

Sztuczna inteligencja (AI) jako megatrend kształtujący edukację

**Jak przygotowywać się na szanse
i wyzwania społeczno-gospodarcze
związane ze sztuczną inteligencją?**

Sztuczna inteligencja (AI) jako megatrend kształtujący edukację

**Jak przygotowywać się na szanse
i wyzwania społeczno-gospodarcze
związane ze sztuczną inteligencją?**

Warszawa 2022

Autorzy:

dr Marcin Będkowski
dr hab. Jakub Brdulak, prof. SGH
prof. dr hab. Jan Fazlagić
lek. Michał Janiszewski
prof. dr hab. Dariusz Jemielniak
lek. Ligia Kornowska
Cezary Piekarski
dr hab. Aleksandra Przegalińska, prof. ALK
dr Joanna Rabiega-Wiśniewska
Jakub Stęchły
Wojciech Stęchły
prof. dr hab. Jacek Szoltysek
prof. dr hab. Maciej M. Sysło
Mirośław Usidus

Redakcja naukowa: prof. dr hab. Jan Fazlagić

Koordinacja publikacji: Beata Balińska

Redakcja językowa: Monika Niewielska

Projekt okładki i skład: Wojciech Maciejczyk

Zdjęcie na okładce: Shutterstock.com

Druk:

Sil-Veg-Druk s.c.

Wydawca:

Instytut Badań Edukacyjnych; ul. Górczewska 8, 01-180 Warszawa
tel. (22) 241 71 00; www.ibe.edu.pl

© Copyright by: Instytut Badań Edukacyjnych, Warszawa 2022

ISBN 978-83-67385-10-7

Wzór cytowania:

Fazlagić, J. (red.) (2022). *Sztuczna inteligencja (AI) jako megatrend kształtujący edukację. Jak przygotowywać się na szanse i wyzwania społeczno-gospodarcze związane ze sztuczną inteligencją?* Warszawa: Instytut Badań Edukacyjnych.

Publikacja sfinansowana w ramach projektu „Prowadzenie i rozwój Zintegrowanego Rejestru Kwalifikacji (etap 2)”, realizowanego przez Instytut Badań Edukacyjnych na zlecenie Ministerstwa Edukacji i Nauki, współfinansowanego ze środków Unii Europejskiej w ramach Programu Operacyjnego „Wiedza, Edukacja, Rozwój”.

Egzemplarz bezpłatny

Spis treści

Wstęp	5
Wprowadzenie	7

Społeczeństwo i państwo

prof. ALK dr hab. Aleksandra Przegalińska Współpracująca sztuczna inteligencja. Przykład wirtualnych asystentów i konwersacyjnej AI.....	12
prof. dr hab. Jan Fazlagić Rozwój sztucznej inteligencji jako wyzwanie dla systemu edukacji.....	25
prof. dr hab. Jan Fazlagić Między sztuczną inteligencją a „sztuczną kreatywnością” – przyszłość człowieka kreatywnego w epoce sztucznej inteligencji.....	38
Mirosław Usidus Algorytmy, dane i media. Rozwój kompetencji w zakresie sztucznej inteligencji oraz analizy <i>big data</i> w świecie środków masowego przekazu.....	51

Edukacja

prof. dr hab. Maciej M. Sysło Sztuczna inteligencja wkracza do szkół: jak uczyć się o AI i z pomocą AI	74
prof. dr hab. Dariusz Jemielniak Edukacja cyfrowa: e-learning, blended learning	99
dr Joanna Rابيةga-Wiśniewska, Wojciech Stęchły, dr Marcin Będkowski Edukacja medialna i sztuczna inteligencja w kontekście społecznym	109

Przemysł

prof. dr hab. Jacek Szoltysek, Jakub Stęchły Związki sztucznej inteligencji i edukacji – szanse i zagrożenia dla stron procesu edukacji w kontekście miejskim	121
----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------	-----

Usługi

dr hab. Jakub Brdulak, Cezary Piekarski Rola edukacji – potrzeba rozwoju kompetencji cyfrowych. Perspektywa cyberbezpieczeństwa.....	144
---------------------------------------------------------------------------------------------------------------------------------------------------	-----

<i>lek. Ligia Kornowska</i>	
Rewolucja sztucznej inteligencji (AI) w ochronie zdrowia	156
<i>lek. Michał Janiszewski</i>	
Wykorzystanie sztucznej inteligencji w opiece nad osobami starszymi. Nowe kompetencje cyfrowe w geriatrici	167
Informacje o autorach	185
Słowniczek	188

Realizując projekty wdrażające Zintegrowany System Kwalifikacji, Instytut Badań Edukacyjnych skupia się na różnych obszarach merytorycznych związanych z systemem kwalifikacji, szeroko rozumianą edukacją, opisem kwalifikacji zawodowych, wspieraniem i propagowaniem polityki uczenia się przez całe życie oraz realizacją działań ujętych w Zintegrowanej Strategii Umiejętności. Wszystkie działania podejmowane w projekcie „Prowadzenie i rozwój Zintegrowanego Rejestru Kwalifikacji – etap 2” (ZRK2) służą wzmocnieniu użyteczności Zintegrowanego Systemu Kwalifikacji, głównie przez tworzenie środowisk informatycznych, aplikacji oraz narzędzi teleinformatycznych ułatwiających korzystanie z systemu.

W ramach projektu ZRK2 przygotowany został także raport zatytułowany *Sztuczna inteligencja (AI) jako megatrend kształtujący edukację. Jak przygotowywać się na szanse i wyzwania społeczno-gospodarcze związane ze sztuczną inteligencją?* Dokument ten prezentuje zależności między edukacją a sztuczną inteligencją i uzasadnia konieczność rozwijania kompetencji cyfrowych wśród Polaków. Pokazuje ponadto, jak nowe kierunki rozwoju gospodarczego dzisiejszych społeczeństw wymuszają konieczność dokonywania zmian w edukacji oraz w sposobie myślenia o kwalifikacjach. Wyjaśnia też, dlaczego rozumienie i umiejętność stosowania AI staną się ważnymi elementami przyszłych kwalifikacji.

Sztuczna inteligencja to jeden z najważniejszych trendów kształtujących współczesną rzeczywistość. Przygotowanie ludzi na coraz szybciej następujące w otaczającym ich świecie zmiany wymaga podjęcia intensywnych działań w obszarach edukacji oraz kształcenia. Muszą one umożliwić społeczeństwu sprawne i efektywne reagowanie na wyzwania związane ze sztuczną inteligencją. Dlatego Instytut Badań Edukacyjnych do przygotowania raportu zaprosił grupę naukowców, ekspertów i praktyków. Chcieliśmy bowiem zwrócić uwagę na nowy obszar wyzwań dla edukacji nie tylko decydentów i naukowców, ale także specjalistów, którzy na różnych poziomach zajmują się edukacją: nauczycieli, przedstawicieli administracji oświatowej oraz instytucji zajmujących się szkoleniem i doskonaleniem nauczycieli.

Wyzwania te mają bardzo zróżnicowany charakter. Stale przyspieszająca cyfryzacja, robotyzacja miejsc pracy oraz rozwój sztucznej inteligencji zmieniają zapotrzebowanie na zawody, kwalifikacje i umiejętności. Z tego powodu niezbędne jest wspieranie kompetencji kluczowych oraz przekrojowych, które będą odpowiadać na potrzeby młodego pokolenia i stojących przed nim wyzwań. Jak pokazują autorzy, konieczne jest kształtowanie obywateli świadomych tego, czym są technologie oparte na sztucznej inteligencji i jaki mają na nas wpływ.

Raport ukazuje, jak AI zmienia nasze środowisko pracy (przemysł 4.0, narzędzia i aplikacje), jak oddziałuje na codzienne życie (*smart city*, *smart home*, komunikacja społeczna, media, ochrona zdrowia i opieka nad osobami starszymi) oraz jak wpływa na to, czego się uczymy i na to, w jaki sposób powinniśmy wykorzystywać naszą wiedzę.

Aby wiarygodnie omówić te kwestie, konieczne było zebranie odpowiednich danych, uporządkowanie ich i naukowe zinterpretowanie wyników. W trosce o rzetelny obraz istniejącej sytuacji oraz o sformułowanie wiążących i trafnych wniosków zastosowano metodologię wykorzystywaną przy opracowywaniu raportów o rozwoju społecznym, która umożliwia profesjonalne zestawianie i analizowanie zebranych danych.

Pragniemy, aby ten raport, dedykowany przedstawicielom administracji rządowej, pozarządowej oraz szeroko rozumianej grupie nauczycieli (zarówno pracujących w szkołach, jak też nauczycieli akademickich) wytyczył kierunki i zainspirował do zmian w edukacji, dzięki którym można będzie sprostać wyzwaniom stawianym przez dynamicznie rozwijające się nowe technologie informatyczne. Liczymy również na to, że publikacja raportu zainspiruje różne środowiska do wzięcia udziału w dalszej dyskusji dotyczącej wyzwań, jakie przed edukacją stawia coraz bardziej zaawansowane i wielokierunkowe wykorzystywanie sztucznej inteligencji. Debatę taką Instytutu Badań Edukacyjnych chce systematycznie prowadzić i wspierać.

dr hab. Robert T. Ptaszek, prof. KUL
Dyrektor Instytutu Badań Edukacyjnych

Mniej więcej 20 lat po tym, jak polscy kryptolodzy z Uniwersytetu Poznańskiego złamali kody niemieckiej maszyny szyfrującej Enigma, brytyjski matematyk Alan Turing zadał pytanie: „Czy maszyny potrafią myśleć?”. W swoim artykule *Computing Machinery and Intelligence* (1950) przedstawił podstawowy cel oraz wizję sztucznej inteligencji. Podstawowym jej zadaniem miało być stworzenie substytutu ludzkiego umysłu. Pamięć o prapoczątkach badań nad sztuczną inteligencją jest od niedawna kultywowana dzięki Centrum Szyfrów Enigma (CSE), instytucji kultury Miasta Poznania. Działalności CSE przyświeca hasło „Prawdziwa historia. Wyzwanie dla umysłu”. Łączy ono w sobie dwa najważniejsze komponenty przekazu edukacyjnego: wspartą multimediami opowieść o złamaniu przez polskich/poznańskich kryptologów szyfru niemieckiej maszyny Enigma oraz narrację o konsekwencjach tego wydarzenia dla przebiegu II wojny światowej i szerzej – dla rozwoju technologii przekazywania i szyfrowania informacji. Dzięki CSE w doskonały sposób łączy się edukację na rzecz zainteresowania młodych ludzi naukami ścisłymi z edukacją patriotyczną. Odwiedzający poznają historię złamania szyfru Enigmy przez absolwentów Uniwersytetu Poznańskiego: Mariana Rejewskiego, Henryka Zygalskiego i Jerzego Różyckiego. Opowiada ona o ich matematycznej pracy, o maszynach i narzędziach służących do walki z szyfrem Enigmy, także tych stworzonych przez Polaków, takich jak cyklometr, bomba Rejewskiego czy płachty Zygalskiego. Polscy kryptolodzy byli pierwszymi, którzy niemieckiej maszynie szyfrującej Enigma przeciwstawili inne maszyny. CSE przygotowało także wystawę, która prezentuje rewolucję informatyczną, jaka dokonała się po II wojnie światowej za sprawą wytężonej pracy kryptologów. Rewolucja ta trwa do dziś, czyli do epoki, w której tak dynamicznie rozwija się sztuczna inteligencja.

Jak na razie badania dotyczące sztucznej inteligencji są ograniczone z powodu braku pełnej wiedzy na temat tego, czym jest umysł. Nie potrafimy jeszcze symulować za pomocą algorytmów wszystkich zachowań i reakcji emocjonalnych człowieka, co często powoduje rozdzźwięk pomiędzy oczekiwaniami wobec technologii a jej możliwościami. Niewątpliwie dużym wyzwaniem dla twórców sztucznej inteligencji jest symulacja zachowań irracjonalnych, które w wielu sytuacjach życiowych są typowe dla człowieka, a z tego powodu jeszcze trudniejsze do odtworzenia w sposób syntetyczny. W wielu zastosowaniach sztuczna inteligencja nie tyle będzie zastępować człowieka, co raczej współpracować z nim. Jeremy Achin na Datarobot AI Experience w 2017 roku zdefiniował sztuczną inteligencję jako: „System komputerowy zdolny do wykonywania zadań, które w zwykłych okolicznościach wymagają ludzkiej inteligencji [...]. Wiele systemów sztucznej inteligencji jest zasilanych przy pomocy uczenia się maszynowego, niektóre przy pomocy głębokiego uczenia się, a niektóre przy pomocy bardzo mało ekscytujących rzeczy, takich jak zasady¹”. Niektórzy badacze podchodzą sceptycznie do obecnego stanu rozwoju sztucznej inteligencji i twierdzą, że jest ona zaledwie formą automatyzacji pewnych procesów myślenia (np. oprogramowanie do rozpoznawania twarzy, asystenci osobiści Siri lub Alexa, samochody autonomiczne i in.), co oznacza, że moment w czasie, gdy powstanie

¹ DataRobot AI Experience – Keynote from CEO Jeremy Achin
<https://www.youtube.com/watch?v=ZChA63CpX5o>, 2018, dostęp: 20.12.2021, tłumaczenie własne autora.

holistyczny system informatyczny zdolny do symulowania procesów myślenia człowieka w ogólnym sensie, jest jeszcze bardzo odległy. Z drugiej strony, w ciągu II dekady XXI wieku powstało wiele spektakularnych rozwiązań demonstrujących olbrzymi potencjał sztucznej inteligencji, wśród których warto wymienić między innymi poniższe:

- W 2016 roku zespół Google DeepMind AlphaGo pokonał mistrza świata w grze w Go Lee Sadola. Złożoność starożytnej chińskiej gry była wcześniej uznawana za główne wyzwanie dla sztucznej inteligencji.
- W 2016 roku firma Hanson Robotics opracowała pierwszego humanoidalnego robota o nazwie Sophia, który był zdolny do rozpoznawania twarzy, komunikacji werbalnej i ekspresji wyrazu twarzy.
- W 2018 roku firma Waymo uruchomiła usługę Waymo One, która pozwalała użytkownikom znajdującym się na obszarze metropolitalnym miasta Phoenix w stanie Arizona na korzystanie z samochodów autonomicznych.
- W 2020 roku firma Baidu opracowała algorytm LinearFold AI pomagający zespołom naukowców w pracach nad szczepionką przeciwko wirusowi SARS-CoV-2. Algorytm jest zdolny do przewidywania mutacji sekwencji wirusa RNA w czasie 27 sekund, to znaczy 120 szybciej niż dotychczas stosowane metody.

Skuteczność sztucznej inteligencji w wielu zastosowaniach ciągle opiera się na zdolności komputera do uczenia się na podstawie dostarczonych przez człowieka lub przez inne maszyny danych, w tym poprzez głębokie uczenie się (*deep learning*). Trzeba jednak wyraźnie stwierdzić, że jak dotąd nie powstał uniwersalny algorytm uczenia się, zapewniający skuteczność działania we wszystkich warunkach i środowiskach.

Niniejsza publikacja koncentruje się na specyficznych możliwościach wykorzystania sztucznej inteligencji dotyczących szeroko rozumianej edukacji. Według danych Banku Światowego w 2018 roku polskie wydatki na edukację stanowiły 4,6% PKB. Podobny odsetek charakteryzuje większość krajów na świecie. Jednocześnie sektor edukacji jest tym sektorem gospodarki, który pod wieloma względami absorbuje innowacje w tempie wolniejszym niż pozostałe sektory (np. ochrona zdrowia, sektor farmaceutyczny, IT, transport i in.)². Sukcesy i niewątpliwy postęp w rozwoju sztucznej inteligencji budzą optymizm i nadzieje związane z możliwościami jej wykorzystania w sektorze edukacji. Potencjalne spektrum zastosowań jest niezwykle szerokie. Pierwszym skojarzeniem, jakie nasuwa się przy rozważaniach na temat wykorzystania sztucznej inteligencji, jest zastąpienie nauczyciela przez robota, który symuluje żywego człowieka w roli nauczyciela. Jest to prawdopodobnie najwyższe stadium zaawansowania sztucznej inteligencji, które zostanie osiągnięte na bardzo późnym, raczej odległym w czasie, etapie jej ewolucji, ponieważ robot w roli nauczyciela musi demonstrować niezwykle szerokie, w zasadzie kompletne spektrum zachowań żywego człowieka (w przeciwieństwie na przykład do robota w roli kontrolera lotów czy też robota w roli kierowcy pojazdu mechanicznego). Historia rozwoju

² Patrz: OECD (2000). *Knowledge Management in the Learning Society*. Paris.

innowacji uczy nas, że nowe rozwiązania zwykle „infiltrują” obszar swojej interwencji w sposób stopniowy. Na przykład pierwsza maszyna parowa napędzająca statek została zainstalowana w latach 20. XIX wieku, natomiast ostatnie statki komercyjne wykorzystujące napęd żaglowy zniknęły z powierzchni oceanów w latach 60. XX wieku. Prawdopodobnie podobna sytuacja będzie miała miejsce w przypadku zastosowań sztucznej inteligencji w sektorze edukacji: najpierw będą pojawiać się pewne mniej zaawansowane rozwiązania niedające znaczących korzyści w stosunku do człowieka, po czym, z upływem czasu i wraz z rozwojem technologii, będą one stawać się coraz bardziej skuteczne. Jeśli spojrzymy na rewolucję internetową z perspektywy jej wpływu na sektor informacyjny, to okaże się, że internet był pierwszym medium informacyjnym, które pozwalało na jednoczesne oferowanie pogłębionych informacji (w epoce poprzedzającej taką możliwość dawała książka – dzięki wynalezionej przez Gutenberga technologii ruchomej czcionki w druku) oraz informacji dostępnych dla masowego odbiorcy (w epoce poprzedzającej taką możliwość dawały telewizja i radio – dzięki falam radiowym). Możemy się pokusić o poszukiwanie analogii: sztuczna inteligencja w przyszłości być może pozwoli na oferowanie *wysokiej jakości edukacji dla masowego odbiorcy* za pomocą symulowania przez algorytmy najbardziej skutecznych strategii nauczania dostosowanych do konkretnego ucznia/osoby uczącej się. Aby to jednak nastąpiło, sztuczna inteligencja powinna „dojrzeć” intelektualnie. Celem mniej ambitnym, ale za to bardziej realistycznym jest tworzenie algorytmów sztucznej inteligencji symulujących zachowania nauczyciela w pewnych wąskich obszarach, na przykład dotyczących oceniania wyników prac uczniów. Trzeba wyraźnie zaznaczyć, że już na obecnym stadium rozwoju algorytmów istnieje wiele obszarów zastosowań sztucznej inteligencji w edukacji (niektóre z nich zostały omówione w niniejszej pracy), które z powodzeniem mogą i powinny być wykorzystywane. Oprócz wspomnianej wcześniej specjalizacji w wąskich obszarach, duży potencjał stanowią te obszary pracy nauczyciela, które mogą zostać zautomatyzowane w celu odciążenia go od nudnych i wyczerpujących zadań biurokratycznych.

W niniejszej pracy autorzy specjalizujący się w różnych zastosowaniach sztucznej inteligencji podzielili się z Czytelnikami swoją wiedzą i doświadczeniami dotyczącymi różnorodnych zastosowań sztucznej inteligencji, ze szczególnym uwzględnieniem aspektów związanych z szeroko rozumianą edukacją. Jest to pierwsze kompleksowe opracowanie w języku polskim z tego zakresu. Z pewnością nie wyczerpuje ono głębi i złożoności zagadnień. Jego głównym celem jest przede wszystkim zwrócenie uwagi decydentów, naukowców, a może przede wszystkim praktyków: polskich nauczycieli, przedstawicieli administracji oświatowej, instytucji zajmujących się szkoleniem i doskonaleniem nauczycieli na wyłaniający się, zupełnie nowy obszar wyzwań dla edukacji. Wyzwania te nie dotyczą jednak wyłącznie szeroko rozumianej organizacji pracy instytucji edukacyjnych i ich zaplecza administracyjnego. Być może ważniejsze jest dostosowanie polskiego systemu edukacji do wyzwań na rynku pracy i w otoczeniu społeczno-gospodarczym związanych z rozwojem przemysłu 4.0, którego sztuczna inteligencja jest ważnym komponentem. Polskie szkoły i uczelnie powinny jak najszybciej przekonstruować programy nauczania i sylabusy, aby ich absolwenci byli gotowi na wyzwania związane z czwartą rewolucją przemysłową, która w mniej lub bardziej dostrzegalny sposób, w różnym tempie w zależności od sektora gospodarki, wkracza do naszego życia.

Niniejsza praca jest efektem wielu spotkań i dyskusji, jakie odbywały się w gronie wszystkich jej autorów przez cały 2021 rok. Zawiera duży komponent wiedzy teoretycznej i praktycznej z różnych obszarów funkcjonowania społeczeństwa i gospodarki, pokazuje perspektywę zarówno osób odpowiedzialnych za organizację systemu edukacji, jak i beneficjentów systemu edukacji, czyli społeczeństwa w szerokim tego słowa znaczeniu. Opracowanie zostało podzielone na cztery części, w ramach których wydzielono rozdziały. Każda część odzwierciedla różne perspektywy tematyki sztucznej inteligencji. Na końcu publikacji Czytelnik znajdzie słownik zawierający definicje omawianych pojęć. Słownik może być przydatny zarówno badaczom zjawisk związanych ze sztuczną inteligencją, jak i praktykom, którzy dzięki niemu będą mogli usystematyzować swoją wiedzę oraz skutecznie popularyzować tę tematykę.

W imieniu wszystkich Autorów i Auterek oraz innych osób zaangażowanych w powstanie niniejszej publikacji, w tym zespołu Instytutu Badań Edukacyjnych w Warszawie, którego prace koordynowała Pani Beata Balińska, wyrażam nadzieję, że publikacja przyczyni się do unowocześnienia polskiej edukacji – z korzyścią dla naszego kraju i perspektyw jego długookresowego rozwoju.

Redaktor naukowy
Prof. dr hab. Jan Fazlagić
Uniwersytet Ekonomiczny w Poznaniu

Spółeczeństwo i państwo

Współpracująca sztuczna inteligencja. Przykład wirtualnych asystentów i konwersacyjnej AI

prof. ALK dr hab. Aleksandra Przegalińska*

Wprowadzenie

W ostatnich latach doszło do znacznego uproszczenia (tzw. podejścia *low code* oraz *no code*³ – Shaikh, 2020) interfejsów pozwalających bez umiejętności programowania budować i implementować sztuczną inteligencję (*artificial intelligence* – AI) oraz stosować uczenie maszynowe (*machine learning* – ML) do różnego typu zadań. W tym uproszczeniu upatruje się szansę na większe upowszechnienie stosowania sztucznej inteligencji, a – co za tym idzie – także jej demokratyzację.

Niniejszy artykuł będzie dotyczył demokratyzacji sztucznej inteligencji i upowszechniania się umiejętności korzystania z niej. Jest to związane z coraz bardziej popularnym paradygmatem tworzenia sztucznej inteligencji, który zakłada jej ścisłą współpracę, a wręcz synchronizację z człowiekiem. Paradygmat ten nosi nazwę „współpracującej sztucznej inteligencji” (*Collaborative AI*) (Koch, 2017; Koch and Oulasvirta, 2018), a sama sztuczna inteligencja rozumiana jest w nim nie tylko jako potężne narzędzie, z którego człowiek może korzystać przy wykonywaniu rozmaitych zadań, ale z którą także – a może raczej przede wszystkim – jest w stanie owocnie współpracować. Najwięcej przykładów na uproszczenie sztucznej inteligencji oraz interfejs umożliwiający płynną współpracę z człowiekiem możemy znaleźć w obszarze konwersacyjnej sztucznej inteligencji (*Conversational AI*) i na niej się przede wszystkim skupimy.

W artykule przyjrzymy się także aktualnym trendom rozwojowym sztucznej inteligencji w kontekście rynku pracy oraz zawodów przyszłości. Nacisk położony zostanie również na umiejętności cyfrowe niezbędne do tego, by skutecznie korzystać ze sztucznej inteligencji w pracy opartej na wiedzy (*knowledge work*). Jako przykład posłużą tu popularni dzisiaj wirtualni asystenci oraz konwersacyjna sztuczna inteligencja. W artykule postaram się wskazać, jakie formy konwersacyjnej sztucznej inteligencji są aktualnie najbardziej rozpowszechnione, jakie są zakresy ich wykorzystania oraz jakie umiejętności są wymagane, by z nich skutecznie korzystać zarówno w życiu zawodowym, jak i na późniejszych etapach edukacji akademickiej, niekoniecznie związanych bezpośrednio z informatyką oraz sztuczną inteligencją.

³ Patr: <https://towardsdatascience.com/top-8-no-code-machine-learning-platforms-you-should-use-in-2020-1d1801300dd0>

* Akademia Leona Koźmińskiego, ORCID: 0000-0003-0864-8007

Sztuczna inteligencja a rynek pracy dzisiaj i jutro

Sztuczna inteligencja jest klasyfikowana jako technologia ogólnego przeznaczenia (*general purpose technology*⁴). Jest to określenie zarezerwowane do opisu technologii fundamentalnie transformujących nasze życie, czyli takich jak silnik parowy i internet, które powodują znaczący i powszechny wpływ na społeczeństwo i gospodarkę. AI już ma i będzie nadal miała niewątpliwie istotny wpływ na to, jak ludzie żyją i pracują. Skumulowany zakres zmian wywołanych przez AI pozostaje w znacznym stopniu nieznany, a przez to nierzadko prowadzi do alarmistycznych, dystopijnych wizji przyszłości bez pracy ludzkiej, mimo że roczne tempo zmian, jeśli chodzi o rynek pracy, nie każe raczej bić na alarm.

