiajmy jak dziecko z AI! Czego najmłodszy chce dowiedzieć się od sztucznej inteligencji i jak wiąże się to z ich dobrostanem psychicznym?* Pobrano 20 sierpnia 2024 z, <https://www.uni.lodz.pl/strefa-studenta/aktualnosci/szczegoly/porozmawiajmy-jak-dziecko-z-ai-czego-najmlodsi-chca-dowiedziec-sie-od-sztucznej-inteligencji-i-jak-wiaze-sie-to-z-ich-dobrostanem-psychicznym>.

Vianna, V. P. (2018). *Study and development of a Computer-Aided Diagnosis system for classification of chest x-ray images using convolutional neural networks pre-trained for ImageNet and data augmentation*. Pobrano 5 lipca 2024 z, <https://arxiv.org/abs/1806.00839>.



Wikipedia. (2023). Social robot. Pobrano 28 marca 2024 z, [https://en.wikipedia.org/wiki/Social\\_robot](https://en.wikipedia.org/wiki/Social_robot).

World Bank. (2021). World development report 2021: Data for better lives. Washington: World Bank. Pobrano 7 marca 2024 z, <https://doi.org/10.1596/978-1-4648-1600-3> <https://openknowledge.worldbank.org/bitstream/handle/10986/35218/9781464816000.pdf>.

World Economic Forum. (2020). *The Future of Jobs Report 2020*. Pobrano 3 sierpnia 2024 z, <https://www.weforum.org/reports/the-future-of-jobs-report-2020>.

World Economic Forum. (2025). *The Future of Jobs Report 2025*. WEF.

World Health Organization. (2018). Gaming disorder. Pobrano 5 kwietnia 2024 z, <https://www.who.int/news-room/questions-and-answers/item/addictive-behaviours-gaming-disorder>.



## Spis tabel

Tabela 7.1 Liczbowy i procentowy rozkład badanych pod względem płci.....	155
Tabela 7.2 Liczbowy i procentowy rozkład badanych pod względem wieku.....	155
Tabela 7.3 Liczbowy i procentowy rozkład badanych pod względem miejsca zamieszkania.....	156
Tabela 7.4 Liczbowy i procentowy rozkład badanych pod względem spędzanego czasu korzystając z technologii cyfrowych w ciągu dnia.....	157
Tabela 7.5 Liczbowy i procentowy rozkład badanych pod względem wpływu technologii na samopoczucie.....	160
Tabela 7.6 Tabela rozkładu badanych pod względem płci na wyniki poznawcze.....	163
Tabela 7.7 Tabela rozkładu badanych pod względem płci na wyniki poznawcze.....	165
Tabela 7.8 Tabela poziomu istotności rozkładu badanych pod względem płci na wyniki poznawcze.....	166
Tabela 7.9 Tabela rozkładu badanych kobiet pod względem wpływu technologii na wyniki poznawcze.....	169
Tabela 7.10 Tabela rozkładu badanych kobiet pod względem wpływu technologii na wyniki poznawcze.....	169
Tabela 7.11 Tabela rozkładu badanych mężczyzn pod względem wpływu technologii na wyniki poznawcze.....	172
Tabela 7.12 Tabela rozkładu badanych mężczyzn pod względem wpływu technologii na wyniki poznawcze.....	173
Tabela 7.13 Tabela rozkładu badanych dzieci pod względem wpływu technologii na wyniki poznawcze.....	176
Tabela 7.14 Tabela rozkładu badanych dzieci pod względem wpływu technologii na wyniki poznawcze.....	177
Tabela 7.15 Tabela rozkładu badanej młodzieży pod względem wpływu technologii na wyniki poznawcze.....	179
Tabela 7.16 Tabela rozkładu badanej młodzieży pod względem wpływu technologii na wyniki poznawcze.....	180
Tabela 7.17 Tabela rozkładu badanych dzieci pod względem wpływu technologii na poziom stresu.....	181



Tabela 7.18 Tabela rozkładu badanych dzieci pod względem wpływu technologii na poziom stresu .....	182
Tabela 7.19 Tabela rozkładu badanych młodzieży pod względem wpływu technologii na poziom stresu.....	183
Tabela 7.20 Tabela rozkładu badanych młodzieży pod względem wpływu technologii na poziom stresu.....	184
Tabela 7.21 Tabela rozkładu badanych mężczyzn i kobiet pod względem wpływu technologii na interakcje społeczne.....	187
Tabela 7.22 Tabela rozkładu badanych pod względem wpływu technologii AI na interakcje społeczne.....	188
Tabela 7.23 Porównanie rang średnich dla każdej grupy .....	189
Tabela 7.24 Porównanie wpływu ilości spędzonych godzin na interakcje społeczne.....	190
Tabela 7.25 Rangi średnie dla każdej grupy.....	191

### **Spis wykresów**

Diagram 7.1 Liczbowy i procentowy rozkład badanych pod względem celu korzystania z technologii cyfrowych.....	158
Diagram 7.2 Liczbowy i procentowy rozkład badanych pod względem celu korzystania z technologii cyfrowych.....	159
Wykres 7.1 Wykresy oraz histogram rozkładu badanych pod względem płci na wyniki poznawcze.....	163
Wykres 7.2 Wykres poziomu istotności rozkładu badanych pod względem płci na wyniki poznawcze.....	166
Wykres 7.3 Wykresy oraz histogram rozkładu badanych kobiet pod względem wpływu technologii na wyniki poznawcze.....	168
Wykres 7.4 Wykresy oraz histogram rozkładu badanych mężczyzn pod względem wpływu technologii na wyniki poznawcze.....	171
Wykres 7.5 Wykresy oraz histogram rozkładu badanych dzieci pod względem wpływu technologii na wyniki poznawcze.....	174
Wykres 7.6 Wykresy oraz histogram rozkładu badanej młodzieży pod względem wpływu technologii na wyniki poznawcze.....	178
Wykres 7.7 Wykresy oraz histogram rozkładu badanych mężczyzn i kobiet pod względem wpływu technologii na interakcje społeczne.....	186



## Załączniki

### Załącznik numer 1 – Ankieta Początkowa

Uzupełniaj wszystkie pola zgodnie z prawdą. Te dane pomogą lepiej zrozumieć mechanizmy wpływu sztucznej inteligencji na rozwój dzieci i młodzieży.

#### Płeć

Kobieta

Mężczyzna

Inna / Nie chcę podawać

#### Wiek

12 - 14 lat

15 - 18 lat

19 - 21 lat

22 - 25 lat

26 - 29 lat

30 - 35 lat

#### Miejsce zamieszkania

Wieś

Małe miasto (do 50 tys. mieszkańców)

Średnie miasto (50-200 tys. mieszkańców)

Duże miasto (powyżej 200 tys. mieszkańców)

#### Czy korzystasz codziennie z technologii (smartfon, komputer, tablet)?

Tak

Nie



**Ile godzin dziennie spędzasz korzystając z technologii cyfrowych?**

Mniej niż 1 godzinę

1 -3 godziny

3 - 5 godzin

Powyżej 5 godzin

**W jakim celu najczęściej korzystasz z technologii cyfrowych? (możesz wybrać więcej niż jedną opcję)?**

Nauka

Rozrywka (gry, filmy, muzyka)

Media społecznościowe

Komunikacja z rodziną i znajomymi

Inne:

**Czy korzystasz z aplikacji lub narzędzi opartych na sztucznej inteligencji (AI)?**

Tak

Nie

Nie wiem

**Jeśli tak, jakie narzędzia AI najczęściej wykorzystujesz? (możesz wybrać więcej niż jedną opcję)**

Chatboty (np. ChatGPT)

Generatory obrazów (np. DALL·E)

Aplikacje edukacyjne

Aplikacje do zarządzania czasem / organizacji

Inne:



**Czy zauważasz, że korzystanie z technologii wpływa na Twoje samopoczucie?**

Tak, pozytywnie

Tak, negatywnie

Nie zauważam wpływu

**Czy Twoi rodzice/opiekunowie ograniczają Twój czas spędzany przed ekranem?**

Tak

Nie



## Załącznik numer 2 - Kwestionariusz Cyfrowego Dobrostanu

### Instrukcja dla uczestników:

„Ten kwestionariusz ma na celu ocenę, jak korzystanie z technologii wpływa na Twoje emocje, zachowania i samopoczucie. Proszę, zaznaczyć odpowiedzi zgodnie z tym, jak często czujesz lub robisz coś w określonych sytuacjach, korzystając z technologii cyfrowych, w tym sztucznej inteligencji. Odpowiedz jak szczerze.”