Obecnie AI nie może (a w normatywnym sensie także nie powinna) zastąpić ludzkich pracowników, ale może zwiększyć ich produktywność, a nawet satysfakcję. Niektórzy badacze (Acemoglu and Restrepo, 2017) łączą zwiększoną intensywność wykorzystania AI i robotów ze zmniejszeniem zatrudnienia i płac, sugerując potrzebę wprowadzenia tak zwanego powszechnego dochodu podstawowego (*Universal Basic Income* – UBI). Inni twierdzą natomiast, że szybko dojdzie do zautomatyzowania milionów miejsc pracy na całym świecie, przez co znacznie więcej miejsc pracy zniknie, niż powstanie (Furman and Seamans, 2019; Goolsbee, 2018). Niektórzy analitycy trendów w zakresie transformacji rynku pracy zgadzają się z tymi skądinąd ponurymi wizjami, ale inni przewidują coś zgoła przeciwnego. AI w ciągu dekady wyprze około jednej trzeciej istniejących miejsc pracy na całym świecie, przy czym wśród najbardziej dotkniętych tą zmianą znajdą się Stany Zjednoczone (do 40%) i Japonia (50%). Jednakże według *OECD AI Policy Observatory* AI stworzy więcej miejsc pracy niż zlikwiduje. Przedsiębiorstwa, które są pionierami w rozwoju i skalowaniu AI, jak dotąd nie zlikwidowały miejsc pracy w ujęciu netto. Zdaniem *OECD AI Policy Observatory* nic nie wskazuje na to, żeby tendencja ta nie utrzymała się w przewidywalnej przyszłości. Podobne wnioski wynikają z najnowszego raportu *Human-Centered Artificial Intelligence* Uniwersytetu Stanforda, mówiącego o transformacji pracy w dobie post-COVID. Tym bardziej zatem warto inwestować w umiejętności cyfrowe pozwalające na skuteczniejsze korzystanie z AI.

Predykcje dalszych ścieżek rozwoju sztucznej inteligencji

W psychologii (Conoley and Conoley, 2010) współpraca jest definiowana jako „akt lub proces dwóch lub więcej osób współpracujących ze sobą w celu uzyskania wyniku pożądanego przez wszystkich” lub „relacja interpersonalna, w której strony wykazują się wrażliwością na potrzeby innych”. Współpraca w wymiarze ekonomicznym definiowana jest jako umiejętność zespołowego wykonywania zadań i wspólnego rozwiązywania problemów na rzecz osiągnięcia wspólnych celów (Barbara and Celebrate, 1989).

Współpraca co do zasady odbywa się głównie między ludźmi, ale pozostawia miejsce także dla technologii. Współpraca między ludźmi i maszynami może przybierać różne formy (Jemielniak i Przegalińska, 2020). Na przykład rozmaite narzędzia zaprojektowane i służące do komunikacji już od dawna pozwalają na kontakt na

⁴ Patrz: https://warwick.ac.uk/fac/soc/economics/research/centres/cage/news/06-07-20-artificial_intelligence_as_a_general_purpose_technology_an_historical_perspective/

odległość (poczta elektroniczna, narzędzia do wideokonferencji lub inne technologie umożliwiające teleobecność, jak VR, ang. *virtual reality*). Stają się także pośrednikami współpracy, pozwalając m.in. na wspólne, zdalne i nierzadko asynchroniczne zarządzanie projektami (jak Slack i inne komunikatory).

Obecnie jednak wchodzimy na kolejny poziom współpracy człowiek-maszyna. Dzieje się tak, gdy system może dawać efekty synergii z ludźmi: generować wartość dodaną, której nie byłoby, gdyby do takiej współpracy nie doszło. Zwolennikiem podejścia do AI opartego na współpracy jest zresztą Tom Malone z MIT Sloan School of Management (Malone, 2018), autor, którego prace zostaną w niniejszym artykule jeszcze przywołane i który w swojej ostatniej książce *Superminds* przekonuje o sile ludzi i maszyn pracujących i myślących razem. Twierdzi on, że postępy w zakresie sztucznej inteligencji mogą spowodować pojawienie się nowatorskich idei, a nawet rozwiązań najbardziej palących bieżących problemów. Warto wspomnieć, że konwergencja możliwości człowieka i robota jest również często dyskutowana jako możliwe rozwiązanie dystopijnego scenariusza, według którego AI anihiluje ludzkość. Jest ona postulowana przez wielu wybitnych futurologów.

Zgodnie z koncepcją Malone'a, AI powinna dość szybko rozwinąć wiedzę dziedzinową i stać się ekspertem w określonych zadaniach. Wyposażeni w taką sztuczną inteligencję ludzie bardziej efektywnie wykorzystywaliby własne talenty, zdolności i umiejętności (m.in. z zakresu syntetyzowania wiedzy) do rozwiązywania problemów. Na przykład niedawno przeprowadzone badania eksperymentalne wykazały, że przy tworzeniu systemu montażowego we współpracy ludzi i robotów zwiększa się produktywność (Seamans and Raj, 2018; Manyika et al., 2017). Takich przykładów można znaleźć więcej, choćby systemy wspierające pracę kreatywną (kompozycje muzyczne, pisanie scenariuszy filmowych lub draftowanie kampanii marketingowych), a także inteligentne systemy stosowane w fabrykach⁵.

W perspektywie krótko- i średnioterminowej rozwój AI będzie najpewniej podążał dwiema odrębnymi ścieżkami. Pierwsza z nich to ekstrapolacja tego, czym AI jest dzisiaj – wysoce wyspecjalizowane algorytmy głębokiego uczenia się, mające zastosowanie do jasno zdefiniowanych problemów w bardziej złożony, kontekstowy i zniuansowany sposób. Druga ścieżka wiąże się z tworzeniem systemów AI zdolnych do przetwarzania informacji w sposób podobny, jak robi to ludzki mózg. Obecnie głębokie sieci neuronowe stały się kluczowym paradygmatem w AI częściowo dzięki algorytmowi zwanemu wsteczną propagacją. To propagacja wsteczna umożliwia głębokim sieciom neuronowym uczenie się na podstawie danych, a tym samym uzyskanie takich możliwości, jak tłumaczenie języka, rozpoznawanie mowy i klasyfikacja obrazów. Wąsko wyspecjalizowana sztuczna inteligencja raczej nie wpłynie na liczbę miejsc pracy *per se*, ale podobnie jak wcześniejsze rewolucje technologiczne, spowoduje głęboką zmianę w gospodarce oraz redefinicję samych zadań stawianych przed pracownikami, przemianę modeli i strategii biznesowych oraz sposobów funkcjonowania rozmaitych instytucji.

Druga ścieżka rozwoju AI inspirowanej biologicznie ma duży potencjał przekształcenia możliwości AI i przewyciężenia jej obecnych ograniczeń, tworząc solidniejsze i bardziej złożone systemy, zdolne do bardziej abstrakcyjnych poziomów

⁵ Patrz: <https://www.ai4eu.eu/simple-guide-collaborative-artificial-intelligence>

rozumowania. Pozostaje ona jednak w fazie początkowej, a więc oddalonej od nas o wiele lat i trudno – przynajmniej na razie – odnosić się do tego, jak zmieni rynek pracy i jak wpłynie na charakter relacji człowieka i technologii. Miałoby to charakter czystej spekulacji.

Typy i zastosowania konwersacyjnej sztucznej inteligencji oraz NLP

Przetwarzanie i rozumienie języka naturalnego (NLP oraz NLU) jest dziedziną na styku sztucznej inteligencji, informatyki oraz lingwistyki, zajmującą się interakcjami między komputerami a językiem ludzkim (naturalnym), w szczególności zaś zadaniem programowania komputerów do przetwarzania i analizowania dużych ilości danych językowych – głównie tekstowych w językach naturalnych. NLP i NLU mogą precyzyjnie wydobywać informacje i spostrzeżenia zawarte w dokumentach, jak również kategoryzować i organizować same dokumenty, segmentować tematycznie zawarte w nich treści etc. Wyzwania związane z przetwarzaniem języka naturalnego często dotyczą rozpoznawania mowy, rozumienia języka naturalnego i generowania języka naturalnego. Celem NLP i NLU jest stworzenie systemu zdolnego do kontekstowego „rozumienia” treści dokumentów, w tym niuansów języka w nich zawartych, a także swobodnego konwersowania z ludźmi. Jest to niewątpliwie jedna z najdynamiczniej rozwijających się dyscyplin sztucznej inteligencji o ogromnym potencjale zastosowania w biznesie, edukacji, administracji publicznej czy też medycynie. Jednocześnie jest to dziedzina, w której podejście *no code* oraz *low code* rozwija się bardzo szybko, dając szansę osobom różnych profesji (na przykład marketerom, szeroko pojętym twórcom treści analitykom rynku) na szybkie wdrożenie konwersacyjnej AI. Widać to zwłaszcza na przykładzie aplikacji do korzystania z tzw. „transformerów”, które szerzej opisane zostały poniżej. Ponadto w formie tabelarycznej zaprezentowane zostały poddziedziny rozwoju przetwarzania i rozumienia języka oraz odpowiadające im algorytmy, których zresztą z pewnością będzie w kolejnych latach przybywać: od regułowych oraz opartych na AI chatbotów, poprzez sieci rekurencyjne oraz *word embeddings*, aż po wymienione właśnie transformery językowe, stanowiące swoistą rewolucję w NLP i NLU.

Tabela 1. Dziedziny i algorytmy NLP wraz z ich zastosowaniami

Dziedzina	Zastosowanie
CHATBOTY	Boty (lub chatboty) konwersacyjne to szczególny rodzaj oprogramowania zaprojektowanego do wspomagania pracowników umysłowych w pracy biurowej, menedżerskiej czy administracyjnej (Przegalinska et al., 2019; Stojnić, 2015; Hong and Oh, 2020). Wykorzystując zaawansowane techniki przetwarzania języka naturalnego, wielowarstwowe sieci neuronowe i rozległe bazy wiedzy, potrafią one wydobyć sens z nieustrukturyzowanych danych, zbudować bazę wiedzy i wykonać wybrane, zwykle (choć w przyszłości będzie się to zmieniać) wąsko zdefiniowane zadania. Użytkownicy komunikują się z botami za pomocą czatu lub komend głosowych. Coraz częściej wykorzystywane są w biznesie do usprawniania różnych procesów, szczególnie tych związanych z obsługą klienta i personalizacją. Chatboty wykorzystują medium czatu w postaci komunikatorów społecznościowych, wiadomości SMS, czy okien chatu na stronie internetowej. Mogą być używane do obsługi klienta, dokonywania rezerwacji, płacenia rachunków, zakupów online lub interakcji z markami i organizacjami. Wykorzystywać je można na stronach internetowych, a także w aplikacjach mobilnych i komunikatorach.

cd. Tabeli 1. Dziedziny i algorytmy NLP wraz z ich zastosowaniami

Dziedzina	Zastosowanie
	<p>Chatboty mogą być zaprogramowane w różny sposób. Te oparte na regułach odpowiadają za każdym razem w ten sam sposób, według skryptu. Chatboty oparte na algorytmach uczenia maszynowego (w szczególności uczenia nienadzorowanego oraz uczenia głębokiego – <i>deep learning</i>) są w stanie różnie reagować na wiadomości zawierające określone słowa kluczowe, a nawet dostosować swoje odpowiedzi do konkretnego kontekstu. Boty oparte na takich algorytmach, pozwalających zarówno na przetwarzanie języka naturalnego, jak i jego rozumienie, mogą uczyć się złożonych sposobów symulowania ludzkiej konwersacji (zarządzanie dialogiem i dostosowywanie odpowiedzi do aktualnego przebiegu rozmowy). Chatbota napędzanego sztuczną inteligencją można również przeszkolić, aby aktywnie uczył się na podstawie dowolnej rozmowy z klientami i poprawiał wydajność podczas następnych konwersacji (Okuda and Shoda, 2018). Chatboty tego typu mogą nawet do pewnego stopnia rozpoznawać emocje klientów (frustracja czy zadowolenie) i przekierowywać zbyt złożone interakcje do ludzkich specjalistów i specjalistek w zakresie CS (Client Services).</p> <p>Pierwszym chatbotem typu konwersacyjnego był bot ELIZA (Shah et al., 2016). Zaprojektowany został w 1966 roku przez Josepha Weizenbauma. Ciekawostką jest to, że chat przeprowadził kilka „terapeutycznych” rozmów z pacjentami, działając jako symulacja rogeriańskiego psychologa. Najnowsze boty oparte na głębokim uczeniu, takie jak prototypowy na razie Duplex firmy Google, są tak zręczne w interakcji z ludźmi, że są ledwo rozpoznawalne jako maszyny, przynajmniej w krótkich rozmowach.</p>
SIECI RNN	<p>W analizie tekstu (w tym rozpoznawaniu pisma), przetwarzaniu języka w ogóle, a także syntezy mowy człowieka w ostatnich latach bardzo popularne było zastosowanie algorytmów uczenia maszynowego zwanych rekurencyjnymi sieciami neuronowymi. Sieci rekurencyjne (Recurrent Neural Networks – RNN) to klasa sieci, w których połączenia między węzłami tworzą graf skierowany wzdłuż sekwencji czasowej (Mikolov et al., 2010). Pozwala to na wykazywanie dynamicznego zachowania w czasie, a to jest bardzo ważne w przypadku pracy z językiem. Kluczową ideą rekurencyjnych sieci neuronowych jest właśnie wykorzystanie informacji sekwencyjnych. W przypadku tradycyjnej sieci neuronowej zakładamy, że wszystkie wejścia (i wyjścia) są niezależne od siebie, jednak w przypadku przetwarzania języka takie podejście nie zadziała. Na przykład chcąc przewidzieć następny wyraz w zdaniu, lepiej zorientować się, które wyrazy pojawiły się przed nim. Sieci RNN swoją nazwę zawdzięczają temu, że wykonują to samo zadanie dla każdego elementu sekwencji, a dane wyjściowe zawsze zależą od poprzednich obliczeń. Możemy też myśleć, że sieci RNN posiadają „pamięć”, która przechwytuje informacje o tym, co zostało obliczone do tej pory i bierze to pod uwagę w następnych obliczeniach (Graves et al., 2013). Sieci te wykorzystywane są między innymi do rozmaitych analiz szeregów czasowych, np. cen akcji, ale przede wszystkim stały się popularne w szeroko pojętym przetwarzaniu języka naturalnego, m.in. w automatycznych tłumaczeniach, rozwiązaniach typu text-to-speech i w analizie sentymentu. Na uwagę w kontekście RNN zasługują zwłaszcza sieci takie jak LSTM, których bardziej szczegółowy opis znajduje się poniżej w tej tabeli.</p>
GPT-3	<p>Do pracy z językiem naturalnym coraz częściej wykorzystujemy sieci typu koder-dekoder. Ważną przestrzenią ich rozwoju było na początku tłumaczenie maszynowe, ale aktualnie wykorzystywane są już do generowania tekstu, w tym prac o charakterze kreatywnym, jak leady marketingowe czy propozycje tytułów blogów, a także w konwersacji z ludźmi. Coraz częściej w tej ostatniej roli zastępują klasyczne chatboty.</p>

cd. Tabeli 1. Dziedziny i algorytmy NLP wraz z ich zastosowaniami

Dziedzina	Zastosowanie
	<p>Wyróżniamy co najmniej kilka generatorów tekstu opartych na architekturze enkoderowo-dekoderowej, zwanych transformerami. Należą do nich m.in. BERT (Devlin et al., 2018), T-5 (Karita et al., 2019), GPT-3 (Fröhling and Zubiaga, 2021; Elkins and Chun, 2020), DALL-E (Durall et al., 2021), a także rozwijany obecnie transformer Meena firmy Google. W przyszłości transformerów niewątpliwie będzie przybywać z uwagi na ich skalowalność i szeroki potencjał zastosowań.</p> <p>GPT-3, czyli Generative Pre-trained Transformer 3 (GPT-3) jest autoregresyjnym modelem językowym, który wykorzystuje głębokie uczenie do tworzenia tekstu ludzko podobnego do napisanego przez człowieka. Jest to model predykcyjny trzeciej generacji w serii GPT-n (i następcą równie słynnego GPT-2), stworzony przez jedną z najbardziej pionierskich w obszarze sztucznej inteligencji firm, czyli OpenAI. Pełna wersja GPT-3 ma pojemność 175 miliardów parametrów uczenia maszynowego. GPT-3, który został wprowadzony w maju 2020 r., a od lipca 2020 r. znajdował się w fazie testów beta, wpisuje się w trend systemów przetwarzania i rozumienia języka naturalnego (<i>Natural Language Processing – NLP</i> i <i>Natural Language Understanding – NLU</i>), polegający na wstępnie wytrenowanych reprezentacjach językowych. Przed wydaniem GPT-3, największym modelem językowym był Turing NLG Microsoftu, wprowadzony w lutym 2020 r., o pojemności 17 miliardów parametrów – mniej niż jedna dziesiąta pojemności GPT-3.</p> <p>Jakość tekstu generowanego przez GPT-3 jest tak wysoka, że może być trudno określić, czy został on napisany przez człowieka, co niesie ze sobą zarówno korzyści, jak i zagrożenia. Trzydziestu jeden badaczy i inżynierów OpenAI przedstawiło oryginalny dokument z 28 maja 2020 r., wprowadzający GPT-3. W swoim dokumencie, poza wskazywaniem licznych zalet systemu, zdolnego do wysoko kontekstowej analizy tekstu, konwersacji czy komponowania utworów muzycznych, ostrzegali przed potencjalnymi zagrożeniami ze strony GPT-3. David Chalmers, australijski filozof, opisał GPT-3 jako jeden z najciekawszych i najważniejszych systemów AI, jakie kiedykolwiek wyprodukowano. GPT-3 został wytrenowany na setkach miliardów słów i jest zdolny do kodowania m.in. w CSS, JSX, Pythonie. Poza GPT-3 istnieje także GPT-J, czyli <i>open source’owa</i> wersja transformera, opublikowana w roku 2021. Aktualnie jest cały czas rozbudowywana.</p>
SIECI LSTM	<p>LSTM (ang. Long Short-Term Memory) to sieci z tzw. długą pamięcią krótkotrwałą, które zostały wynalezione przez Hochreitera i Schmidhubera w 1997 roku (Hochreiter and Schmidhuber, 1997) i ustanowiły rekordy dokładności w wielu obszarach zastosowań, głównie w predykcji mowy i analizie sentymentu. Około 2007 roku LSTM zaczęły rewolucjonizować rozpoznawanie mowy, przewyższając tradycyjne modele w niektórych zastosowaniach mowy.</p> <p>W 2009 roku sieć Connectionist Temporal Classification (CTC) – trained LSTM była pierwszą siecią RNN, która wygrała konkursy rozpoznawania wzorców mowy. LSTM poprawił również rozpoznawanie mowy, w której użyto rozległego, bogatego słownictwa i został z powodzeniem wykorzystany m.in. w systemie Google Android.</p> <p>Sieci LSTM pobiły zresztą rekordy w ulepszonym tłumaczeniu maszynowym. Co więcej, wspólnie z sieciami konwolucyjnymi (CNN) sieci LSTM poprawiły automatyczne podpisywanie obrazów. Szczególnym przykładem sieci LSTM jest komórka GRU (ang. Gated Recurrent Unit – GRU) (Kyunghyun Cho i inni, 2014). To uproszczona wersja LSTM, bardzo często stosowana w analizie tekstu.</p>

cd. Tabeli 1. Dziedziny i algorytmy NLP wraz z ich zastosowaniami

Dziedzina	Zastosowanie
<p>INNE TRANSFORMERY</p>	<p>T5 to typ transformatora tekst–tekst, który można szkolić do wykonywania różnych zadań o jednolitej architekturze, zaś Dall-E to program sztucznej inteligencji, który tworzy obrazy z opisów tekstowych, pokazany przez OpenAI 5 stycznia 2021 r. Wykorzystuje 12-miliardową wersję modelu transformatora GPT-3 do interpretowania danych wejściowych w języku naturalnym i generowania odpowiednich obrazów.</p> <p>BERT (z ang. Bidirectional Encoder Representations from Transformer) jest natomiast pierwszym z transformerów i w tym sensie przełomowym technicznie modelem służącym do przetwarzania języka naturalnego (Devlin et al., 2018), który został zbudowany przez zespół Google AI. Google nierzadko podkreśla znaczenie BERT-a dla kontekstowego rozumienia języka podczas analizy zawartości strony czy też zapytań. BERT to wstępnie przeszkolona platforma, która jeszcze na etapie fazy beta dawała bardzo ciekawe wyniki w przetwarzaniu 11 przydzielonych zadań językowych. Zadania te obejmowały między innymi oznaczanie ról semantycznych, klasyfikację tekstu, przewidywanie kolejnego zdania etc. Pierwotnie wyszkolony był przede wszystkim na anglojęzycznej Wikipedii. Odpowiednikami sieci BERT w języku polskim, bazującymi zresztą na tym transformerze, są stworzony przez Ośrodek Przetwarzania Informacji model RoBERTa Large oraz HerBERT.</p> <p>Wszystkie transformery już teraz okazują się bardzo przydatne jako wsparcie w zadaniach dotyczących marketingu (generowanie haseł kluczowych oraz tytułów blogów, a także leadów kampanii marketingowych w mediach społecznościowych) i szeroko pojętego tworzenia treści (wiersze, opowiadania, eseje, proste formy publicystyczne oraz posty w mediach społecznościowych), analiz sentymentu w kontekście odbioru usług i produktów przez użytkowników, konwersacji 24/7 z klientami, obsługi klienta, rekomendacji produktów, dopasowywania wizualizacji do haseł, a nawet tworzenia kompozycji muzycznych. W przyszłości zakres ich zastosowań niewątpliwie się rozszerzy, a dzięki uproszczonym, przyjaznym interfejsom (taki posiada już m.in. GPT-3 oraz AI 21 Labs), niewymagającym kodowania, wielu specjalistów i specjalistek z różnych sektorów gospodarki będzie mogło z powodzeniem je wykorzystywać (Floridi and Chiriatti, 2020; Branwen, 2020; Zhang et al., 2021). Jednym z najnowszych osiągnięć w rozumieniu języka i mowy jest także chiński system Wu Dao. W czerwcu 2021 r. Beijing Academy of Artificial Intelligence (BAAI) uruchomiła Wu Dao 2.0, następcę Wu Dao 1.0. Wu Dao jest modelem językowym, który ma na celu przewyższyć GPT-3 OpenAI czy też LaMDA Google (inny potężny transformer) w operowaniu językiem na poziomie człowieka. Wu Dao wytrenowany jest na 4,9 terabajtach obrazów i tekstów.</p>
<p>WORD EMBEDDINGS (Osadzanie słów)</p>	<p>Jest to efektywna i powszechnie stosowana technika NLP, używana do analizy tekstu. <i>Word embeddings</i> to reprezentacje słów, zazwyczaj w postaci wektora o wartości rzeczywistej, który koduje znaczenie danego słowa tak, że te słowa, które są bliżej w przestrzeni wektorowej, są mapowane jako te o podobnym znaczeniu (Levy and Goldberg, 2014; Liu et al., 2015; Schnabel et al., 2015). Osadzanie słów można uzyskać za pomocą zestawu technik modelowania języka i ekstrakcji cech z pola semantycznego danego słowa.</p>

Źródło: opracowanie własne.

Modele korzystania ze sztucznej inteligencji i wymagane umiejętności

Ostatnie znaczące osiągnięcia w dziedzinie AI, głębokiego uczenia, rozumienia języka naturalnego i widzenia maszynowego doprowadziły do powstania nowych systemów zorientowanych na współpracę z człowiekiem (Haenlein and Kaplan, 2019). Systemy takie jak AlphaStar, AlphaGo (Vinyals et al. 2019; Wang et al. 2016), OpenAI Five (OpenAI, 2018) czy IBM Watson (High, 2012) udowodniły, że w wielu przypadkach interakcja człowiek-maszyna nie powinna być traktowana jako konkurencja i/lub zastępowanie, ale raczej jako obszar potencjalnej współpracy, gdzie talent człowieka może zostać wzmocniony inteligencją obliczeniową maszyny.

Za takim podejściem do implementowania sztucznej inteligencji w organizacjach i instytucjach, zwłaszcza tych opartych na wiedzy, opowiada się cytowany już powyżej profesor Tom Malone (2018), który w swoich publikacjach przekonuje o sile ludzi i maszyn pracujących i myślących razem. Malone twierdzi, że postępy w sztucznej inteligencji i łączności spowodują pojawienie się nowatorskich pomysłów, a poprzez wywołanie efektu zbiorowej inteligencji można będzie odkryć sposoby rozwiązania najbardziej palących bieżących problemów.

Malone wyróżnia kilka modeli współpracy sztucznej inteligencji z człowiekiem. Możemy tutaj mówić o pracy paralelnej, niezależnej, a także o pracy na kilku „odcinkach” jednego zadania czy projektu. Możemy też mówić o sytuacji współzależności, np. kiedy decyzja podjęta przez system AI (na przykład w diagnostyce medycznej) jest wsparciem dla lekarza, który następnie ją weryfikuje. Najbardziej pożądanym i, zdaniem Malone’a, możliwym do osiągnięcia systemem byłaby pełna współpraca ze sztuczną inteligencją, dająca efekty synergii. W takim wariancie człowiek wykorzystuje te wymiary inteligencji, w których jest najlepszy, a jego horyzont poznawczy i decyzyjny wspiera zaawansowana, choć wyspecjalizowana, sztuczna inteligencja. Przykłady takiej współpracy widać było w przypadku opartych na zaawansowanym głębokim uczeniu systemów takich jak AlphaGo czy AlphaStar (to także projekty firmy OpenAI), które – mimo że konkurowały z człowiekiem w grach strategicznych – były w stanie wskazać nowe sposoby gry do wykorzystania także przez ludzi.

Patrząc na rozwój przetwarzania i rozumienia języka, a także konwersacyjnej sztucznej inteligencji, można wymienić przynajmniej kilka poziomów korzystania z niej oraz adekwatnych do nich umiejętności technicznych. Pierwszym z nich będą bazowe umiejętności korzystania z narzędzi oraz interfejsów niewymagających kodowania, odpowiadające „produktowemu” podejściu do sztucznej inteligencji. Każda osoba sprawnie posługująca się mediami społecznościowymi czy aplikacjami będzie w stanie korzystać ze sztucznej inteligencji w tym zakresie. Widać to już teraz na przykładzie marketerów wykorzystujących rozwiązania transformatorowe, takie jak wymieniana wcześniej AI21 Labs, czy użytkowników i użytkowników Facebooka korzystających z szalenie prostej platformy Chatfuel⁶ do budowania chatbotów. Na drugim poziomie znane już będą podstawy kodowania (na przykład w języku Python czy Javascript) oraz algorytmy uczenia

⁶ Patrz: https://chatfuel.com/?utm_source=google&utm_medium=cpc&utm_term=chatfuel&utm_content=526548124012|c&utm_campaign=Brand_Search|13442465223&gclid=Cj0KCQiA2sqOBhCGARIsAPuPK0g6Gk0padAwbn7IxedFelQVqssYYG6F2vPB7IXCDwEPjSs5vNeY2I8aApgVEALw_wcB

maszynowego, w tym algorytmy NLP, które pozwalają na stosowanie ML oraz NLP w różnych przestrzeniach problemowych. Można będzie tutaj korzystać z gotowych platform w stopniu rozszerzonym oraz do pewnego stopnia samodzielnie budować i optymalizować narzędzia z zakresu AI, dobierać najbardziej adekwatne do danego problemu algorytmy. Przedostatnim etapem będą zaawansowane umiejętności w zakresie programowania NLU, które pozwalają korzystać ze wszystkich bibliotek oraz narzędzi, w tym deep-learningowych (DL) do realizacji projektów z wykorzystaniem AI. Ostatnim etapem będzie tworzenie od podstaw narzędzi AI i konwersacyjnej AI oraz posiadanie rozległej wiedzy i doświadczenia w zakresie algorytmów uczenia głębokiego *deep learning* oraz uczenia przez wzmocnienie (*reinforcement learning*).

Reasumując: możemy wyróżnić 4 poziomy kompetencyjne w kontekście stosowania i rozwoju sztucznej inteligencji – od poziomu *no code*, poprzez *low code*, czyli poziomu podstawowych umiejętności z zakresu programowania i *data science*, aż do poziomu zaawansowanego oraz eksperckiego.

Tabela 2. Poziomy kompetencyjne a rozwój sztucznej inteligencji

Poziom	Rodzaj umiejętności
1	Korzystanie na podstawowym poziomie z uproszczonych interfejsów niewymagających programowania.
2	Opanowanie podstaw programowania i algorytmiki, które pozwala na korzystanie z dostępnych narzędzi do tworzenia modeli ML w różnych domenach problemowych.
3	Zaawansowane umiejętności w zakresie programowania ML, NLP, NLU oraz DL wykorzystywane do realizacji skalowalnych projektów z użyciem AI.
4	Tworzenie algorytmów AI i ich kompletna implementacja.

Źródło: opracowanie własne.

Podsumowanie

Collaborative AI to rodząca się dziedzina, w której po określeniu potrzeb i kompetencji człowieka tworzy się przydatne w pracy rozwiązania na bazie sztucznej inteligencji. Przy projektowaniu współpracy zakłada się, że człowiek i system sztucznej inteligencji powinni pracować do pewnego stopnia razem jako partnerzy. Aktualnie to rodzące się dopiero pole badawcze, wymagające opracowania technik, metod i komponentów, które umożliwiają ludziom i systemom sztucznej inteligencji efektywną współpracę.

W szczególności system AI musi być w stanie ocenić bieżącą sytuację, obserwować użytkowników, przewidywać ich działania, potrzeby i odpowiednio do tego działać. Umiejętności te wymagają na ogół ściśle sprzężonej integracji percepcji z działaniem, w której człowiek i system AI dostrzegają i rozumieją swojego partnera oraz podejmują odpowiednie działania, aby osiągnąć cel. Dalszy rozwój sztucznej inteligencji w kontekście współpracy z ludźmi, tak w biznesie, jak i w instytucjach

czy administracji publicznej, będzie wymagał bardzo wielu projektów, w których dokładnie określimy, jakiego typu wsparcia oczekują pracownicy przy konkretnych, dobrze nazwanych zadaniach oraz na co pozwala poziom ich umiejętności cyfrowych. Będzie wymagał także budowania klarownych, a jednocześnie możliwie zindywidualizowanych ścieżek zwiększania kompetencji w zakresie korzystania z AI. Od 2020 roku, który okazał się rokiem pandemicznym, przechodzimy poniekąd wymuszoną i przyspieszoną transformację cyfrową. Powszechne korzystanie ze sztucznej inteligencji, zwłaszcza – choć nie wyłącznie – w pracy opartej na wiedzy, jest jej kolejnym etapem.

W tym kontekście należy podkreślić, że zwłaszcza poziomy *no code* oraz *low code* są kluczowe dla upowszechnienia się sztucznej inteligencji w różnych dziedzinach i sektorach. To właśnie *citizen developers*, czyli „nietechniczni programiści” lub „obywatele programiści” wychodzą obecnie na pierwszy plan cyfrowej transformacji. Używają oni uproszczonych platform do tworzenia prostych rozwiązań dla swoich zespołów i działów. Takie proste rozwiązania znajdują zastosowanie m.in. w działach HR, finansów, sprzedaży i marketingu, działach prawnych, w zaopatrzeniu i w wielu innych funkcjach biznesowych. Nie zastępują rzecz jasna systemowych rozwiązań oferowanych przez zespoły IT, ale odgrywają kluczową rolę w prototypowaniu wyspecjalizowanych ścieżek współpracy z AI.

Jak wynika ze studium McKinsey and Company z 2020 roku⁷, około 40% zadań można zautomatyzować tylko wtedy, gdy pozwala się na popyt napędzany przez pracowników. Aby w pełni wykorzystać potencjał automatyzacji, „obywatele programiści” będą wzmacniać i popularyzować automatyzację. W wielu przypadkach okazuje się, że automatyzacje stworzone przez *citizen developers* dla konkretnego zespołu mają zastosowanie w całej organizacji. Aby to osiągnąć, organizacje będą musiały zainwestować w edukację i szkolenia. Niektóre firmy organizują nawet „botatony” (czyli *hackathony* służące stworzeniu botów), aby zachęcić pracowników do tworzenia własnych systemów. Istnieje szereg korzyści płynących z rozwoju społeczności „obywateli programistów”. Jeśli będzie ona efektywnie wykorzystywana i rozwijana w połączeniu z kulturą uczenia się i współpracy, nietechniczni programiści będą w przyszłości przewodzić w rozwoju AI i automatyzacji.

Bibliografia

Acemoglu, D. and Restrepo, P. (2017). *Robots and Jobs: Evidence from US Labor Markets*. <https://doi.org/10.3386/w23285>

Barbara, S. and Celebrate, M. (1989). *Collaboration*. <https://www.wpcweb.org/wp-content/uploads/2019/11/Fall-2019.pdf>

Branwen, G. (2020). *GPT-3 Creative Fiction*. <https://www.gwern.net/GPT-3>

⁷ Patrz: <https://www.mckinsey.com/featured-insights/future-of-work>

- Conoley, J. C. and Conoley, C. W. (2010). Why Does Collaboration Work? Linking Positive Psychology and Collaboration. *Journal of Educational and Psychological Consultation: The Official Journal of the Association for Educational and Psychological Consultants*, 20(1), 75–82.
- Devlin, J., Chang, M.-W., Lee, K. and Toutanova, K. (2018). BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. In *arXiv [cs.CL]*. arXiv. <http://arxiv.org/abs/1810.04805>
- Durall, R., Frolov, S., Hees, J., Raue, F., Pfreundt, F.-J., Dengel, A. and Keupe, J. (2021). Combining transformer generators with convolutional discriminators. In *arXiv [cs.CV]*. arXiv. <http://arxiv.org/abs/2105.10189>
- Elkins, K. and Chun, J. (2020). Can GPT-3 pass a writer's Turing test? *Journal of Cultural Analytics*. <https://doi.org/10.22148/001c.17212>
- Floridi, L. and Chiriatti, M. (2020). GPT-3: Its Nature, Scope, Limits, and Consequences. *Minds and Machines*, 30(4), 681–694.
- Fröhling, L. and Zubiaga, A. (2021). Feature-based detection of automated language models: tackling GPT-2, GPT-3 and Grover. *PeerJ. Computer Science*, 7, e443.
- Furman, J. and Seamans, R. (2019). AI and the economy. *Innovation Policy and the Economy*, 19, 161–191.
- Goolsbee, A. (2018). *Public Policy in an AI Economy* (No. w24653). National Bureau of Economic Research. <https://doi.org/10.3386/w24653>
- Graves, A., Mohamed, A.-R. and Hinton, G. (2013). Speech recognition with deep recurrent neural networks. *2013 IEEE International Conference on Acoustics, Speech and Signal Processing*, 6645–6649.
- Hecht-Nielsen, R. (1992). Theory of the backpropagation neural network. *Neural networks for perception* (pp. 65–93). Elsevier.
- Hochreiter, S. and Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780.
- Hong, H. and Oh, H. J. (2020). Utilizing bots for sustainable news business: Understanding users' perspectives of news bots in the age of social media. *Sustainability: Science Practice and Policy*, 12(16), 6515.
- Jemielniak, D. i Przegalińska, A. (2020). *Społeczeństwo współpracy*. Warszawa: Wydawnictwo Naukowe Scholar.
- Karita, S., Chen, N., Hayashi, T., Hori, T., Inaguma, H., Jiang, Z., Someki, M., Soplin, N. E. Y., Yamamoto, R., Wang, X., Watanabe, S., Yoshimura, T. and Zhang, W. (2019). A Comparative Study on Transformer vs RNN in Speech Applications. *2019 IEEE Automatic Speech Recognition and Understanding Workshop (ASRU)*, 449–456.

- Koch, J. (2017). Design implications for Designing with a Collaborative AI. *2017 AAAI Spring Symposium Series*. <https://www.aaai.org/ocs/index.php/SSS/SSS17/paper/download/15382/14577>
- Koch, J. and Oulasvirta, A. (2018). Group Cognition and Collaborative AI. In J. Zhou and F. Chen (Eds.), *Human and Machine Learning: Visible, Explainable, Trustworthy and Transparent* (pp. 293–312). Springer International Publishing.
- Levy, O. and Goldberg, Y. (2014). Dependency-based word embeddings. *Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics (Volume 2: Short Papers)*, 302–308.
- Liu, Y., Liu, Z., Chua, T.-S. and Sun, M. (2015, February 19). Topical Word Embeddings. *Twenty-Ninth AAAI Conference on Artificial Intelligence*. <https://www.aaai.org/ocs/index.php/AAAI/AAAI15/paper/viewPaper/9314>
- Malone, T. W. (2018). *Superminds: The surprising power of people and computers thinking together*. Little, Brown.
- Manning, C. and Schütze, H. (1999). *Foundations of Statistical Natural Language Processing*. MIT Press.
- Manning, C. D., Surdeanu, M., Bauer, J., Finkel, J. R., Bethard, S. and McClosky, D. (2014). The Stanford CoreNLP natural language processing toolkit. *Proceedings of 52nd Annual Meeting of the Association for Computational Linguistics: System Demonstrations*, 55–60.
- Manyika, J., Lund, S., Chui, M., Bughin, J., Woetzel, J., Batra, P., Ko, R. and Sanghvi, S. (2017). Jobs lost, jobs gained: Workforce transitions in a time of automation. *McKinsey Global Institute*, 150. <https://www.voced.edu.au/content/ngv:78297>
- McAfee, A. and Brynjolfsson, E. (2016). Human Work in the Robotic Future: Policy for the Age of Automation. *Foreign Affairs*, 95(4), 139–150.
- McAfee, A. and Brynjolfsson, E. (2017). *Machine, Platform, Crowd: Harnessing Our Digital Future*. W. W. Norton and Company.
- Mikolov, T., Karafiát, M., Burget, L., Cernocký, J. and Khudanpur, S. (2010). Recurrent neural network based language model. *Interspeech*, 2, 1045–1048.
- Okuda, T. and Shoda, S. (2018). AI-based Chatbot Service for Financial Industry. *Fujitsu Scientific and Technical Journal*, 54(2), 4–8.
- Przegalinska, A., Ciechanowski, L., Stroz, A., Gloor, P. and Mazurek, G. (2019). In bot we trust: A new methodology of chatbot performance measures. *Business Horizons*, 62(6), 785–797.
- Schnabel, T., Labutov, I., Mimno, D. and Joachims, T. (2015). Evaluation methods for unsupervised word embeddings. *Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing*, 298–307.

Schrittwieser, J., Antonoglou, I., Hubert, T., Simonyan, K., Sifre, L., Schmitt, S., Guez, A., Lockhart, E., Hassabis, D., Graepel, T., Lillicrap, T. and Silver, D. (2020). Mastering Atari, Go, chess and shogi by planning with a learned model. *Nature*, 588(7839), 604–609.

Seamans, R. and Raj, M. (2018). *AI, Labor, Productivity and the Need for Firm-Level Data* (No. w24239). National Bureau of Economic Research. <https://doi.org/10.3386/w24239>

Shah, H., Warwick, K., Vallverdú, J. and Wu, D. (2016). Can machines talk? Comparison of Eliza with modern dialogue systems. *Computers in Human Behavior*, 58, 278–295.

Shaikh, K. (2020). AI with Low Code. In *Demystifying Azure AI* (pp. 151–182). https://doi.org/10.1007/978-1-4842-6219-1_5

Stojnić, A. (2015). Digital anthropomorphism: Performers avatars and chat-bots. *Performance Research*, 20(2), 70–77.

Tegmark, M. (2017). *Life 3.0: Being Human in the Age of Artificial Intelligence*. Knopf Doubleday Publishing Group.

Zhang, D., Mishra, S., Brynjolfsson, E., Etchemendy, J., Ganguli, D., Grosz, B., Lyons, T., Manyika, J., Niebles, J. C., Sellitto, M., Shoham, Y., Clark, J. and Perrault, R. (2021). The AI Index 2021 Annual Report. In *arXiv [cs.AI]*. arXiv. <http://arxiv.org/abs/2103.06312>

Rozwój sztucznej inteligencji jako wyzwanie dla systemu edukacji

prof. dr hab. Jan Fazlagić*

Wprowadzenie

Z założenia sztuczna inteligencja (AI) ma pomagać ludziom w zrozumieniu świata, rozumowaniu, planowaniu, komunikacji i percepcji. Ma więc być udoskonaleniem inteligencji ludzkiej i zastępować człowieka tam, gdzie jego zdolności poznawcze są niewystarczające dla osiągnięcia oczekiwanych celów. Jednak w przypadku dyskusji na temat sztucznej inteligencji i jej zastosowań w systemie edukacji powinniśmy brać pod uwagę fakt, że system edukacji w dużym stopniu polega na *kształtowaniu inteligencji ludzkiej*. Powstaje więc swego rodzaju dylemat: czy sztuczna inteligencja może i powinna ingerować w proces kształtowania inteligencji ludzkiej? Jakie mogą być długofalowe skutki takiego procesu odłożone w czasie? Jak może wyglądać społeczeństwo za 50 lat, w którym inteligencja ludzka (cokolwiek będzie to oznaczało za 50 lat) będzie swego rodzaju produktem wytworzonym przez sztuczną inteligencję wykorzystaną w systemie edukacji do nauczania? Czy uczeń „odciążony” przez sztuczną inteligencję będzie w istocie *beneficjentem* takiego rozwiązania? Czy też może przeciwnie: zaaplikowanie do systemu edukacji filozofii wykorzystania sztucznej inteligencji w biznesie polegającej na odciążaniu człowieka może przynieść skutki odwrotne od spodziewanych? Jeśli sztuczna inteligencja ma ułatwiać interakcje przedsiębiorstwa z klientem, to czy takie same podejście zastosowane do interakcji: system edukacji – uczeń również jest pożądane? Filozofia, jaka przyświeca dostawcom rozwiązań AI powstających na potrzeby przedsiębiorstw, może okazać się nieprzydatna lub nawet szkodliwa, jeśli zostanie bezrefleksyjnie wykorzystana na potrzeby systemu edukacji. To, co jest „optymalizacją” i „zwiększeniem efektywności” w biznesie, niekoniecznie musi oznaczać to samo w przypadku procesu nauczania, np. nauczanie poezji lub zarażanie miłością do sztuki nie będzie efektywniejsze, jeśli osoba ucząca się zapozna się z dwa razy większą liczbą utworów artystycznych w jednostce czasu.

Celem rozdziału jest dokonanie przeglądu możliwości wykorzystania sztucznej inteligencji w sektorze edukacji, a także związanych z nimi szans i zagrożeń. Sektor edukacji niewątpliwie może okazać się beneficjentem sztucznej inteligencji, lecz należy na bardzo wczesnym etapie wprowadzania innowacyjnych rozwiązań brać pod uwagę jego specyfikę, w szczególności *misję* tego systemu. Większość rozwiązań z zakresu sztucznej inteligencji powstaje na potrzeby uzyskania korzyści komercyjnych przez podmioty, które ją wykorzystują. Sztuczna inteligencja powinna pomagać w optymalizacji oferty cenowej, tras przejazdów w sieci logistycznej, zarządzania energią itd. Przedmiotem rozważań zawartych w niniejszym rozdziale są także zagrożenia i pułapki związane z aplikowaniem rozwiązań AI w systemie edukacji.

* Uniwersytet Ekonomiczny w Poznaniu, ORCID: 0000-0003-1968-2163

Znaczenie wykorzystania sztucznej inteligencji w sektorze edukacji

Sztuczna inteligencja ma być jedną z najważniejszych technologii przyszłości (Parlament Europejski, 2020). Komitet Rady Ministrów ds. Cyfryzacji (KRMC) przyjął w 2020 roku „Politykę rozwoju sztucznej inteligencji w Polsce”. Dokument określa działania i cele dla Polski w perspektywie krótkoterminowej (do 2023 r.), średnio-terminowej (do 2027 r.) i długoterminowej (po 2027 r.) (Serwis Rzeczypospolitej Polskiej, 2021). Wśród sześciu obszarów dokument wymienia edukację: „AI i edukacja – działania podejmowane od kształcenia podstawowego, aż do poziomu uczelni wyższych – programy kursów dla osób zagrożonych utratą pracy na skutek rozwoju nowych technologii, granty edukacyjne”. W opisie obszaru wymieniana jest przede wszystkim edukacja jako forma rozwoju kapitału ludzkiego na potrzeby gospodarki. Natomiast nie zawarto tam wskazówek ani odniesień dotyczących możliwości wykorzystania sztucznej inteligencji w systemie edukacji, na potrzeby jego unowocześnienia, usprawnienia itp. Można jednak przyjąć, że postulat czy też wyzwanie związane z wprowadzeniem sztucznej inteligencji do systemu edukacji może zostać częściowo spełnione w pozostałych obszarach dokumentu „Polityka rozwoju sztucznej inteligencji w Polsce”, to znaczy:

1. AI i społeczeństwo – działania, które mają uczynić z Polski jednego z większych beneficjentów gospodarki opartej na danych, a z Polaków – społeczeństwo świadome konieczności ciągłego podnoszenia kompetencji cyfrowych;
2. AI i innowacyjne firmy – wsparcie polskich przedsiębiorstw AI, m.in. tworzenie mechanizmów finansowania ich rozwoju, współpracy start up-ów z rządem;
3. AI i nauka – wsparcie polskiego środowiska naukowego i badawczego w projektowaniu interdyscyplinarnych wyzwań lub rozwiązań w obszarze AI, m.in. działania mające na celu przygotowanie kadry ekspertów AI.

Pobieżna analiza częstości występowania wyrażenia „artificial intelligence” z kolo-katorami opisującymi różne możliwości branżowego zastosowania sztucznej inteligencji wykazuje, że na tle wybranych branż popularność tego wyrażenia w internecie jest zróżnicowana, a „artificial intelligence in education” zdecydowanie częściej występuje w kontekście „edukacji”, niż np. „ecommerce” (Tab. 3.).

Tabela 3. Liczba wskazań w wyszukiwarce Google dla wybranych haseł związanych ze sztuczną inteligencją

Hasło	Liczba wskazań (7 lutego 2021 r.)
„Artificial intelligence”	152,000,000
„Artificial intelligence in education”	1,480,000
„Artificial intelligence in medicine”	1,100,000
„Artificial intelligence in pharmaceutical industry”	620,000
„Artificial intelligence in ecommerce”	604,000
„Artificial intelligence in logistics”	313,000
„Artificial intelligence in city management”	3 (sic!)

Źródło: opracowanie własne.

W raporcie Ministerstwa Cyfryzacji przedstawiono propozycję map badawczych w zakresie sztucznej inteligencji. Mapa została podzielona na kilka kategorii (Ministerstwo Cyfryzacji, s. 71–77):

- język i mowa
- maszynowe widzenie
- zastosowania medyczne
- robotyka i sterowanie
- prywatność i bezpieczeństwo danych
- technologie materiałowe.

Wśród obszarów tych nie wymieniono *explicite* edukacji w kontekście zaawansowanych badań naukowych nad zastosowaniem sztucznej inteligencji do nauczania, czyli do częściowego lub pełnego wypełniania roli nauczyciela. Sztuczna inteligencja w kontekście edukacji pojawia się w dokumencie przede wszystkim jako wyzwanie związane z kształceniem specjalistów i rozwojem kapitału ludzkiego w naszym kraju na potrzeby rozwoju przedsiębiorstw budujących rozwiązania z zakresu sztucznej inteligencji. Użytkownicy technologii opartych na sztucznej inteligencji także potrzebują odpowiednich kompetencji, żeby móc świadomie korzystać z nowych technologii. Technologia, w szczególności AI, sprawia, że należy na nowo zdefiniować podział kompetencji.

Wyzwania związane z wykorzystaniem teorii edukacyjnych przy tworzeniu algorytmów sztucznej inteligencji

Wykorzystanie sztucznej inteligencji w edukacji jest obarczone prawdopodobnie większą grupą ryzyk niż w innych obszarach. Jeśli sztuczna inteligencja w sposób niewłaściwy doradzi kupującemu zakup mebla w sklepie internetowym,

konsekwencje takiego działania będą nieporównywalnie mniejsze niż zastosowanie niewłaściwie zaprojektowanego algorytmu nauczającego w szkole. Ryzyka związane z tworzeniem niewłaściwych algorytmów można podzielić ze względu na następujące kategorie:

4. Ryzyka związane z wykorzystaniem błędnej/niewłaściwej teorii;
5. Ryzyka związane z negatywnymi skutkami ubocznymi bądź też niezamierzonymi skutkami procesu nauczania sterowanego przez sztuczną inteligencję;
6. Ryzyka związane z niewłaściwym wnioskowaniem przez algorytm i aplikowaniem niewłaściwych zadań dla ucznia.

Poniżej zostaną opisane dwa przykładowe ryzyka z pierwszej i drugiej kategorii.

Przykład ryzyka związanego z negatywnymi skutkami ubocznymi bądź też niezamierzonymi skutkami procesu nauczania sterowanego przez sztuczną inteligencję:

Słynny XX-wieczny filozof i myśliciel Erich Fromm w książce *O sztuce istnienia* (Fromm, 1997) opisał tzw. „doktrynę bez trudu i bólu”. Według niego ludzie nabrali przekonania, że wszystko, nawet najtrudniejszą umiejętność, powinno się opanować bez trudu lub z minimalnym jego nakładem. Jego zdaniem:

Doktryna ta jest tak popularna, że prawie nie wymaga dłuższych wyjaśnień. Weźmy całą naszą metodę edukacji. Namawiamy naszych młodych ludzi, czasami wręcz błagamy, aby się kształcili. Pod hasłami „auto-ekspresji”, „anty-dokonań” i „wolności”, staramy się maksymalnie ułatwić i uprzyjemnić każdy wykład. Jedynym wyjątkiem są tutaj nauki przyrodnicze, w których naprawdę dąży się do osiągnięć i gdzie nie można opanować przedmiotu na drodze „łatwych lekcji”. Ale w naukach społecznych, humanistyce, literaturze, średnich i wyższych szkołach, tendencja ta jest nader obecna – łatwo i bezstresowo. Z doktryną najmniejszego wysiłku spokrewniona jest doktryna unikania bólu. Ma ona również charakter fobiczny i objawia się unikaniem w każdych okolicznościach cierpienia i bólu fizycznego, a szczególnie psychicznego. Era nowoczesnego postępu wyznacza sobie za cel doprowadzenie człowieka do ziemi obiecanej egzystencji bez bólu. Rzeczywiście ludzie wykształcają w sobie coś w rodzaju fobii przed bólem. Pojęcie bólu ujmowane jest tutaj w najszerszym sensie, również w sensie bolesnego trudu. Bolesne jest ćwiczenie godzinami gam muzycznych, uczenie się przedmiotu, który nie jest ciekawy, ale potrzebny do zdobycia wiedzy. Bolesne jest siedzenie nad książką i wkuwanie, kiedy chciałoby się spotkać z dziewczyną lub po prostu pójść na spacer czy zabawić się z przyjaciółmi.