### Skala ocen:

- **1 - Zdecydowanie się nie zgadzam**
- **2 - Nie zgadzam się**
- **3 - Neutralnie**
- **4 - Zgadza się**
- **5 - Zdecydowanie się zgadzam**

### Sekcja 1: Korzystanie z technologii i samopoczucie

1. Czuję się zestresowany/a, kiedy nie mam dostępu do Internetu lub technologii przez dłuższy czas.

1	2	3	4	5
---	---	---	---	---

2. Spędzam zbyt dużo czasu przed ekranem (komputer, telefon, tablet).

1	2	3	4	5
---	---	---	---	---

3. Korzystanie z technologii pomaga mi w relaksacji i odpoczynku.

1	2	3	4	5
---	---	---	---	---

4. Czuję, że moje życie społeczne jest uzależnione od technologii.

1	2	3	4	5
---	---	---	---	---

5. Czuję się bardziej zestresowany/a, kiedy mam za dużo powiadomień na telefonie.

1	2	3	4	5
---	---	---	---	---

6. Często czuję się zmęczony/a po długim korzystaniu z technologii.

1	2	3	4	5
---	---	---	---	---

7. Korzystanie z Internetu pozwala mi czuć się bardziej połączonym z innymi.

1	2	3	4	5
---	---	---	---	---



8. Mój nastrój pogarsza się, kiedy nie mogę używać technologii.

1	2	3	4	5
---	---	---	---	---

9. Mam trudności w znalezieniu równowagi między czasem spędzonym online i offline.

1	2	3	4	5
---	---	---	---	---

10. Czuję się lepiej, kiedy korzystam z mediów społecznościowych, ponieważ czuję się bardziej zauważony/a.

1	2	3	4	5
---	---	---	---	---

## Sekcja 2: Emocje i zachowania online

11. Czuję się przygnębiony/a, gdy widzę negatywne komentarze w Internecie.

1	2	3	4	5
---	---	---	---	---

12. Korzystanie z technologii wpływa na moją zdolność do koncentracji w innych zadaniach.

1	2	3	4	5
---	---	---	---	---

13. Czuję się niekomfortowo, kiedy muszę przełączyć się z jednego urządzenia na drugie.

1	2	3	4	5
---	---	---	---	---

14. Czuję się samotny/a, gdy nie mam dostępu do Internetu lub mediów społecznościowych.

1	2	3	4	5
---	---	---	---	---

15. Jestem świadomy/a, że spędzam zbyt dużo czasu w sieci, ale nie potrafię tego zmienić.

1	2	3	4	5
---	---	---	---	---

16. Czuję, że korzystanie z AI w aplikacjach pomaga mi lepiej zorganizować mój czas.

1	2	3	4	5
---	---	---	---	---

17. Kiedy nie mam dostępu do Internetu, czuję się odizolowany/a od świata.

1	2	3	4	5
---	---	---	---	---



18. Zdecydowanie zauważam poprawę swojego samopoczucia po zakończeniu korzystania z mediów społecznościowych.

1	2	3	4	5
---	---	---	---	---

19. Technologia sprawia, że czuję się mniej stresowany/a w moim codziennym życiu.

1	2	3	4	5
---	---	---	---	---

20. Czuję, że mój nastrój zależy od tego, jak dużo czasu spędzam online.

1	2	3	4	5
---	---	---	---	---

### Sekcja 3: Zdolności poznawcze i koncentracja

21. Z łatwością angażuję się w naukę lub zadania, korzystając z aplikacji opartych na AI.

1	2	3	4	5
---	---	---	---	---

22. Korzystanie z technologii sprawia, że mam trudności w skupieniu się na zadaniach edukacyjnych.

1	2	3	4	5
---	---	---	---	---

23. Kiedy używam technologii, czuję, że moja koncentracja jest lepsza.

1	2	3	4	5
---	---	---	---	---

24. Kiedy korzystam z mediów społecznościowych, czuję się rozproszony/a i trudno mi się skoncentrować na innych zadaniach.

1	2	3	4	5
---	---	---	---	---

25. Aplikacje edukacyjne i AI pomagają mi szybciej przyswajać nowe informacje.

1	2	3	4	5
---	---	---	---	---

26. Technologia często rozprasza moją uwagę, szczególnie w czasie nauki.

1	2	3	4	5
---	---	---	---	---

27. Czuję się bardziej produktywny/a, kiedy korzystam z technologii do nauki lub pracy.

1	2	3	4	5
---	---	---	---	---



28. Technologia, a w szczególności AI, pomaga mi lepiej zarządzać czasem, który poświęcam na naukę.

1	2	3	4	5
---	---	---	---	---

29. Czuję się mniej zmotywowany/a, gdy używam technologii, żeby się uczyć.

1	2	3	4	5
---	---	---	---	---

30. Korzystanie z mediów społecznościowych sprawia, że często tracę czas, który mógłbym przeznaczyć na naukę lub inne aktywności.