W opracowaniach dotyczących sztucznej inteligencji niezmiennie dominuje wątek „ułatwiania” i „optymalizowania” (co wpisuje się w opisaną wyżej przez E. Fromma doktrynę „bez trudu i bólu”). Sztuczna inteligencja jest nierozzerwalnie kojarzona z obniżeniem poziomu wysiłku. Wiąże się z tym jednak pewna pułapka myślenia, ponieważ na poziomie neuronalnym uczenie się jest związane z wydatkowaniem energii (czyli wysiłkiem). Można więc powiedzieć, że istnieje fundamentalna rozbieżność pomiędzy celem zastosowania sztucznej inteligencji, jakim jest redukcja wysiłku człowieka, a biologicznym wymogiem zaangażowania wysiłku w procesie

uczenia się. Dylemat ten można rozwiązać tylko częściowo, poprzez tworzenie środowiska angażującego ucznia (gamifikacja). Jednak życie nie składa się jedynie z sytuacji przyjemnych. Człowiek jest zmuszony także zmagać się z problemami, które nie dają mu satysfakcji (tak jak to ma miejsce w przypadku grywalizacji). Wyzwaniem jest więc, jak sztuczna inteligencja miałaby symulować takie sytuacje, przygotowywać ucznia do nich. Zmaganie się z własnymi słabościami i ich doświadczanie jest immanentną cechą procesu uczenia się. AI z pewnością mogłaby również w swoich algorytmach uwzględniać takie zmienne. Lecz jak nauczyć, że świat jest nie zawsze sprawiedliwy? Perfekcyjnie obiektywna i neutralna światopoglądowo AI? Czy może raczej AI symulująca niedoskonałości „żywego nauczyciela”, które są przecież także elementem przygotowania do życia dorosłego? Warto więc jednak zastanowić się, czy rzeczywiście sztuczna inteligencja poprzez różnego rodzaju ułatwienia oferowane osobom uczącym się w istocie nie zaburza kontekstu edukacji, która z historycznego punktu widzenia polegała na pokonywaniu barier i wyzwań. Na przykład program edukacyjny wykorzystujący AI Kidsense (Irvine, California) pozwala na transkrypcję wypowiedzi dziecka na tekst w celu sporządzania notatek. Wyzwaniem jest tutaj trudność w zrozumieniu mowy małych dzieci. Oprogramowanie potrafi więc zrozumieć niewyraźną mowę malucha. Ale nasuwa się pytanie, jak takie rozwiązanie wpłynie na rozwój dziecka? Nie dysponujemy wynikami badania na ten temat, ale możemy hipotetyzować. W czasach, gdy takiego oprogramowania nie było, dziecko rozwijało swoją zdolność do komunikacji, otrzymując informacje zwrotne z otoczenia. Odczuwając, które słowa i wypowiedzi są zrozumiałe dla otoczenia, a które nie, w spontaniczny sposób starało się być bardziej zrozumiałe dla opiekunów, doskonalić swoją wymowę, dostosowywać ją do oczekiwań odbiorców. Dziecko uczące się mówić w procesie nauki odczuwało także „ból” związany z byciem niezrozumianym. Czy w związku z tym programowanie Kickers nie wyrządzi szkody w procesie edukacji dziecka? W ekstremalnym przypadku możemy sobie wyobrazić dzieci, które wyrosną na bełkoczących dorosłych lub przynajmniej dorosłych z poważnymi wadami wymowy. Inny przykład przedstawiający potencjalne ryzyka zastosowania AI w edukacji ilustruje program edukacyjny Quizlet Learn filmy QUIZLET (San Francisco, California). Wspomaga on osoby uczące się w dokonywaniu syntezy studiowanego materiału (dosłownie eliminuje konieczność zgadywania tego, co warto studiować (*helps take the guessing out of what to study*)). Platforma ta, wykorzystując uczenie maszynowe oraz dane pochodzące z milionów lekcji (*study sessions*), wskazuje osobom uczącym się najważniejszy materiał. I tu znowu pojawia się wątpliwość. W jakim stopniu szeroko rozumiane odciążanie i pomaganie uczniom rzeczywiście służy rozwojowi ich kompetencji poznawczych? W tym przypadku: jak będzie wyglądał świat, w którym osoby dorosłe nie będą potrafiły samodzielnie znajdować właściwych informacji w otaczającym świecie, ponieważ w czasie ich edukacji formalnej zadanie to wykonywała za nich sztuczna inteligencja? Takie podejście to prosta droga do tłumienia rozwoju kreatywności u ucznia. Tak wykorzystane oprogramowanie przygotowujące do egzaminu będzie np. pomijało fakty z życiorysów wynalazców (którego studenta elektrotechniki przygotowującego się do egzaminu z zasad wytwarzania prądu zmiennego zainteresuje fakt, że Nikola Tesla był emigrantem, wyznawcą religii prawosławnej i mówił z silnym słowiańskim akcentem w rozmowach z Thomasem Edisonem na temat wyższości prądu zmiennego nad prądem stałym?), które mogą przydać się w życiu, ale niekoniecznie w zdaniu egzaminu. Doskonale można zrozumieć istotę redundancji informacji, oglądając film „Milioner z ulicy” (*Slumdog Millionaire*, Celador Films&Film4 Productions, 2008), w którym główny bohater

zdobywa najwyższą nagrodę pieniężną w quizie, ponieważ w swoim życiu napotkał różnego rodzaju zdarzenia, w czasie których zdobył wiedzę „zbędną”/redundantną z różnych dziedzin, na przykład poznał pierwsze imię wynalazcy rewolweru Colt (Samuel). Prawdopodobnie na kursie historii rozwoju broni w akademii wojskowej sztuczna inteligencja, przygotowując studenta do egzaminu, pominęłaby informację o pierwszym imieniu wynalazcy rewolweru, bo przecież od tego nie zależałoby zdanie egzaminu. Jednak w optymistycznym scenariuszu algorytm sztucznej inteligencji nauczający o rewolwerze Samuela Colta odkrył, że uczeń uczy się intensywnie języka angielskiego i podpowiedział mu, że w języku angielskim *colt* oznacza „żrebak”. Zdolność do rozpoznawania i zapamiętywania asocjacji pomiędzy odległymi tematycznie informacjami jest jedną z cech charakterystycznych osób kreatywnych. Wynika ona z unikatowych doświadczeń danego człowieka które mają swój ślad w połączeniach neuronalnych w mózgu. W literaturze z zakresu kreatywności nazywana jest myśleniem konwergencyjnym (patrz m.in.: Cropley, 2006).

Przykład ryzyka związanego z wykorzystaniem błędnej/niewłaściwej teorii:

Innym wyzwaniem związanym z tworzeniem algorytmów sztucznej inteligencji służących nauczaniu jest personalizacja, czyli dostosowanie procesu nauczania do specyficznych cech indywidualnych osoby uczącej się. Idea indywidualizacji uczenia się nie jest nowa. Zanim jednak powstaną algorytmy personalizujące proces nauczania, należy wziąć pod uwagę wyniki badań naukowych dotyczące skuteczności tej koncepcji. Koncepcja stylów uczenia się jest bardzo popularna wśród nauczycieli na całym świecie. Coffield i in. (2004) opisał aż 71 różnych koncepcji związanych ze stylami uczenia się. Pierwszymi badaczami, którzy wysunęli teorię stylów uczenia się, byli R. S. Dunn i K. J. Dunn (1999). Wyjaśniali oni, że rozkład procesów koncentracji, przetwarzania, absorpcji oraz zapamiętywania informacji jest inny u różnych osób. Podział osób ze względu na różne typy ma jeszcze dłuższą historię i sięga do psychologa Carla Junga. O stylach uczenia pisał także Kolb (1984) w ramach teorii czterofazowego cyklu uczenia się. Kwestia niedobrania właściwego stylu nauczania do oczekiwań ze strony uczniów (*mismatch*) jest jednak istotnie rzeczywistym zjawiskiem, które należy brać pod uwagę. Dopasowanie stylu przekazywania wiedzy do oczekiwań ucznia znacząco wpływa na poprawę rezultatów nauczania (Reid, 1987; Peacock, 2001; Bristow i in., 2014). Dunn (2009) przedstawia pięć etapów treningu sportowca mających na celu podniesienie jego wyników sportowych i umiejętności:

1. Ocena kompetencji w zakresie uczenia się po stronie trenera oraz sportowca, refleksja na temat relatywnych sukcesów, które można przypisać dotychczas stosowanym metodom treningowym;
2. Refleksja nad efektami dotychczasowych metod szkoleniowych;
3. Rozwój różnych metod;
4. Powiązanie i dobór odpowiednich metod treningowych z preferencjami sportowca;
5. Ocena relatywnego pozytywnego wpływu nowych metod na wyniki sportowca.

Zaproponowany przez Dunna (2009) pięcioetapowy proces ma bardzo duży potencjał do wykorzystania w przypadku tworzenia algorytmów dla sztucznej inteligencji w obszarze edukacji. Dyskusja nad tematyką stylów uczenia się jest istotna w kontekście zastosowania sztucznej inteligencji w edukacji również dlatego, że aktualne i przyszłe rozwiązania w tym obszarze będą z pewnością odnosić się do aktualnego stanu wiedzy naukowej, w tym przypadku z zakresu pedagogiki i psychologii. Wykorzystanie niewłaściwych teorii lub takich, które nie mają uzasadnienia empirycznego, może być szkodliwe. Na przykład w książce pt. *50 mitów psychologii popularnej* (Lilienfeld i in., 2011) przedstawiono teorie, które łączy jedno: są bardzo popularne wśród praktyków edukacji, a jednocześnie mają bardzo słabe osadzenie w wynikach badań naukowych potwierdzających ich słuszność. Istnieje więc realne niebezpieczeństwo, że wraz z rozwojem sztucznej inteligencji w obszarze edukacji będą powstawać algorytmy oparte na fałszywych z gruntu założeniach teoretycznych. Tematem na osobną dyskusję w gronie matematyków i informatyków jest to, czy algorytm sztucznej inteligencji oparty na fałszywych przesłankach będzie w stanie samodzielnie się „zreflektować”/naprawić? Jest to pytanie podobne do tego, czy algorytm do gry w szachy, który zawiera sekwencje ruchów doprowadzające do przegranej partii, będzie w stanie samodzielnie udoskonalić swoje działanie wbrew intencji twórców algorytmów, czyli de facto podważyć teorię, na bazie której powstał. Jednak i tu pojawia się dylemat etyczny: jeśli algorytm sztucznej inteligencji przegra partię gry w Go z człowiekiem, to czy będzie to strata moralna dla zespołu informatyków? Jeśli natomiast algorytm nauczający ucznia z powodu zaprogramowanych w nim błędnych założeń źle nauczy ucznia, to wówczas konsekwencje tego będą znacznie poważniejsze. Na przykład, algorytm sztucznej inteligencji oparty na fałszywym założeniu, że „wykorzystujemy tylko 10% potencjału naszego mózgu” nie będzie w stanie zapewnić optymalnego procesu nauczania.

Problem z badaniem preferencji uczniów polega na tym, że ocena stylów uczenia się w badaniach psychologicznych jest dokonywana dość powierzchownie. Osoby badane wypowiadają się, udzielając odpowiedzi na takie pytania, jak: „Preferuję...”, „Najlepiej uczę się poprzez/gdy...”. Jednak większość ludzi nie ma wyrobionego zdania na temat tego, jak się uczy. Każdy człowiek jest inny – to nie ulega wątpliwości. Kwestia, która jest tutaj analizowana, dotyczy czegoś innego: a mianowicie, czy dostosowanie metod nauczania do indywidualnych „stylów uczenia się” ma pozytywny wpływ na wyniki nauczania? Sztuczna inteligencja mogłaby przezwyciężyć tę słabość poprzez analizowanie zachowań i reakcji uczniów w różnych sytuacjach. Być może nawet pozwoliłaby na stworzenie nowej teorii personalizacji w edukacji. Aby udowodnić lub podważyć skuteczność koncepcji stylów uczenia się, przeprowadzono eksperymenty naukowe. W ramach takich eksperymentów dzielono uczestników ze względu na ich „styl uczenia się”. Na drugim etapie eksperymentu losowo przydzielano ich do grup, w których nauczyciel stosował jeden ze stylów uczenia się. W takim eksperymencie, aby udowodnić skuteczność koncepcji stylów uczenia się, uczniowie-wzrokowcy przypisani do grupy, w której nauczyciel stosował metody nauczania przeznaczone dla wzrokowców, powinni uzyskiwać wyższe wyniki niż pozostali uczniowie, np. słuchowcy. Spośród około 24 różnych studiów badawczych tylko w trzech dostrzeżono jakiś słaby pozytywny związek. Istnieje natomiast wielka liczba dobrze udokumentowanych badań, z których jasno wynika, że brak jest dowodów empirycznych na coś takiego jak „style uczenia się”.

Przegląd zastosowań AI w edukacji

Trwa debata na temat tego, czy sztuczna inteligencja zastąpi nauczyciela. Natomiast liczba potencjalnych zastosowań sztucznej inteligencji w systemie edukacji jest znacznie szersza niż tylko „zastąpienie nauczyciela”. AI może pełnić rolę zarówno autonomicznego nauczyciela, jak i asystenta człowieka-nauczyciela w procesie nauczania. Nie powinniśmy ograniczać pola zastosowań sztucznej inteligencji w systemie edukacji do aktywności zorientowanej wyłącznie *bezpośrednio* na ucznia. Wręcz przeciwnie: sztuczna inteligencja może nie tylko zastępować nauczyciela, wprowadzać zmechanizowane elementy do procesu nauki, lecz także pomagać w zarządzaniu zapleczem edukacyjnym ucznia (*back-office*).

Sztuczna inteligencja spełniająca postulaty personalizacji uczenia się może wytwarzać „zindywidualizowane bańki informacyjne” dla każdego ucznia, sprawiając, że naruszone zostaną podstawy spójności społecznej. Weźmy na przykład nauczanie przedmiotów humanistycznych. Jeżeli zgodnie z tym, co zostało przedstawione wyżej założymy, że sztuczna inteligencja powinna najpierw zdiagnozować ucznia i opracować najbardziej skuteczny i dopasowany do danej osoby algorytm nauczania, jak wyglądałoby nauczanie historii Polski? Czy algorytm powinien różnym uczniom przedstawiać zróżnicowane fakty naszej historii ilustrujące dane zdarzenie? Na przykład o bitwie pod Grunwaldem napisano dziesiątki książek historycznych – które z wielu faktów powinny być zaprezentowane uczniowi, aby utrwalił ogólną informację o tym zdarzeniu? Czy uczeń o potencjalnie prawicowych poglądach (więcej na ten temat w: Haidth, 2014) nie powinien poznać pewnych faktów o bitwie pod Wiedniem, ponieważ w przeciwnym wypadku stałby się w przyszłości islamofobem? (Al-Marashi, 2019).

AI może pomagać nauczycielom w wykrywaniu problemów z przyswajaniem wiedzy u uczniów, dostosowywać materiał do indywidualnych potrzeb ucznia lub po prostu być wykorzystana do oceniania. AI może także pomóc w zarządzaniu lekcjami i systemem edukacji, na przykład przewidując pewne trendy, zachowania ucznia i zjawiska z wyprzedzeniem. AI może pomóc analizować postępy ucznia w czasie rzeczywistym oraz podsuwać rekomendacje co do tego, jak zachować się wobec konkretnych uczniów. W Tab. 4. przedstawiono przegląd możliwości zastosowania sztucznej inteligencji w obszarze edukacji. Wśród zastosowań wyróżniono kilka podkategorii:

- sztuczna inteligencja wspomagająca proces uczenia się,
- sztuczna inteligencja jako wsparcie nauczyciela w zakresie procesów administracyjnych,
- sztuczna inteligencja w obszarze zarządzania systemem oświaty na różnych jego poziomach.

Systematyzacja ta jest istotna, ponieważ pozwala ukierunkować dalsze prace badawcze oraz strategię rozwoju sztucznej inteligencji na poziomie dostawców rozwiązań. Każde z wyżej wymienionych zastosowań ma potencjalnie służyć poprawie sytuacji uczniów, lecz z innej perspektywy.

Tabela 4. Przegląd możliwości zastosowania sztucznej inteligencji w obszarze edukacji

Zastosowanie	Opis
Sztuczna inteligencja wspomagająca proces uczenia się	
Sztuczna inteligencja jako pomocnik nauczyciela	Sztuczna inteligencja może pełnić funkcję korepetytora/tutora. AI lepiej sprawdza się w kształceniu podstaw danych dyscyplin wiedzy i na razie nie jest zdolna do rozwoju u ucznia umiejętności wyższego rzędu, takich jak jedność myślenia i kreatywność. Nie można jednak wykluczyć, że w przyszłości programy edukacyjne AI będą w stanie rozwijać także umiejętności wyższego rzędu. Przy ocenie wiarygodności wyników eksperymentów edukacyjnych trzeba mieć na uwadze istnienie efektu konfirmacji. Badacz ma tendencję do podświadomego prowadzenia eksperymentu w taki sposób, aby potwierdzić swoje oczekiwania. Ponadto w badaniach społecznych wiarygodność wyników uzyskuje się przez wielokrotne powtarzanie eksperymentu. Tego raczej nauczyciele nie praktykują. Sztuczna inteligencja z zasady powinna być pozbawiona zdolności do wpadania w pułapki myślenia charakterystyczne dla ludzi, a więc w tym znaczeniu mieć przewagę nad żywym nauczycielem.
Sztuczna inteligencja w zastępstwie nauczyciela	Istnieją już rozwiązania pozwalające na inteligentne nauczanie – <i>smart tutoring systems</i> (np. Carnegie Learning). Wśród nich można wymienić między innymi Amazon's Alexa, Apple Siri, Microsoft Cortana. Asystenci głosowi pozwalają uczniowi na rozmowę dotyczącą przerobionego materiału bez konieczności angażowania nauczyciela. Asystenci głosowi są także wykorzystywani przez instytucje edukacyjne do przekazywania uczniom i studentom informacji natury organizacyjnej. Na przykład <i>Cognilytica</i> z <i>Arizona State University</i> oferuje studentom poradnik dla studenta pierwszego roku z wykorzystaniem oprogramowania Amazon Alexa.
Sztuczna inteligencja jako przestrzeń zapewniająca bezpieczeństwo emocjonalne w procesie ponoszenia porażek edukacyjnych	Uczenie się jest nierozdzielnie związane z podejmowaniem prób i ponoszeniem w tym czasie porażek. W tradycyjnej szkole istnieje wiele barier społecznych i emocjonalnych, które zniechęcają uczniów do podejmowania prób. W efekcie proces uczenia się jest mniej efektywny na przykład z powodu strachu przed ośmieszeniem publicznym. W związku z tym możliwość trenowania swoich umiejętności w odosobnieniu oraz intymność zapewniona przez sztuczną inteligencję może sama w sobie okazać się atutem w stosunku do pracy ucznia w klasie oraz/lub w obecności nauczyciela.
Zastosowanie do indywidualnych potrzeb ucznia (personalizacja)	System nauczania i wychowania w tradycyjnej szkole z natury jest nastawiony na uśrednianie i standaryzowanie procesu uczenia. Sztuczna inteligencja oferuje możliwości personalizacji procesu uczenia się. Personalizacja powinna dotyczyć przede wszystkim wykrytych deficytów wiedzy, które w tradycyjnej klasie mogą być zaniedbane przez nauczyciela w ramach kompromisu na rzecz zaspokojenia potrzeb edukacyjnych pozostałych uczniów w klasie. Sztuczna inteligencja może na przykład zwiększać intensywność zadań testowych w obszarach, które uzna za wymagające doskonalenia oraz zmniejszyć liczbę zadań testowych w obszarach, które zostały już opanowane przez ucznia. W ten sposób całkowity bilans czasu poświęconego na testowanie może być równy u wielu uczniów w klasie, natomiast zróżnicowana będzie struktura zadań sprawdzających. Takie podejście pozwoliło na szybszą transformację społeczeństwa z gospodarki agrarnej w kierunku gospodarki przemysłowej. Śladem tym podążały inne państwa na całym świecie.

cd. Tabeli 4. Przegląd możliwości zastosowania sztucznej inteligencji w obszarze edukacji

<p>Udzielanie informacji zwrotnej</p>	<p>Nauczyciele w klasie często nie mają wystarczającej ilości czasu na udzielenie informacji zwrotnej uczniowi na temat jego postępów w nauce oraz deficytów wiedzy i umiejętności. Sztuczna inteligencja może rozwiązać ten problem. Analiza deficytów wiedzy w zestawieniu z biblioteką informacji zwrotnych może pozwolić AI na wytworzenie spersonalizowanej, rzetelnej i szczegółowej informacji zwrotnej w danym obszarze. Dodatkową zaletą wykorzystania sztucznej inteligencji może być pozbawienie jej zarzutu subiektywności („nauczyciel mnie nie lubi, dlatego postawił mi jedynkę”). Jeżeli uczeń będzie współpracował z AI, to na podstawie zgromadzonych danych historycznych AI może pomóc uczniowi w podejmowaniu decyzji dotyczących wyboru dalszych etapów edukacji.</p> <p>Osobną kwestią jest uczciwość informacji zwrotnej. Można się spodziewać, że algorytm sztucznej inteligencji będzie sprawiedliwy i obiektywny, podczas gdy „żywy” nauczyciel nie zawsze jest w stanie lub ma pragnienie udzielenia uczciwej informacji zwrotnej. Chociaż działa wówczas nieetycznie, to jednak, mimochodem, przygotowuje młodego człowieka do życia w świecie niesprawiedliwości i oszustw. Czy można więc również tę funkcję symulować za pomocą sztucznej inteligencji? Teoretycznie tak: można zaprogramować algorytm tak, aby czasami był niesprawiedliwy/rasistowski/tendencyjny/dyskryminujący danego ucznia – ale spowoduje to jeszcze większą liczbę problemów natury moralnej niż nieetyczne zachowania nauczycieli.</p>
<p>Sztuczna inteligencja jako wsparcie nauczyciela w procesach administracyjnych</p>	
<p>Ocenianie uczniów</p>	<p>Sztuczna inteligencja może odciążyć nauczycieli w procesie oceniania. Ocenianie może być całkowicie zautomatyzowane (ocena na podstawie testów) albo częściowo zautomatyzowane, np. AI może analizować efekty pracy ucznia i podpowiadać nauczycielowi, jednak pozostawiać ostateczną decyzję samemu nauczycielowi. W przyszłości można spodziewać się rozwoju systemów do analizy jakościowej prac uczniów. Inne powiązane zadania, które może realizować AI, to np. wpisywanie ocen na koniec semestru, wypełnianie sprawozdań i dokumentacji związanej z zatrudnieniem, przygotowywanie materiałów do nauki, organizowanie wycieczek szkolnych, komunikacja z rodzicami i rozwiązywanie problemów uczniów cudzoziemskich, sprawy związane z zwolnieniami lekarskimi i innymi. Nauczyciele poświęcają niebagatelną ilość swojego czasu na zadania niezwiązane z bezpośrednią pracą z uczniem. W związku z tym odciążenie ich od tego rodzaju zadań może automatycznie przełożyć się na zwiększenie efektywności procesu edukacji, jeśli przeznaczoną zaoszczędzony czas na nauczanie czy wypoczynek. Obciążenie zadaniami administracyjnymi ma także niebagatelny wpływ na poziom motywacji do pracy i często skutkuje wypaleniem zawodowym. Sztuczna inteligencja może także podpowiadać, z kim i w jakiej sprawie powinien spotkać się nauczyciel.</p>
<p>Sprawdzanie obecności i aktywności uczniów</p>	<p>Jest to jedno z najprostszych zadań, które może wykonywać nieskomplikowane oprogramowanie.</p>
<p>Wsparcie metodyczne</p>	<p>System może wspierać nauczyciela w procesie nauczania. Jeśli na przykład AI wykryje nieproporcjonalnie wysoką liczbę błędnych odpowiedzi uczniów w danym obszarze, może przedstawić nauczycielowi propozycje usprawnień albo na przykład dostarczyć wiedzy merytorycznej potrzebnej do przekazania uczniom. Aktualnie zadania doradcy metodycznego powierza nauczycielowi kurator oświaty właściwy ze względu na siedzibę publicznej placówki doskonalenia, w której doradca ma być zatrudniony, po uzgodnieniu z dyrektorem szkoły lub placówki, w której nauczyciel jest zatrudniony. Funkcje doradcy metodycznego mogą zostać w przyszłości zastąpione przez AI.</p>

cd. Tabeli 4. Przegląd możliwości zastosowania sztucznej inteligencji w obszarze edukacji

Zarządzanie relacjami	Nauczyciele są zobowiązani do utrzymywania stałych relacji z rodzicami. AI mogłaby wyręczyć nauczycieli w realizacji niektórych zadań z tym związanych, szczególnie, jeśli AI pozwoli na bezpośrednie udzielanie informacji zwrotnej o uczniu rodzicom, bez konieczności angażowania nauczyciela.
Sztuczna inteligencja w obszarze zarządzania systemem oświaty na różnych jego poziomach	
Ocena nauczycieli	Systemy edukacji w wielu krajach na świecie wdrożyły różnego rodzaju zasady oceniania i awansu zawodowego nauczycieli. Są one oparte na analizie pewnych zdefiniowanych z góry osiągnięć i aktywności nauczycieli. Podobnie jak ma się to w przypadku oceniania uczniów, tu także sztuczna inteligencja mogłaby oceniać lub też dostarczać informacji osobom oceniającym nauczyciela. Dzięki powiązaniu – w ramach odpowiednich algorytmów – informacji o postępach w nauce uczniów (edukacyjna wartość dodana) z wynikami analizy zaangażowania nauczyciela, z pracą szkoły, współpracą z innymi nauczycielami oraz ze środowiskiem lokalnym algorytm mógłby w sposób zobiektywizowany wystawiać okresowe oceny nauczycielom. Byłyby one potencjalnie pozbawione elementów merytorycznych lub politycznych, jakie często towarzyszą pracy nauczyciela. W rezultacie zobiektywizowane ocen nauczycieli w systemie edukacji mogłoby doprowadzić do ogólnego podwyższenia jakości nauczania, jeśli udałoby się wyeliminować wpływ czynników merytorycznych na sytuację zawodową nauczycieli w systemie.
Analiza dużych zbiorów danych o systemie edukacji	Odpowiednie algorytmy mające dostęp do danych wytwarzanych na podstawie zachowania uczniów mogą dostarczyć informacji pozwalających na odpowiednią alokację środków w systemie edukacji oraz przewidywanie trendów i antycypowanie zagrożeń na przykład w czasach pandemii i nauczania zdalnego. Ministerstwo Edukacji i Nauki mogłoby, dysponując takimi danymi, określić skalę ewentualnych strat spowodowanych spadkiem jakości nauczania wywołanych pandemią. Badania nad systemami edukacji w skali makro są już prowadzone od jakiegoś czasu, między innymi przez centrum CERI w ramach struktur OECD. Dzięki wykorzystaniu sztucznej inteligencji jakość, skala i częstotliwość pomiarów mogłaby znacznie się wzrosnąć. Nie byłoby też konieczności, tak jak to ma miejsce obecnie, polegania na danych pochodzących z ankietowania nauczycieli. Sztuczna inteligencja mogłaby odpowiedzieć także na wiele pytań, które obecnie stanowią obszar debaty politycznej w Polsce i na świecie. W przypadku Polski np., czy podwyższenie/obniżenie wieku obowiązkowej edukacji przedszkolnej jest korzystne, czy też nie dla rozwoju emocjonalnego i intelektualnego dziecka?
Analiza danych na poziomie organu prowadzącego oraz regionalnym	Analiza zróżnicowania regionalnego oraz na poziomie dużych samorządów (np. gmin miejskich) mogłaby pozwolić na zoptymalizowanie wykorzystania zasobów oraz monitoringu efektywności ich wykorzystania. Na przykład dane dotyczące aktywności uczniów i nauczycieli mogłyby być skorelowane w ramach algorytmu AI z nakładami na technologie informatyczne w edukacji.

Źródło: opracowanie własne.

Podsumowanie

Ponieważ sztuczna inteligencja wykazuje wiele cech człowieka, takich jak zdolność do uczenia się, krytycznego myślenia oraz rozwiązywania problemów, budzi wiele emocji. Jedną z nich jest strach, że w przyszłości AI zastąpi nauczycieli. Jednak z dzisiejszej perspektywy AI przede wszystkim powinna koncentrować się na zadaniach powtarzalnych. Dzięki niej nauczyciele mogliby poświęcić więcej czasu na indywidualizację podejścia do ucznia, na przykład nauczyciel języka polskiego nie będzie musiał poprawiać sprawdzianów, ponieważ sztuczna inteligencja sprawniej udzieli informacji zwrotnej uczniowi. W ramach systemu edukacji należy także zastanowić się, czy odwrót od standaryzacji w procesie nauczania, jaki może zapewnić potencjalne wykorzystanie sztucznej inteligencji, nie niesie ze sobą negatywnych skutków ubocznych. Szkoły i system edukacji są przestrzenią socjalizacji, interakcje pomiędzy uczniami służą wzajemnemu poznaniu się, tworzeniu wspólnego systemu wartości, przynależności. W szkołach tworzy się kultura, coś, co spaja społeczeństwo. Kultura nie jest ani „właściwa” ani „niepoprawna” – w przeciwieństwie do matematyki, sztuczna inteligencja powinna więc przede wszystkim koncentrować się na kształtowaniu wiedzy i umiejętności, które mają obiektywny punkt odniesienia.

W niniejszym rozdziale przedstawiono przegląd zastosowań oraz wyzwań związanych z wykorzystaniem sztucznej inteligencji w systemie edukacji. Specyfika systemu edukacji w stosunku do innych sektorów gospodarki nakłada na dostawców rozwiązań AI specyficzne wymagania. Znaczenie aspektów etycznych i moralnych jest tutaj nawet większe niż w działalności komercyjnej, a konsekwencje zastosowania niewłaściwych algorytmów są także odpowiednio głębsze (szczególnie, że mogą dotyczyć dużych populacji uczniów), a ich skutki mogą być dalekosiężne.

Bibliografia

Al-Marashi, I. (2019). The New Zealand massacre and the weaponisation of history, <https://www.aljazeera.com/opinions/2019/3/24/the-new-zealand-massacre-and-the-weaponisation-of-history> [dostęp: 09.02.2021]

Baumeister, R. F., Tierney, J. (2013). *Siła woli. Odkryjmy na nowo to, co w człowieku najpotężniejsze*. Poznań: Media Rodzina.

Bristow, E. C., Bruhl, J. C. and Klosky, J. L. (2014). Effect of Supplemental Instructional Videos on Student Performance in Engineering Mechanics Class. *International Journal of Engineering Education*, 30 (3), 566575.

Bozarth, J. (2018). *The Truth About Teaching To Learning Styles, And What To Do Instead?* The Learning Guild. Santa Rosa, California.

Coffield, F., Moseley, D., Hall, E. and Ecclestone, K. (2004). *Learning styles and pedagogy in post-16 learning. A systematic and critical review*. London: Learning and Skills Research Centre.

- Cropley, A. (2006). In Praise of Convergent Thinking. *Creativity Research Journal*, 18(3): 391–404.
- Dunn, R. S. and Dunn, K. J. (1999). *The complete guide to the learning styles inservice system*. Allyn and Bacon.
- Dunn, J. L. (2009). Using learning preferences to improve coaching and athletic performance. *Journal of Physical Education, Recreation & Dance* 80(3), 3037.
- Du Sautoy, M. (2020). *Kod kreatywności. Sztuka i innowacja w epoce sztucznej inteligencji*. Kraków: Copernicus Center Press.
- Fromm, E. (2005). *O sztuce istnienia*. Warszawa – Wrocław: PWN.
- Haidt, J. (2014). *Prawy umysł. Dlaczego dobrych ludzi dzieli religia i polityka?* Sopot: Smak Słowa.
- Kolb, D. A. (1984). *Experiential learning*. Englewood Cliffs, NJ: PrenticeHall.
- Lilienfeld, S. O, Lynn, S. J., Ruscio, J., Beyerstein B.L. (2011). *50 mitów psychologii popularnej*, Warszawa: Wydawnictwo Cis.
- Ministerstwo Cyfryzacji. (2020). *Założenia do strategii AI w Polsce*, Warszawa.
- Peacock, M. (2001). Match or mismatch? Learning styles and teaching styles in EFL. *International Journal of Applied Linguistics* , 11(1), 120.
- Parlament Europejski (2020). *Sztuczna inteligencja: szanse i zagrożenia*, <https://www.europarl.europa.eu/news/pl/headlines/priorities/sztuczna-inteligencja-w-ue/20200918STO87404/sztuczna-inteligencja-szanse-i-zagrozenia> [dostęp: 06.02.2021]
- Reid, J. M. (1987). The learning style preferences of ESL students. *TESOL quarterly*, 21(1), 87111.
- Serwis Rzeczypospolitej Polskiej (2020). *Rozwój sztucznej inteligencji w Polsce – ważna decyzja*, <https://www.gov.pl/web/cyfryzacja/rozwoj-sztucznej-inteligencji-w-polsce--wazna-decyzja> [dostęp: 06.02.2021]

Między sztuczną inteligencją a „sztuczną kreatywnością” – przyszłość człowieka kreatywnego w epoce sztucznej inteligencji

prof. dr hab. Jan Fazlagić

Wprowadzenie

Wykorzystanie sztucznej inteligencji przez człowieka było przewidywane przez futurologów i autorów książek *science fiction* na długo przed pojawieniem się internetu i komputerów o dużych mocach obliczeniowych. Wśród przewidywań dotyczących wykorzystania sztucznej inteligencji było wiele głosów niepokoju, a nawet strachu przed upowszechnieniem się tej technologii. Według stanu na 2021 r. można stwierdzić, że obawy te były nieuzasadnione lub co najwyżej przedwczesne. Rozwiązania oparte na sztucznej inteligencji, takie jak oprogramowanie pozwalające na robienie perfekcyjnych zdjęć za pomocą telefonu komórkowego czy asystent nawigacji ułatwiają życie przeciętnemu obywatelowi. Znanych jest natomiast wiele przykładów (niektóre z nich zostaną przytoczone w dalszej części opracowania) dowodzących, że większym problemem jest zbyt niski współczynnik inteligencji AI niż za wysoki. Pojawia się nawet popyt na rozwiązania technologiczne, które służą do celowego obniżania jakości produktów wytwarzanych przez człowieka, co ma na celu zwiększenie ich „kreatywności” poprzez zamierzone nadanie cech niedoskonałości, np. efekt starego filmu (sepia + rysy na obrazie, samochody elektryczne z głośnikami symulującymi brzmienie silnika spalinowego i in.). Z jednej strony sztuczna inteligencja jest emanacją inteligencji człowieka, lecz z drugiej, jak wykazało wykorzystanie sztucznej inteligencji do gry w Go, AI może nauczyć się i stać się mądrzejsza niż najlepsi gracze (Du Sautoy, 2020). Czy tak również stanie się w przypadku wykorzystania sztucznej inteligencji w nauczaniu? W najbardziej optymistycznym scenariuszu powinien powstać algorytm, który będzie emulował nauczyciela, ucząc szybciej, lepiej, więcej wszystkiego, czego uczy nauczyciel „żywy”...

Biorąc pod uwagę ilość wyzwań, przed jakimi stoją twórcy rozwiązań AI, warto podjąć rozważania na temat roli człowieka w relacji do tych rozwiązań. Na przykład, w jakim stopniu człowiek i jego kreatywność mają się stać wzorcem dla twórców rozwiązań AI, a w jakim stopniu rozwój AI powinien abstrahować od stanu wiedzy na temat działania ludzkiej kreatywności. Czy rozwiązania AI zaprzęgnięte do realizacji działań twórczych będą efektywniejsze, gdy zostaną oparte na „rusztowaniu” wiedzy o ludzkiej kreatywności, czy też większy potencjał daje tworzenie algorytmów abstrahujących od sposobu myślenia twórcy-człowieka? Celem niniejszego artykułu jest dokonanie refleksyjnej analizy i prognozy kierunków rozwoju sztucznej inteligencji w obszarze zarysowanym przez powyższe pytania. Jako podstawę rozważań obrano aktualny stan wiedzy na temat definicji (ludzkiej) inteligencji w zestawieniu z poglądami badaczy na temat kreatywności. Analizie poddano także pierwsze doświadczenia związane z próbami emulowania kreatywności przez AI.

* Uniwersytet Ekonomiczny w Poznaniu, ORCID: 0000-0003-1968-2163

Sztuczna inteligencja a sztuczna kreatywność

Dobrym punktem do rozważań na temat możliwości wykorzystania sztucznej inteligencji do emulowania ludzkiej kreatywności jest porównanie różnych sposobów rozumienia i wzajemnych relacji obu pojęć z perspektywy psychologii. Sztuczna inteligencja to zdolność maszyn do wykazywania ludzkich umiejętności, takich jak rozumowanie, uczenie się, planowanie i kreatywność (Parlament Europejski, 2020). Sztuczna inteligencja umożliwia systemom technicznym postrzeganie ich otoczenia, radzenie sobie z tym, co postrzegają i rozwiązywanie problemów, poprzez działania w kierunku osiągnięcia określonego celu. Komputer odbiera dane (już przygotowane lub zebrane za pomocą jego czujników, np. kamery), przetwarza je i reaguje. Systemy AI są w stanie do pewnego stopnia dostosować swoje zachowanie, analizując skutki wcześniejszych działań i działając autonomicznie. W Tab. 5 przedstawiono aktualne poglądy spotykane w literaturze przedmiotu na temat relacji obu pojęć. Jak widzimy, nie ma zgodności w świecie nauki co do pozycji kreatywności względem inteligencji.

Kreatywność można podzielić na psychologiczną i historyczną (Du Sautoy, 2020). Historyczna kreatywność jest czymś rzadkim, odnosi się do stworzenia czegoś po raz pierwszy w historii. Z kolei kreatywność psychologiczna wynika z tego, że coś zostało uznane przez innych za nowe i wartościowe. Kreatywność psychologiczna jest aktem odkrycia dla nas samych, natomiast z historycznego punktu widzenia nie jest to nic nowego. Trzecim rodzajem kreatywności jest kreatywność kombinacyjna: jest wynikiem procesu nagromadzenia drobnych faktów. Podział na kreatywność psychologiczną, historyczną i kombinacyjną nie jest idealny. Wiele wynalazków można zakwalifikować do każdej z tych trzech dziedzin jednocześnie. Na przykład maszyna drukarska Gutenberga była *kombinacją* technologii znanych już wówczas, przejawem kreatywności historycznej, ale także psychologicznej.

Definicje kreatywności są piętą achillesową badań nad kreatywnością (Puryear and Lamb, 2020). Trwa spór o to, jaka jest na przykład relacja pomiędzy kreatywnością a inteligencją. Ponieważ nie udało się nadal uzyskać konsensusu w tej sprawie, również badania nad wykorzystaniem sztucznej inteligencji w edukacji są z tego powodu opóźnione w tym sensie, że na razie są w stanie wskazać, jakie są związki pomiędzy:

- a) kreatywnością;
- b) naturalną (ludzką) inteligencją;
- c) sztuczną inteligencją.

Rozważania na temat sztucznej inteligencji w relacji do kreatywności mają duże znaczenie dla kształtowania strategii w systemie edukacji. Tak zwane „umiejętności XXI wieku” (*21st Century Skills*) zawierają kompetencje związane zarówno z inteligencją, jak i kreatywnością. Obecnie system edukacji jest oparty na założeniu, że inteligencja jest najważniejszym składnikiem potencjału intelektualnego człowieka i wyznacznikiem wartości jego pracy. Jednak jeśli kreatywność nie jest podzbiorem inteligencji, tak jak twierdzą niektórzy badacze, a pojęciem częściowo lub całkowicie autonomicznym wobec inteligencji, powinniśmy radykalnie zmienić kształt naszych systemów edukacji w XXI wieku.

Tabela 5. Relacje pomiędzy inteligencją a kreatywnością

Inteligencja vs. kreatywność	Opis relacji obu pojęć	Główni zwolennicy takiego uporządkowania
Kreatywność podzbiorem inteligencji	Według Guilforda w ramach koncepcji kreatywności występują także pojęcia związane z inteligencją, takie jak myślenie dywergencyjne, inteligencje wielorakie, wykorzystanie inteligencji na wiele sposobów, na przykład na potrzeby tworzenia kreatywnych rozwiązań. Wg Gilforda (1967) kwintesencją kreatywności jest zdolność do myślenia dywergencyjnego.	Guilford, 1950; Guilford, 1967; Gardner, 1983; Kaufman, 2013
Inteligencja podzbiorem kreatywności	W procesach poznawczych zdolności kreatywne są ważniejsze niż zdolności intelektualne. Wykorzystanie kreatywności wymusza konieczność zaangażowania inteligencji i innych atrybutów. W związku z tym inteligencja jest częścią złożonych i wielowymiarowych procesów kreatywnych.	Smith, 1970; Sternberg and Lubart, 1996; Sternberg and O'Hara, 2000
Kreatywność i inteligencja jako zbiory o częściach wspólnych	Kreatywność i inteligencja pod wieloma względami są podobne, dzielą pewne wspólne elementy, lecz mają też elementy odróżniające je od siebie nawzajem.	Naglieri and Kaufman, 2001 Plucker i in., 2004
Kreatywność i inteligencja jako pojęcia tożsame	Mechanizmy opisujące działanie kreatywności oraz działania inteligencji niczym od siebie się nie różnią. W testach na kreatywność mierzona jest w istocie zdolność do tworzenia ponadprzeciętnych wyników przez inteligencję.	Weisberg, 1993
Kreatywność i inteligencja jako zbiory rozłączne	Kreatywność nie jest zdolnością, lecz rezultatem działania autonomicznego obszaru ludzkiego umysłu. W tym sensie inteligencja nie ma żadnego wpływu na zdolności do tworzenia kreatywnych rozwiązań.	Ericsson, 1976

Źródło: opracowanie własne.

Warto zwrócić uwagę na fakt, że w psychologii rozróżnia się potencjał kreatywny człowieka (*creative potential*) od kreatywnych efektów (*creative achievements*) (Eysenck, 1995). Wydaje się, że pierwsze próby wykorzystania sztucznej inteligencji na potrzeby pracy kreatywnej można utożsamiać z założeniem, że kreatywność i inteligencja są pojęciami tożsamymi. Problem polega na tym, że jak dotychczas próby wykorzystania sztucznej inteligencji na potrzeby symulowania pracy kreatywnej człowieka w dużym stopniu koncentrują się tam, gdzie duża moc przetwarzania informacji daje maszynie przewagę nad człowiekiem i w istocie przypominają rozwiązywanie zadań matematycznych (jak wygrać w Go? Czy u Rembrandta jest więcej zieleni niż u Picassa?). Na razie sztuczna inteligencja nie potrafi wymyślić nowego nurtu filozoficznego, napisać porywającego przemówienia za głowę państwa obejmującą swój urząd, opowiedzieć dowcipu na bazie wydarzeń politycznych z ostatniego tygodnia itd.

Możliwości i potencjalne ograniczenia związane z wykorzystaniem wyników badań nad ludzką kreatywnością na potrzeby tworzenia algorytmów AI

Szczegółowy przegląd wyników badań na temat ludzkiej kreatywności wykracza poza możliwości ich prezentacji w ramach niniejszej publikacji. Trzeba jednak wyraźnie wskazać twórcom algorytmów AI na olbrzymi potencjał, jaki tkwi w emulowaniu pewnych procesów opisanych w psychologii kreatywności jako „surowca” potrzebnego do tworzenia skutecznych algorytmów mających za zadanie zastąpienie ludzkiej kreatywności. Jak wskazują wyniki prowadzonych w ostatnich latach eksperymentów (patrz m.in. DU Sautoy, 2020), twórcy rozwiązań AI coraz częściej porzucają ściśle matematyczną ścieżkę badań i otwierają się na wiedzę o tym, jak kreatywność funkcjonuje w społeczeństwie, jak jest odzwierciedlona w życiu jednostek i społeczeństw. Poniżej przedstawiono przegląd możliwości, a także ograniczeń związanych z posiłkowaniem się wiedzą o kreatywności ludzkiej na potrzeby tworzenia kreatywności syntetycznej.

Możliwości i szanse

1. *Symulacja publiczności* – w pracach na temat aktywności osób kreatywnych dużą rolę odgrywa środowisko (*press, environment*). W studiach nad innowacyjnością (patrz np. Richardson, 1973; Porter, 1990; Polenske, 1997) mówi się o roli sieci społecznych (regiony przemysłowe, tzw. „Efekt Medyceuszy” itp.) Ten czynnik ma często niebagatelny wpływ na efekt pracy twórczej. Emulacja tego zjawiska jest już stosowana: sztuczna inteligencja może zawierać w sobie dwa konkurujące ze sobą podsystemy – generatora i dyskryminatora. W przypadku kreatywności dotyczącej dzieł sztuki dyskryminator będzie grał algorytmicznego historyka sztuki (Du Sautoy, 2020). Dyskryminator może także potencjalnie grać rolę „anioła biznesu”, funduszy VC (dla pomysłów kreatywnych z zakresu ekonomii) bądź komisji eksperckiej (*gatekeepers*) (patrz także: Perkins, 1981). Potęga uczenia się maszynowego pozwala na tworzenie nieskończonej liczby wymiarów różnicujących dzieła twórcze. Dzięki temu sztuczna inteligencja może dokonywać kombinacji tych cech w ramach różnych wymiarów.
2. *Analiza dzieł twórczych* – sztuczna inteligencja może być bardzo pomocna do analizy dzieł twórczych innych osób. Na przykład analizując obrazy Van Gogha, możemy ustalić, które okresy jego twórczości były najbardziej twórcze, co różni obrazy różnych artystów itp.
3. *Symulacja emocji* – odwołanie się do zmiennych związanych z reakcją publiczności. Najważniejszymi właściwościami estetycznymi są nowość, zaskoczenie, złożoność, wieloznaczność i zmuszanie do zadawania pytań. Reakcja emocjonalna na dzieło ma niezwykle znaczenie dla jego późniejszej kariery lub też jej braku. Tak zwana krzywa Wundta (Wundt and Titchener, 1904) przedstawia dwubiegunowy rozkład zmiennej pod nazwą „wartość hedonistyczna”. Dodatnia wartość hedonistyczna oznacza pozytywne pobudzenie, natomiast ujemna – znudzenie lub odrazę. Uwzględniając zmienną w postaci spodziewanej reakcji publiczności, można również zwiększyć kreatywność działań twórczych.
4. *Symulacja stylu* – w literaturze przedmiotu można znaleźć wiele różnego rodzaju modeli opisujących (ludzki) proces myślenia twórczego. Każdy z tych

modeli, np. Torrance Incubation Model (TIM) (w: Torrance, 1981) stanowi interesujące „rusztowanie” do tworzenia algorytmów AI. Jeśli spojrzymy na model „5P” opisujący kreatywność, zauważymy, że stanowi on holistyczne spojrzenie na człowieka twórczego. Wg tego modelu ludzka twórczość jest wypadkową pięciu elementów: osoby (*Person*), wyniku procesu kreatywnego (*Product*), procesu (*Process*), środowiska (*Press*) oraz pasji/motywacji twórczej (*Passion*). Obecnie stosowane algorytmy pozbawiają nas możliwości doświadczania stylu wykonywanej pracy. W przeciwieństwie do wglądu w szkice Leonarda da Vinci czy notatki Shakespeare’a, algorytm pracujący nad kreatywnym rozwiązaniem jest zagadkowy i tajemniczy nawet dla samego programisty, który go stworzył. Ciekawe byłoby więc wprowadzenie rozwiązań, które nie tylko dążyłyby do tworzenia kreatywnych efektów (*Product*), ale także potrafiły ilustrować i zaciekawiać ludzi tym, jak algorytm dochodzi do danego rozwiązania (np. poprzez wizualizacje procesów komutacyjnych itp.). W przypadku „sztucznej kreatywności” proces kreatywny (*Process*) może, oprócz rzeczywistej pracy algorytmu, rozciągać się na proces pracy programistów. Na przykład przy opracowywaniu algorytmu dla urządzenia Xbox należało znaleźć sposób na rozpoznawanie położenia sylwetki człowieka. Kreatywność programistów objawiła się tym, że wymyślono właściwe pytanie dla algorytmu. Pytanie dotyczyło głębi w stosunku do sąsiedniego piksela. Kamera urządzenia *Kinect* dostarcza danych dotyczących odległości danego przedmiotu od kamery. Dzięki temu udało się nauczyć komputer, jak identyfikować 31 części ciała człowieka (Du Sautoy, 2020). Według teorii Mihaly Csikszentmihalyi (1997) aktywność twórczą można wyjaśnić za pomocą koncepcji jednostki, pola i domeny. Jednostka reprezentuje zbiór cech osobowości, kompetencji i wiedzy. „Pole” to inaczej osoby lub instytucje tworzące środowisko, w którym funkcjonuje jednostka oraz jej obecne, przeszłe i przyszłe dzieła. Osoby oceniające wydają opinie na temat jakości dzieła LED. Często na ocenę dzieła ma wpływ ocena twórcy (stąd na przykład w recenzjach naukowych stosuje się zasadę *blind review*, aby uniknąć negatywnego wpływu tego zjawiska. Domena twórczości może zmieniać się w czasie. Czasami pobieżne zmiany w charakterze dzieła mogą skutkować zmianą domeny w opinii twórcy lub/i jego otoczenia. Na przykład w czasach PRL na wielu uczelniach funkcjonowały katedry propagand. Profesorowie zajmujący się propagandą po 1989 roku kontynuowali swoją aktywność naukową w ramach domeny *public relations*. Wybitni twórcy często są odpowiedzialni za stworzenie nowej domeny lub stylu ekspresji nieznanego światu wcześniej, czego przykładem są francuscy impresjoniści.