1	2	3	4	5
---	---	---	---	---

#### Sekcja 4: Relacje społeczne i interakcje online

31. Korzystanie z mediów społecznościowych sprawia, że czuję się bardziej połączony/a z moimi przyjaciółmi i rodziną.

1	2	3	4	5
---	---	---	---	---

32. Czuję, że moje relacje z innymi ludźmi są silniejsze dzięki technologii.

1	2	3	4	5
---	---	---	---	---

33. Często czuję, że technologie (w tym AI) pomagają mi nawiązywać głębsze relacje z ludźmi.

1	2	3	4	5
---	---	---	---	---

34. Zdecydowanie czuję się mniej samotny/a, korzystając z mediów społecznościowych.

1	2	3	4	5
---	---	---	---	---

35. Czuję, że media społecznościowe umożliwiają mi wyrażanie siebie w sposób, który jest dla mnie komfortowy.

1	2	3	4	5
---	---	---	---	---

36. Jestem bardziej skłonny/a do dzielenia się osobistymi informacjami w Internecie, dzięki sztucznej inteligencji i aplikacjom.

1	2	3	4	5
---	---	---	---	---

37. Kiedy korzystam z Internetu, czuję, że jestem mniej zaangażowany/a w rzeczywiste spotkania z ludźmi.

1	2	3	4	5
---	---	---	---	---

38. Czuję, że moja aktywność w sieci wpływa na moją relację z rodziną i przyjaciółmi.

1	2	3	4	5
---	---	---	---	---

39. Korzystanie z technologii zmienia sposób, w jaki rozmawiam i wchodzę w interakcje z innymi.

1	2	3	4	5
---	---	---	---	---

40. Zdarza mi się być zaniepokojony/a tym, jak technologie zmieniają moje relacje z innymi ludźmi.

1	2	3	4	5
---	---	---	---	---



## Załącznik nr 3 – SKALA LĘKU SPOŁECZNEGO LSAS-SR

Skala lęku społecznego Leibowitza (The Leibowitz Social Anxiety Scale – LSAS) pozwala ocenić nasilenie objawów fobii społecznej oraz jej wpływu na codzienne funkcjonowanie. Podobnie jak w przypadku wielu testów jej wynik nie jest jednoznaczny z diagnozą fobii społecznej, stanowi raczej pomoc diagnostyczną dla lekarza psychiatry lub psychologa. Mimo to poniższy test na fobię społeczną można wykonać samodzielnie, by szacunkowo określić nasilenie dolegliwości.

Należy przeczytać opisy wszystkich sytuacji przedstawionych w tabeli i każdym przypadku odpowiedzieć na 2 pytania:

- jak mocno doświadczam lęku lub strachu w tej sytuacji oraz
- jak bardzo jestem skłonny unikać takiej sytuacji.

Odpowiedziom należy przypisać następujące punkty:

### Strach lub lęk:

0 = brak

1 = łagodny

2 = umiarkowany

3 = silny

### Unikanie sytuacji:

0 = nigdy (0%)

1 = niekiedy (1 – 33%)

2 = często (34% – 66%)

3 = zawsze (67% – 100%)

Sytuacja	strach lub lęk	unikanie sytuacji
1. Rozmawianie przez telefon przy innych		
2. Bycie w małej grupie osób		
3. Jedzenie w miejscu publicznym		
4. Picie z innymi w miejscu publicznym		
5. Rozmawianie ze zwierzchnikiem, kimś ważnym		
6. Wygłaszanie mowy, bycie aktywnym przed dowolną publicznością		
7. Wyjście na imprezę, spotkanie towarzyskie		
8. Praca gdy jesteś obserwowany		
9. Pisanie gdy jesteś obserwowany		
10. Dzwonienie do osoby, której nie znasz dobrze		
11. Rozmawianie z ludźmi, których nie znasz dobrze		

12. Spotykanie nieznanym osób		
13. Korzystanie z publicznego WC		
14. Wchodzenie do pomieszczenia gdzie inni już siedzą		
15. Bycie w centrum zainteresowania		
16. Przemawianie na spotkaniu		
17. Wykonywanie jakiegoś testu wiedzy lub umiejętności		
18. Spieranie się z osobą, której nie znasz dobrze		
19. Patrzenie w oczy ludziom, których nie znasz		
20. Wygłaszanie przygotowanego wykładu lub raportu przed grupą osób		
21. Podrywanie kogoś		
22. Reklamowanie towaru w sklepie		
23. Urządzanie przyjęcia		
24. Opieranie się natrętnemu sprzedawcy		
<b>Suma:</b>		
<b>Łączna punktacja:</b>		

Należy zsumować wyniki z kolumn „strach lub lęk” oraz z kolumny „unikanie”, tak aby uzyskać „łączną punktację”, co następnie należy porównać z następującymi przedziałami punktowymi:

## Wyniki:

0 – 54 = brak fobii społecznej

55 – 65 = łagodna fobia społeczna

66 – 80 = umiarkowana fobia społeczna

81 – 95 = nasiloną fobia społeczna

96 i więcej = bardzo nasiloną fobia społeczna

Opracowano na podstawie: Liebowitz MR. Social Phobia. Mod Probl Pharmacopsychiatry 1987;22:141-173



## Załącznik nr 4 – SKALA LĘKU SPOŁECZNEGO LSAS-SR-CA

Skala lęku społecznego Leibowitza (The Leibowitz Social Anxiety Scale – LSAS) pozwala ocenić nasilenie objawów fobii społecznej oraz jej wpływu na codzienne funkcjonowanie. Podobnie jak w przypadku wielu testów jej wynik nie jest jednoznaczny z diagnozą fobii społecznej, stanowi raczej pomoc diagnostyczną dla lekarza psychiatry lub psychologa. Mimo to poniższy test na fobię społeczną można wykonać samodzielnie, by szacunkowo określić nasilenie dolegliwości.

Należy przeczytać opisy wszystkich sytuacji przedstawionych w tabeli i każdym przypadku odpowiedzieć na 2 pytania:

- jak mocno doświadczam lęku lub strachu w tej sytuacji oraz
- jak bardzo jestem skłonny unikać takiej sytuacji.

Odpowiedziom należy przypisać następujące punkty:

### Strach lub lęk:

0 = brak

1 = łagodny

2 = umiarkowany

3 = silny

### Unikanie sytuacji:

0 = nigdy (0%)

1 = niekiedy (1 – 33%)

2 = często (34% – 66%)

3 = zawsze (67% – 100%)

Sytuacja	strach lub lęk	unikanie sytuacji
1. Rozmawianie z kolegami z klasy lub innymi osobami przez telefon		
2. Udział w grach zespołowych w klasie		
3. Jedzenie w obecności innych (np. w szkole, stołówce, restauracji)		
4. Poproszenie o pomoc (np. wskazanie drogi lub wyjaśnienie czegoś, czego nie rozumiesz) dorosłego, którego dobrze nie znasz np. sprzedawcy w sklepie, dyrektora, policjanta.		
5. Wygłaszanie ustnego sprawozdania lub prezentacji w klasie (np. „pokaż i opowiedz” w przypadku młodszych dzieci)		
6. Chodzenie na imprezy, tańce lub zajęcia szkolne		
7. Pisanie na tablicy lub w obecności innych osób		
8. Rozmowa z innymi dziećmi, których dobrze nie znasz		
9. Rozpoczynanie rozmowy z osobami, których dobrze nie znasz		



10. Korzystanie ze szkolnych i publicznych toalet		
11. Wchodzenie do klasy lub innego miejsca (np. kościoła, kawiarni, baru), gdy inni już siedzą		
12. Zwracanie na siebie uwagi lub bycie w centrum uwagi (np. na własnym przyjęciu urodzinowym)		
13. Zadawanie pytań na zajęciach		
14. Odpowiadanie na pytania na zajęciach		
15. Czytanie na głos w klasie		
16. Poddanie się testowi		
17. Mówienie „nie” innym, gdy proszą cię o zrobienie czegoś, czego nie chcesz robić (np. pożyczenie czegoś lub sprawdzenie swojej pracy domowej)		
18. Mówienie innym, że się z nimi nie zgadzasz lub że jesteś na nich zły		
19. Patrzenie w oczy osobom, których dobrze nie znasz		
20. Zwrot czegoś w sklepie		
21. Uprawianie sportu lub występowanie przed innymi ludźmi (np. na zajęciach gimnastycznych, recitalu w szkole tańca, koncercie muzycznym)		
22. Przystąpienie do klubu lub organizacji		
23. Poznawanie nowych ludzi lub nieznajomych		
24. Prośenie nauczyciela o pozwolenie na opuszczenie klasy (np. aby pójść do łazienki lub do pielęgniarki)		
<b>Suma:</b>		
<b>Łączna punktacja:</b>		