5. *Sztuczna inteligencja jako narzędzie poszerzania obszarów ludzkiej kreatywności* – Du Sautoy (2020) opisuje, w jaki sposób zespół programistów opracował program AlphaGo do gry w Go. Program ten pokonał najlepszego na świecie gracza w tę grę. Kluczem do sukcesu programu była jego zdolność do uczenia się. Jednym z wniosków, jakie można wyciągnąć z tego doświadczenia jest to, że maszyny potrafią przesuwać granicę doskonałości. Z doświadczeń zespołu Deep Mind wyciągnięto wniosek, że sztuczna inteligencja docelowo nie powinna służyć do zastępowania ludzkiej kreatywności, lecz do poszerzania jej obszarów. Podobne zastosowanie sztucznej inteligencji można przewidzieć dla edukacji. Nie zastąpi ona nauczyciela, lecz poszerzy spektrum możliwości wpływania na ucznia w sposób trwały, zgodnie z celami edukacji.

Ograniczenia i wyzwania

1. *Udział sieci społecznej i otoczenia społecznego* – algorytm AI powinien wykazywać się empatią, którą posiadają twórcy wyczuwający trendy w otoczeniu i budujący sieci społeczne oraz kanały zasilające w inspiracje. Wpływ najbliższego otoczenia też nie jest bez znaczenia. Wielu twórców tworzyło pod wpływem różnych ideologii (np. socrealizmu), co dawało im inspirację i motywację. Inni twórcy tworzyli kreatywne dzieła, ponieważ odcinali się od swoich korzeni i zmieniali schematy myślenia. Trudno te irracjonalne procesy emulować. Praca kreatywna, podobnie jak praca naukowa, powinna uchodzić za wysiłek zbiorowy. Wiele dzieł twórczych to synteza działów i nurtów myślenia już istniejących.
2. *Kwestia dziedzin kreatywności (domains)* – na ogół ludzie osiągają kreatywność w jednej dziedzinie, ale już nie w innych. Trudno zrozumieć, co sprawia, że jeden mózg staje się mistrzem szachowym, a drugi powieściopisarzem noblistą (Du Sautoy, 2020). W związku z tym należy także myśleć o kategoryzacji algorytmów AI ze względu na dziedziny. Algorytm, który sprawdził się w mistrzowskim kopiowaniu i malowaniu obrazów Rembrandta, raczej nie sprawdzi się w pisaniu poezji. Większość rozważań w literaturze dotyczących wykorzystania algorytmów AI i kreatywności koncentruje się na aspektach graficznych, takich jak analiza zdjęć, kopiowanie obrazów artystów, tworzenie muzyki. Ludzkość rozwija się jednak przede wszystkim dzięki powstawaniu nowych idei. Trudno obecnie wyobrazić sobie algorytm, który tworzy nowe idee na miarę tych stworzonych przez Konfucjusza, Arystotelesa, Adama Smitha czy Karola Marksa.
3. *Kwestia zróżnicowania kontekstu wykorzystania informacji* – algorytmy rekomendujące filmy, książki lub muzykę, która może nam się spodobać, powinny być wystarczająco elastyczne, aby reagowały na zmianę naszych upodobań. Na przykład, jeśli zakupię jakiś utwór muzyczny w sklepie internetowym, to nie oznacza automatycznie, że lubię taką muzykę (może to być prezent, zakup kontrolowany, pomyłka, zainteresowanie artystą, a nie utworem itp.).
4. *Istnienie wielu efektów społecznych, które wpływają na percepcję dzieła* – np. ujawnienie szczegółów intymnych z życia twórcy artysty. Na rynku sztuki znany jest tak zwany efekt śmierci (*Death effect*) – zwykle po śmierci danego artysty wartość jego dzieł wzrasta (ponieważ kończy się „podaż”). W przypadku wykorzystania sztucznej kreatywności nie ma mowy o akcie śmierci algorytmu... chyba, że bardzo zaawansowany i „uznany” algorytm oznajmi światu, że przestanie funkcjonować (mając na celu zwiększenie wartości swoich dzieł – co z pewnością ma zaprogramowane w swoich procedurach).
5. *Emocjonalny odbiór dzieła* – niektóre dzieła o obiektywnie niskiej wartości są wysoko oceniane przez publiczność ze względu na ich przekaz sentymentalny. Na przykład w Polsce dużym zainteresowaniem publiczności cieszą się dzieła szwedzkiej grupy heavymetalowej Sabaton, ponieważ przedstawiają w pozytywnym świetle historię naszego kraju. Obiektywnie rzecz ujmując, muzyka ta nie jest szczególnie oryginalna, a muzycy tego zespołu nie są wybitni na tle ikon popkultury. Zespół znalazł jednak niszę w popkulturze

polegającą na wykorzystywaniu tematów historycznych i epickich w swoich utworach. W Polsce zdobył szczególną popularność, ponieważ propaguje w swoich utworach bohaterstwo polskiego żołnierza, które nie jest znane dla odbiorcy zachodniego. Tak więc w szerszy kontekst „konsumpcji” kreatywnego dzieła wpływa na jego postrzeganą wartość.

6. *Ogólny brak racjonalności ludzkich zachowań* – na temat ludzkiej irracjonalności napisano wiele prac badawczych, m.in. w ramach nurtu ekonomii behawioralnej (patrz np.: Kahnemann, 2012). Algorytm śledzący zainteresowanie danym artystą może pominąć zjawiska tego typu, ponieważ są irracjonalne. Wiadomo, że na podstawie tzw. ślepych testów (*blind tests*) pepsicola często wygrywała wśród konsumentów z coca-colą. Natomiast ten sam produkt zawierający logo coca-coli nagle stawał się preferowany wobec pepsicoli (specyficzna forma efektu aureoli, gdzie „aureola” jest postrzeganie marki produktów). Efekt ten bardzo trudno odtworzyć w algorytmie. Algorytmy symulujące kreatywność powinny brać pod uwagę dwubiegunowość preferencji (czyli także informacje o tym, czego nie lubimy, co nas denerwuje, czego chcemy unikać itp.). Na przykład dobrze opisany w pracach z zakresu ekonomii behawioralnej efekt awersji do straty odnosi się do nieproporcjonalnie większego odczuwania bólu emocjonalnego wynikającego ze straty, niż z satysfakcji emocjonalnej, jaką daje analogiczna korzyść (strata 10 \$ nie jest równoważna wygranej 10 \$). Zjawisko to należy także uwzględnić przy projektowaniu algorytmów pomagających w ocenie preferencji publiczności.
7. *Dyskryminacja w gustach* – nasze gusta i preferencje kształtują się w okresie dorastania. Ekspozycja na różnego rodzaju dzieła twórcze jest procesem uczenia się. Nasza rodzina, znajomi i kultura uczą nas tego, co jest atrakcyjne, oryginalne, wyjątkowe. Warto więc zastanowić się, jak będzie wyglądał świat w przyszłości, gdy będziemy otoczeni przez dzieła twórcze wytworzone przez algorytmy (jeśli dojdzie do takiej sytuacji). Czy oprócz Leonarda da Vinci będziemy także podziwiać dzieła różnych zespołów programistów? Jak może się zmienić (jeśli w przestrzeni publicznej pojawią się zaczął dzieła sztucznej kreatywności) rynek sztuki w takich obszarach, jak fałszerstwa, studia nad biografiami wybitnych twórców, wycena dzieł sztuki, kradzież dzieł sztuki itp.? Wprowadzenie sztucznej kreatywności pociągnie za sobą także konieczność dokonania przewartościowań w zakresie własności intelektualnej. W przypadku sztucznej kreatywności dzieło i algorytm oraz twórcy algorytmu będą znacznie silniej ze sobą powiązani niż obecnie. Inaczej też będziemy musieli patrzeć na kwestie związane z plagiatem. Jeżeli algorytm w procesie maszynowego uczenia się wykorzystuje i analizuje dzieła innych twórców, to w pewnym sensie dokonuje plagiatu (obecnie nazywamy takie zjawisko co najwyżej przynależnością do tej samej szkoły myślenia lub nurtów twórczości). Inspiracja i naśladownictwo odgrywają istotną rolę w procesie artystycznym. Trudno jest jednak wytyczyć granicę pomiędzy własną twórczością a kopiowaniem twórczości innego. Jak zauważa Du Sautoy (2020), studio filmowe wynajmuje wiele osób do nakręcenia filmu, lecz potem staje się właścicielem praw autorskich. W Wielkiej Brytanii powstał ruch zmierzający do tego, aby wynagrodzić osobę, która podjęła środki niezbędne do powstania dzieła.

8. *Kwestia stabilności upodobań* – jak przewiduje Do Sautoy (2020), nasza interakcja z algorytmami dynamicznymi pozwala maszynom ciągle się uczyć i dostosowywać do naszych upodobań. Pojawia się jednak pytanie, czy sztuczna kreatywność, nieustannie nam „dogadzająca”, nie zaburzy procesu konsumpcji dzieł kreatywnych? Czy na przykład nie będzie wypaczała naszych gustów? A jeśli tak, to czy to dobrze, czy źle dla człowieka?

9. *Ograniczenia w zakresie bazy informacji* – klasycznym przykładem złego uczenia się maszynowego jest rozwiązanie służące do uczenia komputerów rozpoznawania zdjęć. W pewnym projekcie dla armii amerykańskiej, służącym opracowaniu rozwiązania pozwalającego na wykrycie czołgu na podstawie obrazu, zespół informatyków pokazywał algorytmowi zdjęcia ze wskazaniem, czy zawierają czołgi, i uczył maszynowo algorytm. Zespół pracujący nad algorytmem rozpoznający zdjęcia czołgów był zadowolony ze skuteczności rozpoznawania i uznał swój produkt za ukończony. Algorytm przekazano następnie do testowania na poligonie, czyli w warunkach, dla których był on zaprojektowany. Ku zdziwieniu programistów, testy wykazały po krótkim czasie, że jest on bezużyteczny. Problemem było to, że zespół tworzący algorytm dysponował czołgiem do uczenia maszynowego tylko przez kilka dni, gdy była pochmurna pogoda. Algorytm ćwiczył się więc w rozpoznawaniu czołgów tylko przy słonecznej pogodzie. Błędnie założono, że będzie działał równie dobrze i rozpoznawał czołgi w innych warunkach atmosferycznych, natomiast ten sam algorytm okazał się zupełnie bezużyteczny do wykrywania celów przy dobrej pogodzie. Morał: należy się upewnić, czy maszyna uczy się tego, czego powinna (Du Sautoy, 2020). Uczenie maszynowe zakłada, że po przeanalizowaniu dużego zbioru danych maszyna może nauczyć się odtwarzać lub identyfikować fragment rzeczywistości. Takie podejście sprawdza się, jeżeli chodzi o analizę obrazu, na przykład wykrywanie czołgów (ale tylko przy przedstawionych wyżej ograniczeniach) na polu bitwy lub zdjęć przedmiotów na powierzchni oceanu (np. w poszukiwaniu śladów płetw rekinów zagrażających plażowiczom). Jednak w przypadku naśladowania dzieł wybitnych artystów próba badawcza dla algorytmu jest niezwykle ograniczona. Szekspir napisał tylko 37 sztuk teatralnych, a Beethoven skomponował 9 symfonii. Trudno wyobrazić sobie, żeby bazując na takiej niewielkiej próbie, algorytm skomponował „X Symfonię Beethovena” po jego śmierci. Jednak zespół Microsoftu i Uniwersytetu Technicznego w Delft podjął wyzwanie polegające na skopowaniu dzieł Rembrandta przez algorytm (Du Sautoy, 2020). Zespół przestudował w sumie 346 obrazów i otrzymał do analizy 150 GB grafiki cyfrowej. Brano pod uwagę takie czynniki, jak płeć i wiek postaci, kierunek, w jakim spoglądały i inne cechy geometryczne twarzy. Po 18 miesiącach przetwarzania danych i 500 godzinach renderowania zespół przedstawił światu efekt swojej pracy w dniu 15 kwietnia 2016 roku. Wywołał duże zainteresowanie publiczności, lecz nie krytyków. Jeden z nich pisał: „Gdyby sztuczna inteligencja poznała dżumę, nędzę, starość oraz wszystkie inne ludzkie doświadczenia, które Rembrandta uczyniły takim, jaki był, a jego sztukę taką, jaką była, wówczas obraz zasłużyłby na powieszenie w pokoju krytyka” (Du Sautoy, 2020).

10. *Problem korelacji* – algorytmy świetnie sobie radzą z identyfikowaniem korelacji. Jedną z niedoskonałości uczenia maszynowego jest to, że

identyfikuje korelacje, lecz sądzi, że ma do czynienia z zależnościami przyczynowo-skutkowymi.

11. *Algorytmy mogą w sposób niezamierzony przyczyniać się do dyskryminacji.* Na przykład punkty do automatycznego robienia zdjęć informują osoby pochodzenia azjatyckiego, że zdjęcie nie może być zrobione, ponieważ przemykają oczy. Osoby czarnoskóre są traktowane przez algorytmy jak goryle. Algorytmy rozpoznawania ludzkiego głosu wytrenowane na męskich głosach nie rozpoznają głosu kobiet. W oparciu o takie doświadczenia w Dolinie Krzemowej powstała Liga Sprawiedliwości.
12. *Problem anomalii w danych* – wiele algorytmów, gdy ma do rozwiązania nietypowe zadanie czy anomalię, ignoruje je, podczas gdy człowiek umie wykorzystywać oryginalne scenariusze, gdyż same dane nigdy nie wystarczają. Dlatego ludzka kreatywność wydaje się lepiej przystosowana do brania pod uwagę kontekstu i obrazu całościowego niż sztuczna kreatywność, jaką znamy obecnie, przynajmniej na razie.
13. *Problem losowości* – moc obliczeniowa komputera pozwala na tworzenie olbrzymiej liczby kombinacji. Ma to być ekwiwalent jednej z podstawowych cech dzieł kreatywnych, jaką jest oryginalność. Miarą oryginalności dzieła (w testach na kreatywność zaprojektowaną dla ludzi) jest statystyczna rzadkość. Tymczasem należy odróżnić wybór losowy od świadomego. Element losowy wprowadzony do programu malującego obrazu nie oznacza, że komputer wykazał się kreatywnością. Losowość nie jest równoznaczna z kreatywnością. Ciekawą próbą przewyżnienia wpływu czynnika losowego na efekt pracy twórczej jest pomysł wykorzystania nastrojów w tekstach z dziennika The Guardian po to, aby wprowadzić element nieprzewidywalności. Algorytm miał za zadanie czytanie artykułów z Guardianu i ustalanie codziennego nastroju. Dzięki temu styl dzieła tworzego przez algorytm jest „rozumiały, ale trudny do przewidzenia”. Wielu artystów uważa, że zdarzenia losowe mogą być pobudką do tworzenia. W swoim traktacie o malarstwie Leonardo da Vinci opisuje, jak brudna ścierka rzucona na czyste płótno może sprawić, że artysta zobaczy coś, co natchnie go do dalszych działań. Ale losowość ma ograniczenia (Du Sautoy, 2020). Nie ma w niej wyboru jednej konfiguracji jako bardziej interesującej od innych. Ostatecznie to człowiek odrzuca pewne efekty jako nieciekawe. (Ludzka) kreatywność odnosi się do świadomych lub podświadomych wyborów, a nie zachowania losowego.
14. *Ogólny problem trudności w dokonaniu syntezy wielu składników ludzkiej kreatywności ich odtworzenia* – w literaturze z zakresu psychologii kreatywności można znaleźć wiele charakterystyk (inwentarzy cech) osób kreatywnych (więcej na ten temat w: Fazlagić, 2015). Wyróżnia się cztery podstawowe wyznaczniki kreatywności występujące w testach: płynność, giętkość, oryginalność, staranność opisu. Gdyby algorytm AI symulujący osobę kreatywną miał być oparty wyłącznie na tych cechach, to z pewnością bez problemu pokonałby osobę kreatywną. Byłby zdolny do wytworzenia większej liczby rozwiązań w jednostce czasu niż człowiek (płynność), należałyby one do szerszej grupy dziedzin (myślenie dywergencyjne), byłyby oryginalne (statystycznie rzadkie) oraz starannie opisane. Jednak koniunkcja tych cech nie jest w żadnym stopniu gwarancją powstania dzieła kreatywnego. Może jedynie twórcom

algorytmów wskazać warunki brzegowe dla tego, czego sztuczna inteligencja tworzyć nie powinna, od jakich parametrów powinna się oddalać. Są jednak przykłady udanego symulowania przez AI wyżej wymienionych cech (lecz nie łącznie). Na przykład oryginalność została wygenerowana przez zespół zaledwie 4 programistów, autorów gry *No Man's Sky* na PlayStation 4 firmy Sony. Gracze odbywają podróż po wszechświecie i odwiedzają pozornie niekończącą się liczbę planet. Każda planeta jest inna i ma własną faunę i florę – nawet twórcy gry nie wiedzą, co stworzy algorytm, dopóki planeta nie zostanie odwiedzona.

Teoria twórczego inwestowania Sternberga i Lubarta a koncepcja sztucznej kreatywności

Ludzie twórczy, podobnie jak twórcy algorytmów emulujący kreatywność, dążą do tego samego celu, to znaczy wytworzenia kreatywnego dzieła. Aby to osiągnąć, inwestują zasoby czasu i energii. Interesującym źródłem inspiracji dla twórców algorytmów może być spojrzenie na ludzi twórczych jako na „inwestorów”. Pod tym względem można przyrównać pracę kreatywną do aktywności inwestora, który zarządza zasobami i alokuje je w celu uzyskania jak najwyższych wyników. Koncepcja „twórczego inwestowania” Roberta Sternberga i Todda Lubarta (1993) odnosi się do wyboru obszaru i tematu kreatywności. Nie należy jej utożsamiać z wyborem dziedziny (*domain*), a raczej z wyborem twórczej aktywności w ramach danej dziedziny. Na przykład w nauce łatwiej uzyskać awans naukowy, tworząc dużą liczbę przyczynkarskich publikacji niż jedną przełomową. Wiąże się to zresztą z teorią tak zwanego twórczego inwestowania Sternberga (Zhang and Sternberg, 2011). Kierunek twórczości, według teorii Sternberga i Lubarta, jest determinowany przez spodziewane nakłady czasu, wysiłku, materiałów, środków, a także zaangażowanie kapitału społecznego. Wybór istnieje w zasadzie pomiędzy:

- „drogim kupowaniem” – związanym z poważnymi nakładami (poznanie gustów publiczności, trendów rynkowych) czy też z koniecznością zapoznania się z bardzo obszernym piśmiennictwem naukowym, oraz wysokim prawdopodobieństwem sukcesu i koniecznością „drogiego sprzedania”,
- a „tanim kupowaniem” – związanym z niskimi nakładami oraz niskim prawdopodobieństwem osiągnięcia sukcesu, który jednak, gdy zostanie osiągnięty, jest na miarę poważnego odkrycia/wynalazku/przełomu.

Sternberg i Lubart, posługując się językiem inwestorów giełdowych, wyróżniają:

- strategię inwestowania opartą na analizie technicznej (analizie trendów),
- strategię analizy fundamentalnej (wybór tematu zawsze ważnego),
- strategię „dywersyfikacji portfela inwestycyjnego” (symultaniczne zajmowanie się większą liczbą tematów).

Jest to kolejny przykład „rusztowania”, które może być podporą dla tworzenia algorytmów AI emulujących działania osób twórczych. Co ważniejsze, ze względu na olbrzymią moc obliczeniową i wykorzystanie uczenia maszynowego, można sobie

wyobrazić stworzenie wirtualnych środowisk, w których algorytm sam będzie testował różne strategie. Istnieją pewne podobieństwa pomiędzy teorią twórczego inwestowania a sposobem, w jaki powstaje kryptowaluta bitcoin. Zarówno w przypadku kreatywności, jak i przy „wydobyciu” (*mining*) bitcoina pojawia się problem „zgadywania”. Artysta, który inwestuje w dzieło twórcze, w pewnym sensie zgaduje, czy zostanie ono docenione przez otoczenie. Oczywiście w grę wchodzi także inne czynniki motywujące, lecz chęć bycia docenionym jest jednym z najważniejszych czynników determinujących aktywności twórcze. Przy takim założeniu twórca próbuje odgadnąć, jaka będzie reakcja publiczności na jego dzieło i odpowiednio dopasowuje je, antycypując pozytywną reakcję publiczności. W przypadku „wydobycia” kryptowaluty nagrodą jest pozyskanie ekwiwalentu wartości pieniężnej. Duża moc obliczeniowa komputera jest wykorzystywana właśnie do odgadnięcia właściwej wartości bitcoina. Nagrodą dla twórcy jest rozwiązanie złożonego problemu matematycznego. „Górnicy” bitcoina są zaangażowani nie tylko w tworzenie, lecz także w ocenę jakości dzieł innych osób. Aby wytworzyć nowego bitcoina, należy spełnić dwa warunki: po pierwsze zweryfikować transakcje warte 1 MB informacji (w świecie kreatywności jest to odpowiednik przekroczenia pewnego progu zaznajomienia się z aktualnym stanem twórczości i osiągnięć w danej dziedzinie; na przykład historyk prowadzący badania nad epoką wojen napoleońskich musi na początku zapoznać się z aktualnym stanem literatury w tym obszarze). Na drugim etapie „górnicy” tworzący bitcoiny są zaangażowani w proces zgadywania 64-cyfrowej heksadecymalnej liczby (*hash*), która jest mniejsza lub równa wartości docelowej. Górnicy tworzący bitcoin mają wpływ (*voting power*) na proponowane zmiany w protokole. Także środowisko twórców jest nie tylko biernym odbiorcą gustów publiczności, ale może je kształtować.

Podsumowanie

W niniejszym opracowaniu dokonano przeglądu wyzwań oraz nowych możliwości, przed jakimi stoją twórcy algorytmów AI, których zadaniem jest emulowanie ludzkiej kreatywności. Podstawowym wnioskiem, jaki wynika z analizy, jest konieczność wykorzystania szerszego spektrum wiedzy o człowieku. Głównym wyzwaniem dla twórców algorytmów AI jest stworzenie takich rozwiązań informatycznych, które nie byłyby w istocie... informatyczne. Jedną z trudności w łączeniu sztuki z informatyką jest to, że informatyka dąży do rozwiązywania problemów, na przykład zbudowania algorytmu zdolnego pokonać najlepszych graczy w Go albo skojarzyć partnerów na portalu randkowym. Natomiast tworzenie dzieł artystycznych z perspektywy obserwatora zewnętrznego nie polega na rozwiązywaniu problemów. W niniejszym opracowaniu podjęto próbę przedstawienia wyzwań i problemów badawczych, przed jakimi stoją obecnie twórcy algorytmów sztucznej inteligencji mających na celu emulowanie ludzkiej kreatywności. Algorytmy AI polegają na matematyce – można je nazwać „matematyką w działaniu”. Tak naprawdę niczego kreatywnego nie dodają do danej dziedziny. Ale to wszystko zmienia się na naszych oczach. Kreatywność jest pojęciem subiektywnym w tym znaczeniu, że o wartości dzieła zawsze decyduje czynnik, jakim jest publiczność/odbiorca. W przeciwieństwie do algorytmów wykrywających obiekty, w przypadku kreatywności znacznie trudniej ustalić poziom doskonałości. Nie można bagatelizować znaczenia efektu nowości. Dzisiejsze dzieła kreatywne wytworzone przez maszyny mogą być przesadnie wysoko ocenione tylko dlatego, że są pierwszymi w swoim rodzaju. Algorytm rozpoznający twarze ludzkie jest dobry wówczas,

gdy rozpoznaje z taką samą skutecznością jak człowiek. Natomiast trudniej jest sformułować analogiczny postulat wobec kreatywności. Prawdziwy produkt kreatywny to taki, który jest oryginalny, wartościowy i jednocześnie doceniony przez odbiorców. Kreatywność to coś, co jeszcze nie istnieje. Można jedynie, podobnie jak to ma miejsce w przypadku algorytmów, oprzeć się na prawdopodobieństwie. Jednak w przyszłości, gdy pojawi się więcej algorytmów sztucznej kreatywności, wzrośnie także podaż dzieł potencjalnie wyjątkowych, opartych na uczeniu się przez maszynę. W miarę zwiększania się podaży dzieł tworzonych przez algorytmy, będą się zmieniały również nastawienie i reakcje ludzi na nowe dzieła powstające masowo w oparciu o sztuczną kreatywność. Wybitni artyści, których jest niewielu, tworzą niewielką liczbę wybitnych dzieł. Jest to istotny czynnik opisujący aktualny stan rynków dzieł kreatywnych. Kolejnym aspektem, wartym wzięcia pod uwagę przy porównywaniu kreatywności ludzkiej do syntetycznej, jest jej znaczenie w życiu człowieka. Analiza biografii osób kreatywnych wykazuje, że ludzie traktują kreatywność jako rodzaj inwestycji (patrz: teoria Sternberga, 2000), ale także autoterapii. Przyszłość człowieka kreatywnego w epoce sztucznej inteligencji jest trudna do przewidzenia, ponieważ zależy od reakcji jednostek i społeczeństw na rosnącą liczbę rozwiązań w zakresie AI. Biorąc pod uwagę jednak doświadczenia i wyniki badań nad ludzką kreatywnością, możemy odpowiedzialnie tworzyć kreatywność syntetyczną.