Należy zsumować wyniki z kolumn „strach lub lęk” oraz z kolumny „unikanie”, tak aby uzyskać „łączną punktację”, co następnie należy porównać z następującymi przedziałami punktowymi:

## Wyniki:

- 0 – 54 = brak fobii społecznej
- 55 – 65 = łagodna fobia społeczna
- 66 – 80 = umiarkowana fobia społeczna
- 81 – 95 = nasiloną fobia społeczna
- 96 i więcej = bardzo nasiloną fobia społeczna

Opracowano na podstawie: Liebowitz MR. *Social Phobia. Mod Probl Pharmacopsychiatry* 1987;22:141-173



## Załącznik nr 5 – Test Pamięci Roboczej i Zdolności Poznawczych

W tym teście sprawdzimy, jak szybko i dokładnie potrafisz przetwarzać informacje. Będziesz odpowiadać na pytania związane z liczbami, wzorcami logicznymi i krótkimi zagadkami. Udzielaj odpowiedzi jak najszybciej i staraj się być jak najbardziej precyzyjny. Pytania są jednokrotnego wyboru. Pod uwagę brany jest czas odpowiedzi, na test masz 5 minut, po rozwiązaniu daj znać, że skończyłeś, gdy upływie czas, usłyszysz komendę STOP, wtedy nie rozwiązuj dalej.

Wybierz poprawną odpowiedź jak najszybciej.

1. Jaki jest wynik  $(22-4)+(10-7)-6 = ?$

- A) 14
- B) 15
- C) 16
- D) 17

2. Jaki jest wynik  $(15 \times 4) + (12/4) - 7 = ?$

- A) 54
- B) 56
- C) 52
- D) 50

3. Jaki jest wynik  $(8/2) + (5-2) - 2 = ?$

- A) 5
- B) 6
- C) 4
- D) 3

4. Jaki jest wynik  $(20/2)/(2 \times 1) = ?$

- A) 5
- B) 4
- C) 6
- D) 3



5. Jaki jest wynik  $(32/2)+(6-8)+3 = ?$

- A) 17
- B) 18
- C) 16
- D) 15

6. Jeśli wszystkie psy są zwierzętami, a wszystkie zwierzęta mają ogony, to czy psy mają ogony?

- A) TAK
- B) NIE

7. Jaki jest następny element w sekwencji: 2, 4, 6, \_\_?

- A) 7
- B) 8
- C) 9
- D) 10

8. Jeśli 3 osoby podniosą 3 ciężary w 3 godziny, ile osób musiałoby podnieść 6 ciężarów w 6 godzin?

- A) 3
- B) 4
- C) 6
- D) 9

9. Jeśli kwadrat ma 4 boki, ile boków ma równoległobok?

- A) 4
- B) 6
- C) 5
- D) 3



10. W ciągu tygodnia Adam, Bartek, i Michał odwiedzają bibliotekę łącznie 21 razy. Ile razy średnio odwiedza bibliotekę każdy z nich?

- A) 5
- B) 7
- C) 6
- D) 4

11. Jeśli liczba trzy jest większa od liczby dwa, to jaka jest różnica między nimi?

- A) 2
- B) 3
- C) 1
- D) 4

12. Kiedy wybieramy liczbę osiem, to jaką liczbę dostaniemy, gdy ją podzielimy przez dwa?

- A) 3
- B) 5
- C) 4
- D) 6

13. Jaką liczbę otrzymamy, jeśli pomnożymy siedem przez trzy?

- A) 21
- B) 23
- C) 19
- D) 18

14. Jaki wynik otrzymamy, jeśli podzielimy liczbę dziesięć przez liczbę pięć?

- A) 5
- B) 2
- C) 3
- D) 4



15. Jeśli masz dwanaście jabłek, a oddasz pięć, ile pozostanie ci jabłek?

- A) 5
- B) 7
- C) 6
- D) 8