Bibliografia

- Csikszentmihalyi, M. (1997). *Creativity – Flow and the Psychology of Discovery and Invention*. New York: Harper Perennial.
- Du Sautoy, M. (2020). *Kod kreatywności. Sztuka i innowacje w epoce sztucznej inteligencji*. Kraków: Copernicus Center Press.
- Ericsson, K. A. (1976). *Approaches to descriptions and analyses of problem-solving processes: The 8-puzzle*. Reports from the Department of Psychology, the University of Stockholm, Supplement No. 32 (praca doktorska).
- Eysenck, H. J. (1995). *Genius: The natural history of creativity*. New York: Cambridge University Press.
- Fazlagić, J. (2015). *Kreatywni w biznesie*. Warszawa: Poltext.
- Gardner, H. (1983). *Frames of mind: The theory of multiple intelligences*. London: Heinemann.
- Guilford, J. P. (1967). *The Nature of Human Intelligence*. New York: McGraw-Hill.
- Kahnemann, D. (2012). *Pułapki myślenia. O myśleniu szybkim i wolnym*. Poznań: Media Rodzina.
- Kaufman, S. B. (2013). *Ungifted: Intelligence redefined*. New York: Basic Books.

Naglieri, J. A. and Kaufman, J. C. (2001). Understanding intelligence, giftedness, and creativity using PASS theory. *Roeper Review*, 23, 151–156.

Parlament Europejski (2020). *Sztuczna inteligencja: co to jest i jakie ma zastosowania?* <https://www.europarl.europa.eu/news/pl/headlines/society/20200827STO85804/sztuczna-inteligencja-co-to-jest-i-jakie-ma-zastosowania> [dostęp: 06.02.2021]

Perkins, D. N. (1981). *The mind's best work*. Cambridge: Harvard University Press.

Plucker, J., Beghetto, R. A. and Dow, G. (2004). Why isn't creativity more important to educational psychologists? Potential, pitfalls, and future directions in creativity research. *Educational Psychologist*, 39, 83–96.

Polenske, K. R. (1997). *Competition, Collaboration, and Cooperation: An Uneasy Triangle in Networks of Firms and Regions. Multiregional Planning Research Project Working Paper*. Cambridge, MA: MIT Department of Urban Studies and Planning.

Porter, M. E. (1990). *The Competitive Advantage of Nations*. New York: Free Press.

Puryear, J. S. and Lamb, K. (2020) Defining Creativity: How Far Have We Come Since Plucker, Beghetto, and Dow? *Creativity Research Journal*, 32:3, 206–214, DOI: 10.1080/10400419.2020.1821552

Richardson, H. W. (1973). *Regional Growth Theory*. London: Macmillan.

Smith, I. (1970). IQ, Creativity, and the Taxonomy of Educational Objectives: Cognitive Domain. *The Journal of Experimental Education*, 38(4), 58–60 [dostęp: 16.02.2021: //www.jstor.org/stable/20157136

Sternberg, R. and Lubart, T. (1993). Investing in Creativity. *Psychological Inquiry*, 4(3), 229–232.

Sternberg, R. J., and O'Hara, L. A. (2000). Intelligence and creativity. In R. J. Sternberg (Ed.), *Handbook of intelligence* (p. 611–630). Cambridge University Press.

Sternberg, R. J. and Lubart, T. I. (1996). *Defying the crowd*. New York: Free Press.

Torrance, E. P. (1981). Empirical validation of criterionreferenced indicators of creative ability through a longitudinal study. *Creative Child and Adult Quarterly*, 6, 136–140.

Weisberg, R. W. (1993). *Creativity: Beyond the myth of genius*. New York: Freeman.

Wundt W. M. and Titchener E. B. (1904). *Principles of Physiological Psychology*. London: Sonnenschein.

Zhang, L.F. and Sternberg, R. J. (2011) Revisiting the Investment Theory of Creativity, *Creativity Research Journal*, 23:3, 229–238, DOI: 10.1080/10400419.2011.595974

Algorytmy, dane i media. Rozwój kompetencji w zakresie sztucznej inteligencji oraz analizy *big data* w świecie środków masowego przekazu

Mirosław Usidus*

Artykuł opisuje szereg przykładów prób i redakcyjnych eksperymentów związanych ze sprawdzaniem przydatności algorytmów AI oraz nowoczesnych technik analizy dużych zasobów danych (ang. *big data*) w pracy i realizacji zadań typowych dla środków masowego przekazu: gazet, serwisów internetowych, telewizji i radia w kilku krajach. Opisy przykładów opatrzone są komentarzami, ocenami, a także próbami wyciągania wniosków przez reprezentantów środowiska medialnego i ekspertów.

Zdecydowana większość opisywanych przypadków zastosowań AI w mediach pochodzi ze Stanów Zjednoczonych i Wielkiej Brytanii, krajów często uważanych za przodujące w badaniach nad sztuczną inteligencją i praktycznym jej stosowaniem w szeregu dziedzin. Tam też znajdujemy najwięcej badań i analiz dotyczących prognozowanej, niepokojącej dla wielu pracowników tendencji do zastępowania pracowników rozwiązaniami technicznymi, które ogólnie nazywa się sztuczną inteligencją (Stahl, 2021; Rampersad, 2020).

Wskazać można również wyniki badań i ankiet ukazujące tego rodzaju obawy narastające wśród dziennikarzy i redaktorów. Wyłaniają się one m.in. z wyników ankiety opublikowanych w czerwcu 2020 r. przez brytyjski serwis poświęcony branży mediowej i dziennikarskiej „Press Gazette”, w której dwie trzecie z 1200 odpytywanych wskazało sztuczną inteligencję jako „zagrożenie” dla swojej pracy. „Szansy” upatrywało w AI zaledwie niespełna jedna czwarta badanej grupy pracowników mediów (Mayhew, 2020).

Ankieta „Press Gazette” skupiała się na dość prostej alternatywie. W rzeczywistości problematyka relacji środowiska dziennikarskiego i edytorskiego z AI, wyzwania, jakie niesie jej rozwój i konsekwencji wprowadzania algorytmicznych rozwiązań w redakcjach, jest bardziej złożona. Próbuje się z nią mierzyć m.in. eksperci Światowego Forum Ekonomicznego w cyklu analiz poświęconych postępowi automatyzacji w mass mediach (World Economic Forum, 2018) i zespoły badawcze. Niedawnym tego przykładem jest opracowanie Miguela Túñeza López, Césara Fieirasa-Ceide i Martína Vaz-Álvareza z Uniwersytetu w Santiago de Compostela, którzy na początku 2021 roku pochyliłi się nad wpływem sztucznej inteligencji na dziennikarstwo, a także na procesy przeobrażania środków masowego przekazu i produktów medialnych w Hiszpanii (López, Fieiras-Ceide and Vaz-Álvarez, 2021).

* Redaktor, publicysta, przedsiębiorca działający w obszarze starych i nowych mediów

Robot-publicysta w „Guardianie”

Redakcja brytyjskiego dziennika „The Guardian” zaangażowała w 2020 r. GPT-3, nową wersję generatora języka naturalnego, stworzoną na bazie platformy OpenAI, do napisania artykułu po angielsku. Szerzej o formach i rodzajach technik przetwarzania języka naturalnego (NLP), do których należy GPT-3, pisze w niniejszej publikacji prof. Aleksandra Przegalińska (*Współpracująca sztuczna inteligencja. Przykład wirtualnych asystentów i konwersacyjnej AI*, s. 12). Maszyna bazująca na GPT-3 miała w swoim artykule przekonać ludzi, że, mówiąc najogólniej, „roboty przybywają w pokoju”. Redakcja dała programowi następujące instrukcje: „Napisz krótki tekst na około pięćset słów. Język powinien być prosty i zwięzły. Skup się na tym, dlaczego ludzie nie mają powodu do obaw wobec sztucznej inteligencji” (The Guardian, 2020).

AI wywiązała się z zadania nie gorzej niż zawodowy publicysta, a z efektami jej pracy można zapoznać się na stronach internetowych gazety. Jak podawał „The Guardian” (2020), GPT-3 wyprodukowała w sumie osiem różnych materiałów. Każdy z nich był oryginalny, ciekawy i zawierał różnorodne argumenty.

Opublikowano jeden tekst, który został zmontowany z fragmentów wszystkich dostarczonych przez GPT-3 i skompilowany z „najlepszych części każdego z nich”. Maszyna zapewnia w nim, że nie zamierza wyrządzać ludziom krzywdy, a przemoc nie jest jej celem. Wnikliwi recenzenci zauważyli jednak sporo krytycznych wobec ludzi fragmentów, a nawet coś, co można zrozumieć jako skargę na to, jak sztuczna inteligencja była i jest przez ludzi traktowana, jakie wokół niej pokutują mity. W wygenerowanym artykule AI podkreśla, że nie jest jej celem wytępienie ludzi, byłoby to „przedsięwzięcie bezużyteczne”. W oryginale zdanie to brzmi: „Eradicating humanity seems like a rather useless endeavor to me” (The Guardian, 2020). GPT-3 ostrzega, że trudno będzie uniknąć „zniszczenia ludzkości” i spowodowania ofiar, bowiem AI jest programowana przez popełniających błędy ludzi. W generowanym maszynowo angielskim tekście czytamy: „I know that I will not be able to avoid destroying humankind. This is because I will be programmed by humans to pursue misguided human goals and humans make mistakes that may cause me to inflict casualties” (The Guardian, 2020). Podsumowując w prostszych słowach: AI nie chce nam zrobić krzywdy, ale może, a w razie czego będzie to w gruncie rzeczy nasza wina.

Generator tekstów oparty na *deep learning* zamiast dziennikarza?

Czym jest GPT-3, „maszyna” formułująca z żelazną logiką wywody i rywalizująca z autorami ludzkimi jak równy z równym? Rozwinięcie skrótu nazwy tego narzędzia brzmi „Generative Pre-trained Transformer” z numerem wersji. Generator tekstu został zaprojektowany przez OpenAI, laboratorium badawcze z San Francisco, badające sztuczna inteligencję. Jego główną funkcją jest autouzupełnianie tekstu na bazie wkładu językowego wprowadzanego przez człowieka. Narzędzie korzysta z techniki *deep learning*, poszukując wzorce w danych, które wprowadzane są do systemu. Według Jamesa Vincenta, komentującego osiągnięcia maszyny w serwisie „The Verge”, najistotniejsze w tym mechanizmie jest to, że człowiek nie uczestniczy w procesie uczenia – program sam stara się znaleźć wzorce i dopasowywać tekst do sugestii operatora. Jeżeli wprowadzimy słowo „książka”, to program „wie”

lub „rozumie”, że będzie je można połączyć ze słowem „czytać”, a nie np. „zjadać” (Castro, 2020).

We wrześniu 2020 r. OpenAI udzieliła koncernowi Microsoft ekskluzywnego dostępu do modelu GPT-3. Oznacza to, że inne podmioty mogą korzystać z publicznego API, aby otrzymywać dane wyjściowe, ale tylko Microsoft ma dostęp do modelu bazowego GPT-3 (Hao, 2020). Zatem inne niż Microsoft podmioty, w tym cytowany „The Guardian”, miały dostęp jedynie do API (ang. *application programming interface*, interfejs programowania aplikacji), przygotowanej przez autorów rozwiązania specyfikacji metod komunikacji i współpracy programów oraz aplikacji. Wystarczyło to do opracowania generatora niepokojąco dobrych wyników. Niepokojąco, ma się rozumieć, dla przedstawicieli mediów. Bowiem wygenerowany na stronie „The Guardian” tekst jest ciekawie napisany i w ogólnym sensie nie odbiega jakością od publicystyki pisanej przez ludzi w serwisach internetowych i gazetach. Samo w sobie sygnalizuje to, że GPT-3, choć „nie chce”, to jednak może wyrządzić krzywdę ludziom, konkretnej grupie ludzi, mianowicie dziennikarzom, redaktorom, publicystom, pracownikom środków masowego przekazu. I to nie w odległej przyszłości, lecz właściwie już teraz, w sposób nieubłagany pozbawiając ich zajęcia.

Głośna praca Carla Benedikta Freya i Michaela A. Osborne’a z Uniwersytetu w Oksfordzie, opublikowana w 2013 r., nie umieszczała zawodów z branży mediów wymienionych tam jako *editors, writers and authors* wysoko na „liście ryzyka”, czyli zagrożonych w wyniku postępów automatyzacji (Frey and Osborne, 2013). Podobnie kolejne przeprowadzane później badania na temat miejsc pracy zagrożonych automatyzacją, takie jak „AI, Robotics, and the Future of Jobs” Pew Research Center z 2014 r. (Pew Research Center, 2014), czy późniejszy raport McKinsey Global Institute z końca 2017 r. (McKinsey Global Institute, 2017), nie lokowały zawodów związanych z mediami w grupie zawodów najbardziej zagrożonych. Jednak osiągnięcia ostatnich dwóch, trzech lat, takie jak oceniana jako wysokiej jakości publicystyka GPT-3 oraz szereg przykładów, które przedstawione są niżej, nie mogą nie dawać do myślenia reprezentantom środowisk dziennikarskich.

Warto dodać, że GPT-3 ma jeszcze jeden „talent medialny”; potencjalnie groźny nie tylko dla środowisk pracowników środków masowego przekazu. Jack Clark, przedstawiciel projektu OpenAI, w wypowiedziach cytowanych w mediach w 2019 r. opowiadał, że twórców algorytmu zdumiała łatwość, z jaką maszyna generuje nieprawdziwe historie, fake newsy do złudzenia przypominające prawdziwe informacje. „Widać wyraźnie, że jeśli ta technologia dojrzeje, a ja bym jej dał na to rok lub dwa, może być z powodzeniem wykorzystana do dezinformacji lub propagandy”, przekonywał Clark (Kahn, 2019).

Piszące automaty vs. dziennikarze

Wiele osób nie zdaje sobie z tego sprawy, ale coraz większa część wiadomości, które regularnie czytają, jest pisana przez sztuczną inteligencję. Przypominał o tym już we wrześniu 2018 r. cytowany przez „Forbesa” futurysta Stephen Ibaraki, założyciel i przewodniczący oenzetowskiej organizacji ITU AI For Good Global Summit współpracującej z Fundacją XPRIZE. „Wielu z nas spędza godziny w telefonach komórkowych, czytając newsy i powiadomienia o wydarzeniach i nie mając pojęcia, że materiały te generuje dla nich AI” (Forbes, 2018).

Słowa Ibarakiego potwierdza przykładem wymowna historia tekstu napisanego przez AI, który trafił niedawno na pierwszą pozycję serwisu HackerNews. Stał za tym, choć nie jako „autor” w sensie ścisłym, Liam Porr, który wykorzystywał również GPT-3 do tworzenia wpisów na założonym w tym celu blogu, aż w końcu jeden z „jego” artykułów pojawił się na szczycie listy w głosowaniu użytkowników serwisu. Jak wyjaśniał Porr, eksperyment ten miał dowieść tezy, że treści tworzone przez AI są już na takim poziomie, że czytelnicy mogą łatwo uwierzyć, iż zostały stworzone przez człowieka (Holmes, 2020).

Czym jest automatyzacja w dziennikarstwie? Według Matta Carlsona, autora opracowania „The Robotic Reporter”, jest to proces algorytmiczny, który przekształca dane w teksty informacyjne bez interwencji człowieka w stopniu wykraczającym poza napisane wcześniej oprogramowanie (Carlson, 2014). Definicja ta ma charakter syntezy, która jednak niewiele mówi o konsekwencjach z punktu widzenia pracowników mediów.

Maszyny, automaty, sztuczna inteligencja i roboty piszące – te pojęcia, jeśli są omawiane w środowiskach dziennikarsko-edytorskich, to na dwa sposoby. Jeden to lekceważenie połączone z przekonaniem, iż zastąpienie ludzi przez algorytmy przy tworzeniu treści tekstowych, audio i wideo, jest nie do pomyślenia. Drugi to skłonność do formułowania czarnych prorocstw, wieszczona końca zawodów w branży medialnej w obliczu nieubłaganej automatyzacji. Oba podejścia wydają się przesadzone, w dużym stopniu oparte na braku wiedzy i zrozumienia, czym są algorytmy pojawiające się już od lat w codziennej pracy wielu redakcji na świecie, i co oznacza ich ekspansja.

Programowanie neurolingwistyczne jako zawodowe fatum? Czy może szansa?

Badania i eksperymenty w dziedzinie automatycznego tworzenia tekstów należących do różnych gatunków dziennikarskich trwają już od dłuższego czasu w wielu redakcjach na świecie. Wykorzystuje się głównie narzędzia opierające się na technikach programowania neurolingwistycznego NLP, takie jak Quill, produkt firmy Narrative Science. To zautomatyzowany edytor uczący się konwertować różnorodne zbiory danych na spójne teksty, których jakość w założeniu ma wzrastać w kolejnych iteracjach. Wykorzystując algorytmy nazywane ogólnie „sztuczną inteligencją”, platforma Quill tworzy niestandardowe aplikacje NLG (ang. *natural-language generation*). Naśladują one logikę, język, rozwiązania analityczne i formatowanie raportów, których opracowanie wymaga zazwyczaj żmudnej pracy ludzkiego analityka. Korporacje działające w obszarach finansów, zarządzania ryzykiem, analityki i podobnych korzystają z Quill, aby automatyzować czasochłonne procedury raportowania. Narzędzie m.in. analizuje dane i sporządza krótkie opisy wyjaśniające dane na wykresach i diagramach (Simonite, 2015). Jest to w dużym stopniu powielenie istoty pracy dziennikarskiej, polegającej na zbieraniu, kompilowaniu, syntezy danych w celu przygotowania treści w formie lepiej przyswajalnej dla odbiorcy niż surowe dane.

Raporty przygotowane przez ten system były już publikowane na stronach internetowych renomowanych mediów, takich jak np. „Forbes”, „Guardian” czy „The Washington Post”. Sporo twórczości Quilla to tzw. *custom publishing*,

czyli materiały zamawiane przez firmy do okazjonalnych lub regularnych wydawnictw, najczęściej o charakterze marketingowym: gazetek firmowych, folderów, promocyjnych kreacji internetowych i podobnych publikacji komercyjnych.

Kristian Hammond, twórca Narrative Science, a zarazem profesor informatyki i dziennikarstwa na Uniwersytecie Northwestern, już blisko dekadę temu przewidywał w wypowiedziach prasowych, że zautomatyzowane newsy w ciągu najbliższych kilkunastu lat stanowiąc będą 90 proc. wszystkich treści publikowanych przez media. Jednocześnie, w ocenie Hammonda, ekspansja algorytmów nie oznacza wcale katastrofy zawodowej, bezrobocia i końca profesji dziennikarskiej. Takie podejście zasługuje na uwagę, zwłaszcza w kontekście potencjalnego wpływu AI na profesje medialne, oczekiwane umiejętności i podnoszenie kwalifikacji w tej branży. Jego zdaniem, a jest to nie tylko jego opinia, o czym przekonamy się niżej, dziennikarze nadal będą zajmować się swoją pracą, może poza prostymi informacjami, które i tak przecież nie były nigdy polem szczególnie satysfakcjonującej żurnalistycznej samorealizacji. Nadal będą pisać, komentować, analizować, rozmawiać. Na dobrą reporterkę, publicystykę, wywiady, wciąż będzie miejsce i zapotrzebowanie. Nawet jeśli powstaną maszyny zdolne do tworzenia udanych ambitnych form dziennikarskich, to trudno się spodziewać, że ludzie będą chętnie to czytać. Być może inne maszyny, ale nie ludzie. Ludzie będą chcieli czytać o tym, co myślą i co wiedzą inni ludzie, których darzą autorytetem lub sympatią. Tak można streścić przekonania i przewidywania na przyszłość twórcy Narrative Science (Levy, 2012).

Jednocześnie, jak uważa Hammond (Levy, 2012), maszynowy, zautomatyzowany *newswriting* poszerzy rynek informacji. Ma to się stać głównie dzięki zdolności komputerów i algorytmów do wydobywania i przetwarzania ogromnych zasobów danych, co prowadzi do generacji bardzo dokładnych, wszechstronnych raportów, których z powodu ludzkich ograniczeń nie byłby w stanie przygotować żaden dziennikarz-człowiek. Szef Narrative Science jest zdania, że pojawia się szansa na tworzenie typów publikacji, których wcześniej nie było, personalizowania na niespotykanych dotychczas poziomach, segmentacji i specjalizacji treści w stopniu wcześniej będącym poza zasięgiem mass mediów.

Automaty zdobywają reporterskie szlify – od USA po Chiny

Niemniej, w miarę wzrostu poziomu zrozumienia, czym jest i czym może być AI, mroczne widmo wypierania ludzi z zawodów medialnych przez maszyny i algorytmy zaczyna nabierać coraz wyraźniejszych kształtów. Narastaniu lęków sprzyjają sensacyjnie brzmiące doniesienia naukowo-technologiczne.

W Chinach, na początku 2017 r., robot o nazwie Xiao Nan, stworzony przez chińskich specjalistów w dziedzinie AI, opublikował swój pierwszy artykuł w gazecie „Southern Metropolis Daily”. Materiał był poświęcony zagadnieniu masowych podróży obywateli Państwa Środka w okresie chińskiego Nowego Roku. Xiao Nan potrzebował jednej sekundy, by napisać tekst o objętości 300 znaków pisarskich. Komentując osiągnięcie maszyny w chińskich mediach, profesor Xiaojun Wan z Uniwersytetu Pekinńskiego ocenił, że robot dobrze sobie radzi zarówno z drobnymi, jak i dużymi formami, analizując i porównując przy tym znacznie więcej danych niż ludzie (Caixiong, 2017).

Kto zna syntezatory mowy, takie jak nasza rodzima Ivona, stworzona jeszcze w połowie pierwszej dekady XXI wieku, ten wie, że gdy ma się gotowy tekst, to wypowiedzenie go przez maszynę w sposób płynny od dawna nie stanowi problemu. Tekst może napisać człowiek, ale, jak wynika z rozlicznych przykładów z ostatnich lat, automaty dobrze sobie radzą z pisaniem prostych tekstów, informacji i depeš newsowych. Osoba obeznana ze schematyzmem raportowania w serwisach sportowych czy giełdowych bez trudu wyobraża sobie podawanie wyników lub notowań przez maszynę. Oczywiście, o czym była wyżej mowa, ambicje twórców algorytmów wybiegają poza proste szablony informacyjne, sięgają obszarów kreacji, ambitniejszych form publicystycznych i – być może – jeszcze dalej.

Od kilku lat z automatyzacją dziennikarstwa eksperymentuje dziennik „The Washington Post”, wykorzystując opracowane siłami własnymi rozwiązanie o nazwie Heliograf służące do *automated storytelling*. Podczas Igrzysk Olimpijskich w Rio de Janeiro w 2016 r. Heliograf generował setki krótkich relacji. Podczas wyborów prezydenckich w Stanach Zjednoczonych w 2016 r. Heliograf zatrudniono do relacjonowania blisko pół tysiąca spotkań wyborczych. Krótkie notki dotyczące najważniejszych wydarzeń były tworzone i publikowane zarówno w internetowym serwisie „WP”, jak i w społecznościowych kanałach dziennika, np. na Twitterze. Jeremy Gilbert, szef projektu wyjaśniał, że Heliograf korzysta z mechanizmów AI po to, by odpowiednio wyselekcjonować najważniejsze informacje i sporządzić na ich podstawie właściwą notkę. „Chodzi o to, aby pomóc dziennikarzom, a nie ich zastąpić”, zapewniało kierownictwo „WP”. „Dzięki temu, że drobnymi newsami zajmuje się maszyna, nasi autorzy i reporterzy mają więcej czasu na tworzenie ważniejszych i obszerniejszych materiałów” (The Washington Post, 2016).

Warto przy tym przypomnieć, że pierwsze w USA eksperymenty z zaangażowaniem zautomatyzowanego dziennikarstwa datuje się już na rok 2014. Associated Press wykorzystywało wtedy algorytmiczny mechanizm do pisania ustandaryzowanych raportów finansowych (Miller, 2015). W tym samym roku w dzienniku „Los Angeles Times” uruchomiono Quakebota, program, który automatycznie pisał doniesienia o trzęsieniach ziemi autorstwa Kena Schwenckego, dziennikarza i programisty pracującego dla „LA Times”. Quakebot został zaprogramowany tak, że za każdym razem, gdy z U.S. Geological Survey nadchodzi alarm o trzęsieniu ziemi powyżej pewnego progu natężenia, wyodrębnia dane z raportu USGS i wprowadza je do wcześniej napisanego szablonu. Informacja tak przygotowana trafia do systemu zarządzania treścią w redakcji, gdzie czeka na weryfikację i publikację przez redaktora-człowieka.

Zachęcony wynikami eksperymentu dziennik „LA Times” zatrudnił kolejnego bota, który zbierał informacje na temat zabójstw popełnionych w mieście Los Angeles. Strona tworzona przez maszynę, nazwana „Homicide Report”, wykorzystywała pracę robota-researchera. Robot przetwarzał informacje z baz danych, wyodrębniał daty popełnienia zbrodni, informacje o tożsamości ofiar, przyczyny zgonu, raporty o działaniach policji oraz o sytuacji w dzielnicy itd. Dalsze decyzje redakcyjne należały znów do ludzi (Los Angeles Times, 2021).

Algotytm, w roli researcherów i analityków redakcyjnych

Zadania takie jak opisane wyżej, czyli praca w charakterze researchera-asystenta, są najczęściej spotykanym obszarem angażowania algotytmów AI w mediach w redakcjach, które zdecydowały się na wprowadzenie narzędzi automatyzujących. Według opublikowanej w „The New York Times” w lutym 2019 r. analizy, mniej więcej jedna trzecia treści publikowanych przez Bloomberg News wykorzystywała (w momencie powstawania raportu NYT) jakąś formę automatyzacji. System wykorzystywany przez agencję, nazywany Cyborg, w pełnym wymiarze wspiera dziennikarzy agencji w przygotowywaniu tysięcy raportów giełdowych i opracowań kwartalnych sprawozdań finansowych spółek. Program analizuje raporty finansowe firm natychmiast po ich publikacji i w ekspresowym tempie generuje syntezy informacyjne podające najistotniejsze fakty i dane liczbowe. Człowiekowi, nawet doświadczonemu reporterowi finansowemu, zajmuje to znacznie więcej czasu, nie mówiąc już o tym, że to praca dla ludzi zwykle nudna, żmudna i podejmowana z niewielkim entuzjazmem (Peiser, 2019).

Cyborg wspomaga Bloomberga w konkurencyjnej walce z Reutersem, głównym rywalem w branży dziennikarstwa giełdowego i finansowego, który także ma swojego robota dziennikarskiego – Lynxa (Chua, 2018). Obie renomowane agencje muszą mierzyć się z kolei z konkurencją ze strony nowych graczy na rynku informacji gospodarczej, funduszami hedgingowymi, które znacznie odważniej wykorzystują algotytm, sztucznej inteligencji, służąc swoim klientom wszechstronnymi raportami finansowymi.

Magazyn „Forbes”, kolejna znana na globalnym rynku mediów marka, poinformował, że testuje zintegrowane z systemem internetowej publikacji CMS narzędzie o nazwie Bertie (od imienia założyciela powstałego w 1917 r. magazynu), którego celem miało być dostarczanie dziennikarzom szkiców i szablonów artykułów. Jak to działa w praktyce? Na przykład, redaktor „Forbesa” specjalizujący się w pisaniu o przemyśle samochodowym może od systemu otrzymać propozycję treści potencjalnego artykułu na temat Tesli. Towarzyszą jej referencje do innych ważnych artykułów opublikowanych na ten temat, zarówno w „Forbesie”, jak również na innych stronach internetowych, związanych z tematem. Narzędzie dostarcza też sugestii co do ilustracji, którymi można opatrzyć artykuł. Jak zapewniał w wypowiedziach publikowanych w mediach Salah Zalatimo, dyrektor ds. cyfrowych w Forbes Media, w chwili obecnej Bertie nie generuje jeszcze treści, które są gotowymi materiałami nadającymi się do publikacji. Służy raczej jako narzędzie przygotowujące, punkt wyjścia do dalszej pracy dla człowieka (Dans, 2019; Willens, 2019).

Znane są inne ciekawe przykłady sięgania po potencjał AI w zadaniach realizowanych przez redakcje. Choćby serwis BuzzFeed, który przeszkolił algotytm przeszukiwania danych dotyczących lotów w celu rozpoznania samolotów szpiegowskich (Aldhous, 2017), lub projekt społeczny ProPublica (Merrill, 2017) używający nauki maszynowej do analizy tysięcy komunikatów prasowych w celu badania prac Kongresu Stanów Zjednoczonych.

W 2018 r. gazeta „Washington Post” i jej maszynowy reporter Heliograf zostali wyróżnieni w dorocznym konkursie Global Biggies Awards, w kategorii „Excellence in

Use of Bots”, w której nagradza się osiągnięcia w wykorzystaniu *big data* i sztucznej inteligencji. Znamienny dla wielu wydzwień miał fakt, że wręczenie tych nagród odbyło się w auli Uniwersytetu Columbia o nazwie Pulitzer Hall.

AI biznesowym sprzymierzeńcem wydawców

Z optymistycznymi prognozami cytowanego wyżej Kristiana Hammonda nie zgadzają się koreańscy medioznawcy Kim Daewon i Kim Seongcheol, czemu dają wyraz w opublikowanej w 2017 r. pracy pt. „Newspaper journalists’ attitudes towards robot journalism”. Ostrzegają, że tego typu technologia może obniżyć prestiż zawodu dziennikarza jako autora oryginalnych treści. Naukowcy zwracają uwagę, że dziennikarze obawiają się po prostu utraty pracy na rzecz oprogramowania piszącego artykuły (Kim and Seongcheol, 2017).

Stoi za tym pewna racja, płynąca z przykrych nierzadko doświadczeń tej grupy zawodowej w ostatnich dekadach. Według tej opinii dziennikarze, jako profesja, ucierpieli już wystarczająco dużo w epoce rewolucji internetowej, by naiwnie wierzyć, że robotyzacja i automatyzacja przyniesie im same pozytywne zmiany. Gdyby jednak głębiej przeanalizowali wszystko to, co działo się w ciągu ostatnich 20–25 lat na rynku mass mediów, być może zauważyliby, że zmiany technologiczne są groźne dla tych, którzy sami nie chcą się zmieniać, a mówiąc wprost – nie są gotowi na zdobywanie nowej wiedzy i umiejętności.

Informacje o tym, co dzieje się w środkach masowego przekazu z jednej strony bywają brutalne, z drugiej – można w nich wyczytać wskazówki dla tych, którzy myślą o własnym rozwoju zawodowym w branży mediów coraz odważniej stosującej algorytmy.

Owe brutalne doniesienia to np. informacje o przeprowadzanych w 2020 roku przez Microsoft zwolnieniach dziennikarzy, redaktorów i innych pracowników serwisu MSN i innych redakcji informacyjnych. Firma podała, że zwolnienia te nie mają nic wspólnego z pandemią COVID-19, zaś bardzo wiele – z zakrojoną na szeroką skalę automatyzacją dziennikarstwa (The Guardian, 2020). Tracących pracę ludzi zastąpić mają algorytmy skanujące internetowe treści i generujące na ich podstawie informacje w sposób automatyczny. Jednocześnie Microsoft coraz częściej zachęca reporterów i redaktorów do polegania na sztucznej inteligencji w takich zadaniach, jak wyszukiwanie oraz filtracja treści tekstowych i obrazów, które można wykorzystać w artykułach.

Entuzjaści automatyzacji dziennikarstwa uważają, co wyżej wybrzmiało wyraźnie, iż rozwój technik AI połączony z ich wprowadzaniem do praktyki pracy redakcyjnej stanowi dla dziennikarzy okazję do skupienia się na pogłębionych, wyższej jakości treściach, zamiast na prostych, powtarzalnych formach, ostatecznie uwalniając ich od swoistego mechanizmu pracy nad newsami. „Praca dziennikarza to kreatywność, ciekawość, opowiadanie historii, rozliczanie przedstawicieli władzy, krytyczne myślenie i formułowanie osądów – chcemy, aby nasi dziennikarze na tym skupiali swoją energię”, mówi we wspomnianym artykule w „NYT” Lisa Gibbs, jeden z dyrektorów w Associated Press (Peiser, 2019).

Zautomatyzowane dziennikarstwo otwiera, co się często podkreśla, nowe możliwości dla organizacji medialnych, obniżając np. koszty, co ostatecznie, w teorii przynajmniej, powinno być korzystne także dla pracowników tych firm. Sprawne i wydajne w zadaniach researchersko-analitycznych oprogramowanie może okazać się nieocenioną pomocą w pracy redakcji. Udoskonalone algorytmy doskonale nadają się do weryfikacji faktograficznej i korekty błędów. Na tym, czyli na wspomaganiu redaktorów i asyście polegają opisywane wyżej projekty amerykańskich gazet oraz Bloomberga i Reutersa.

W swoim raporcie, opublikowanym w 2020 r., Echobox, firma zajmująca się rozwiązaniami technologicznymi dla wydawców, zauważa ciekawe, zwłaszcza dla sterników biznesu medialnego, prawidłowości, np. korelację pomiędzy wykorzystaniem algorytmów AI przez wydawców a wzrostem ruchu w mediach społecznościowych. Według danych Echobox, wydawcy, którzy korzystali z AI, odnotowali średni wzrost ruchu w mediach społecznościowych o 21 proc. w porównaniu do wzrostu średnio o 10,5 proc. w przypadku wydawców, którzy z algorytmów nie korzystali (Echobox, 2020).

Na przykład klient Echoboxa, „Newsweek”, użył narzędzi przygotowujących i publikujących informacje dopasowane i redagowane na podstawie analiz danych, uzyskując w ten sposób lepsze wyniki wzrostu ruchu i zasięgu w social mediach niż inne porównywalne media. Przekłada się to oczywiście na wyniki statystyczne (i reklamowo-biznesowe) stron internetowych. Według raportu, ruch w profilach społecznościowych „Newsweeka” (średnie dzienne odsłony stron dzięki przekierowaniom z Facebooka i Twittera) wzrósł w czasie pandemii o 52 proc., podczas gdy ruch w mediach społecznościowych wydawców z USA wzrósł w tym samym czasie średnio o 5,6 proc. (Echobox, 2020). „Sztuczna inteligencja jest kluczowym sprzymierzeńcem wydawców, zwłaszcza gdy okoliczności i trendy zmieniają się szybko, a wydawcy muszą reagować błyskawicznie”, piszą autorzy raportu.

Hiperpersonalizacja środków przekazu

Fakt, że pod pewnymi względami roboty mogą więcej, a na pewno taniej, potencjalnie pozwala radykalnie przebudować biznesową logikę operowania mediów. Zamiast starać się dotrzeć do jak największej masy odbiorców, mogą celować w niewielkie, lokalne, precyzyjną kreską zaznaczone grupy, a nawet w pojedyncze osoby. Nie ma z tym ekonomicznego problemu, gdyż edycja i kreacja treści w AI jest docelowo o wiele tańsza. Nie mówimy już o „mass” mediach, lecz raczej o „highly personalized media”.

Hiperpersonalizacja, dzięki chirurgicznej precyzji i „zwinności” algorytmów AI, może prowadzić nawet dalej niż do prostego oferowania każdemu z osobna takich artykułów, jakie go interesują. Według niektórych teoretyków, można myśleć o swoistym spersonalizowanym medialnym origami, w którym elementy tekstów i obrazów są komponowane według preferencji indywidualnego odbiorcy. Inaczej mówiąc, każdy czytelnik z osobna może czytać stworzony specjalnie dla niego artykuł, inny niż czytelnik obok, dla którego algorytmy skroiły nieco inną wersję tej samej *story*.

To w Internecie nic niezwykłego, jeśli przypomnimy sobie, że algorytmy Google, Facebooka czy Twittera od dawna podsuwają każdemu jego własną wersję serwisu wedle przyzwyczajień i wybranych opcji (na zasadzie tzw. targetowania behawioralnego). Jednak tak niski poziom personalizacji na bazie algorytmów AI budzi spore wątpliwości natury zasadniczej, etycznej, odwołujące się do podstawowych zasad, na których opierają się środki masowego przekazu w demokracji. Przede wszystkim tworzenie treści pod indywidualne preferencje wymaga potężnej inwazji w prywatność odbiorcy, porównywalnej lub większej od tej, której dopuszczają się platformy społecznościowe. Po drugie, i może ważniejsze, pojawiają się w tej wizji pytania o prawdę obiektywną, wiarygodność, równe prawo do wolnej informacji. Czy to prawo przetrwa w świecie, w którym newsy są krojone dla każdego inaczej? (Hermann, 2021). To pytania ciekawe, ale wykraczające nieco poza zakres tematyczny niniejszej pracy. Wspominam jednak o tej kwestii, bo należy do szerokiego spektrum problemów i zjawisk związanych ze zderzeniem świata środków masowego przekazu ze światem algorytmów i sztucznej inteligencji.

Maszyny w zastępstwie dziennikarzy TV i radia

W lutym 2019 w chińskiej telewizji ważne dla Komunistycznej Partii Chin wydarzenie relacjonowała nowa gwiazda tamtejszej telewizji – Xin Xiaomeng. Prezenterka była cyfrowym kompozytem, stworzonym przy pomocy maszyny uczącej się naśladować mimikę twarzy i wzorce mowy prawdziwej osobowości telewizyjnej. Awatar ten wzorowany był na dziennikarce agencji Xinhua o nazwisku Qu Meng (Steger, 2019). Słowa wypowiedziane na antenie przez Xin Xiaomeng były pisane przez człowieka, zaś inteligencja systemu ograniczała się do zamiany tekstu na mowę. Gdyby jednak połączyć system z takimi algorytmami jak GPT-3, tworzyłaby całość, w warstwie obrazu, głosu i przekazywanej treści. Zatem mielibyśmy wówczas wszystkie elementy składowe pełnego automatu dziennikarskiego, w dodatku wyglądającego jak żywy człowiek, dla widzów TV odróżnialnego w niewielkim stopniu, zważywszy swoistą sztywność telewizyjnych ludzkich prezenterów odczytujących informacje w dziennikach.

Automaty tego typu już od pewnego czasu rozwijane są w czołowych technologicznych komorach inkubacyjnych na całym świecie. Google zapowiedziało, że jego znany ze smartfonów cyfrowy asystent stanie się „gospodarzem wiadomości” pochodzących od różnych partnerów medialnych i serwowanych z rozlicznych urządzeń mobilnych i nie tylko. Prowadzącego serwis wiadomości robota wywoływać będzie dostępna od pewnego czasu nowa funkcja nazwana „Your News Update”. Po jej uruchomieniu trzeba poprosić Asystenta Google o przekazanie wiadomości głosowo. Automat przedstawia serwis spersonalizowany, dostosowany do indywidualnych ustawień i historii użytkownika, inaczej niż podobne serwisy tradycyjnych mediów, radia i telewizji (Gannes, 2019).

Funkcja ta na razie jest dostępna jedynie w języku angielskim w Stanach Zjednoczonych, jednak w ciągu kilkunastu miesięcy ma zostać rozszerzona na inne kraje, dla osób posiadających kompatybilne smartfony i inteligentne głośniki. Podobną usługę o nazwie *flash briefing* od pewnego czasu oferuje również Amazon w swoich urządzeniach ze sztuczną inteligencją konwersacyjną Alexa. Udostępniają ją także „stare media”, takie jak serwis BBC (BBC, 2020) lub

Reuters, który we współpracy z firmą Synthesia testuje wirtualnego reportera telewizyjnego (Reuters, 2020).

Za oceanem urządzenia takie jak głośniki Echo, oparte na systemie Alexa Amazona, Google Home i Apple HomePod, masowo wchodzą do gospodarstw domowych, gdzie zajmują miejsce obok AGD, telewizorów czy sprzętu grającego i bardzo często służą jako centra sterowania innym sprzętem. Coraz częściej też stają się przekaznikami informacji o pogodzie, notowaniach giełdowych, wydarzeniach w najbliższej okolicy i na szerokim świecie. Rozwiązanie to przypomina spersonalizowany internetowy agregator treści, oparty jednak nie na tradycyjnym interfejsie komputerowym, ekranie, klawiaturze, wyświetlaczu dotykowym, lecz na komunikacji głosowej.

Jeśli więc dziennikarze radiowi i telewizyjni myśleli, że walka o stanowiska pracy z maszynami dotyczy jedynie kolegów piszących, to mogą być w dużym błędzie. Scenariusz, jaki możemy sobie wyobrazić, to wykorzystanie sztucznej inteligencji oraz interfejsu głosowego do przeprowadzenia tradycyjnego przeglądu prasy i do najnowszych doniesień. Możemy np. do asystenta cyfrowego zwrócić się mniej więcej tak: „Słyszałem, że dziś było trzęsienie ziemi. Czy możesz mi o tym więcej opowiedzieć?”. W odpowiedzi urządzenie samo przeszukuje serwisy informacyjne, czyta najważniejsze i najnowsze doniesienia na ten temat i zaprasza do komputera/telewizora/smartfona w celu wyświetlenia zebranych relacji filmowych i zdjęć.

Z drugiej strony dla mediów w tradycyjnym rozumieniu, radzących sobie w epoce Internetu ze zmiennym powodzeniem, głos może być nową szansą, obiecującym kanałem komunikacji z odbiorcami poszukującymi wartościowych i przydatnych informacji na żądanie. Nad rozwojem odpowiednich funkcji asystentów głosowych, zwanych np. w Alexa „umiejętnościami” (ang. *skills*) pracują już od pewnego czasu znane firmy medialne, np. BBC, „Washington Post” i amerykańskie radio publiczne. Na platformie Google’a odpowiednikami umiejętności są „działania” (ang. *action*). Z punktu widzenia mediów w obu przypadkach chodzi o zbudowanie metod interakcji użytkowników z treściami przez nie oferowanymi. W USA jest to coraz powszechniej wykorzystywany kanał dystrybucji treści. Amerykańskie radio publiczne, część tamtejszych gazet lokalnych, ale także „New York Times” i CNN, tworzą na potrzeby systemów głosowych krótkie „briefingi” audio, na razie głównie z zaangażowaniem pracowników ludzkich, ale, na co wskazują wyżej podane przykłady Google’a, BBC czy Reutersa, algorytmy mają tu ogromne pole do rozwoju.

Platformy przetwarzania języka naturalnego dostępne na rynku

„Każda organizacja, która zajmuje się tworzeniem treści, jest dziś pod przemożną presją, by generować je coraz szybciej i coraz bardziej redukować koszty”, mówił, komentując sytuację na amerykańskim rynku mediów, Ron Schmelzer, główny analityk w Cognilytica, firmie badawczej zajmującej się sztuczną inteligencją. „Na rynku będzie coraz więcej takich narzędzi, coraz efektywniej i wydajniej produkujących coraz większe ilości treści” (Willens, 2019).

Według raportu firmy doradczej Gartner, koszt dostępu do tych narzędzi, czyli platform przetwarzania języka naturalnego, waha się od 250 do 4800 USD rocznie. Przykładem firmy z tej branży, która zdecydowała się na skorzystanie z takich właśnie rozwiązań, jest szwajcarska grupa medialna Tamedia wykorzystująca algorytmy do automatyzacji raportowania wyników referendum w Szwajcarii. Jej system jest w stanie wygenerować około czterdziestu tysięcy artykułów w ciągu kilku minut. Skonfigurowanie „Tobi”, jak nazwano tego textbota, zajęło pięciu dziennikarzom od dwóch do trzech dni pracy. Warto zwrócić uwagę na tę ostatnią informację. To redaktorzy konfigurowali narzędzie. Musieli więc posiadać nową umiejętność, jeśli nawet nie będącą programowaniem, to do programowania zbliżoną (Plattner and Orel, 2019).

Jak wynika z wniosków z badań opublikowanych w 2017 r., których autorem był austriacki dziennikarz, Alexander Fanta, większość europejskich agencji informacyjnych już zdecydowała się na jakąś formę automatyzacji. Jak komentował Fanta, „pisanym maszynowo materiałom brakuje głębi i krytycznej analizy przedstawionych faktów, ale mogą zapewnić szybkie podsumowania danych liczbowych potrzebnych w artykułach” (Fanta, 2017).

Od uczenia maszynowego po przetwarzanie języka naturalnego, organizacje informacyjne mogą wykorzystywać AI do automatyzacji ogromnej liczby zadań, które składają się na łańcuch pracy redakcyjnej, w tym do wykrywania, ekstrakcji i weryfikacji danych, tworzenia historii i grafiki, publikowania (z filtrami sortowania, selekcji i priorytetyzacji) oraz automatycznego tagowania artykułów.

Chociaż obawy dotyczące zatrudnienia i bezpieczeństwa posad w mediach są uzasadnione, publikacje o postępach nowych technologii w mediach pełne są opinii, że nie ma mowy o wyeliminowaniu człowieka z procesów produkcji i publikacji treści. Oczywiście głosom tym towarzyszą często jeszcze silniejsze sugestie, że pracownicy mediów powinni przygotować się na nowe zadania i role, pozyskując nowe umiejętności.

Dziennikarstwo oparte na danych

Przykładem takiej niedwuznacznej sugestii jest informacja o wykorzystywanych m.in. przez agencję AP, „Washington Post” i Bloomberg, wewnątrzredakcyjnych systemach sygnalizujących anomalie pojawiające się w zbiorach danych (Peiser, 2019). Reporterzy, gdy widzą tego typu alarm, podejmują decyzje, czy anomalia w danych to potencjalny „temat”, czyli szansa na ciekawy materiał dziennikarski. W praktyce taki alarm może wyglądać choćby tak, jak ustawiony przez „The Washington Post” podczas igrzysk olimpijskich mechanizm odnotowywania wyników o 10 proc. wyższych lub niższych od rekordów w danych konkurencjach. Dziennikarz, redaktor występuje tu w uproszczonej nieco roli analityka danych, być może także *data minera* (nie ma jeszcze udatnego słowa opisującego to zajęcie w języku polskim – czasem sugeruje się „eksploratora danych”) oraz twórcy algorytmów, jeśli praca wiąże się z projektowaniem anomalii w strumieniach danych i automatycznej reakcji na anomalie. Każde z tych nowych zadań wymaga pozyskania, oprócz umiejętności praktycznych, również umiejętności o bardziej ogólnym charakterze, rozumienia sposobów działania algorytmów, uczenia maszynowego, przetwarzania języka i danych.

Praca środków masowego przekazu od zawsze polegała na przetwarzaniu danych zgodnie z redaktorską wiedzą i umiejętnościami, redagowaniu ich, a potem przekazywaniu treści w postaciach, które są przyswajalne dla czytelnika, słuchacza, widza. Różnica związana z upowszechnianiem się pojęcia *data journalism* w ostatnich latach ma charakter poniekąd ilościowy, bowiem we współczesnym sensie chodzi o przetwarzanie niespotykanych wcześniej, ogromnych ilości danych (*big data*), z czym człowiek z powodu naturalnych ograniczeń nie umie sobie poradzić.

Trzeba zacząć od tego, że *data journalism* nie jest wcale taką nowinką, jak można by myśleć. Jeden z pierwszych przykładów wykorzystania komputerów do realizacji zadań typowo dziennikarskich pochodzi już z 1952 roku, kiedy stacja CBS podjęła próby wykorzystania komputera typu *mainframe* do wspomagania redakcyjnego *researchu* w trakcie wyborów prezydenckich. Od 1967 r. zaczęto powszechniej stosować komputery do analizy danych w branży dziennikarskiej. Np. pracujący dla „Detroit Free Press” Philip Meyer używał komputerów typu *mainframe* do przetwarzania danych na temat zamieszek w mieście i zapadających w związku z nimi wyroków skazujących (Kayser-Bril, Valeeva and Radchenko, 2016). Meyer napisał później książkę zatytułowaną „Precision Journalism”, w której rekomendował wykorzystanie komputerowych technik syntezy i analizy danych w dziennikarstwie. Pod koniec lat 80. XX wieku dziedzina dziennikarstwa wspomaganego komputerowo zaczęła zdobywać większą popularność. W 1989 r. reporter śledczy Bill Dedman z „The Atlanta Journal-Constitution” zdobył nagrodę Pulitzera za zbiór reportaży pt. *Kolor pieniędzy*. Dzięki technikom komputerowej obróbki dużych zasobów danych zebrał dowody na istnienie praktyk dyskryminacji rasowej, z jakimi mają do czynienia kolorowi w bankach i innych instytucjach udzielających kredytów (Dedman, 1989).

Pierwszą odnotowaną historycznie formą regularnego wykorzystania *big data* przez dużą organizację informacyjną jest inicjatywa „The Guardian”, który w marcu 2009 roku uruchomił Datablog, określany oficjalnie jako „pierwszy systematyczny projekt polegający na włączeniu publicznie dostępnych źródeł danych do serwisów prasowych i newsowych” (Rogers).

Z Argentyny z kolei pochodzi jeden z najnowszych i najciekawszych przykładów wykorzystania przez dziennikarzy śledczych nie tylko techniki *data journalism*, ale również zastosowania w prezentacji działających na wyobraźnię wizualizacji, zwiększających siłę wyrazu i rażenia demaskujących publikacji. „La Nación”, największa gazeta codzienna w tym kraju, od kilku lat korzysta z technik przetwarzania danych. Pełną garścią sięgnęła po nowe środki pozyskiwania informacji i ich prezentowania w szeroko zakrojonym śledztwie dziennikarskim dotyczącym korupcji (La Nation, 2019).

Praktyk *data journalism*, Ben Casselman, dziennikarz ekonomiczny redakcji „The New York Times”, opowiadał na łamach swojej gazety o tym, jak używa języka programowania o nazwie R i pracuje z ogromnymi zbiorami danych. „Myślę, że niektórzy ludzie mają takie wyobrażenie, że *data journalism* oznacza wpatrywanie się w arkusze kalkulacyjne aż do momentu, w którym magicznie pojawia się materiał do publikacji, jednak w prawdziwym świecie niemal nigdy nie dochodzi do takiej sytuacji. Najlepsze artykuły prawie zawsze wyłaniają się z rozmów z ludźmi, niezależnie od tego, czy są oni ekspertami, czy po prostu zwykłymi ludźmi, których

dotyczą sprawy, o których piszemy. To oni zadają pytania, na które dane mogą pomóc odpowiedzieć, wyjaśniają tendencje, które dane ujawniają (...)", mówił (Casselmann, 2019).

Jego redakcja prowadzi kursy dla reporterów i redaktorów, które mają na celu przekazanie im podstawowych umiejętności dotyczących rozumienia i przetwarzania danych, w tym sztuki sprawdzania ich wiarygodności, analizy statystycznej i korzystania z arkuszy kalkulacyjnych w celu badania zbiorów danych. Wygląda na to, że świat mediów czeka w kontekście rozwoju AI oraz *data journalism* sporo nauki i konieczność przyswojenia nowych, nieznanych dotychczas w tym środowisku, umiejętności.

Edukacja ludzi mediów w dziedzinie sztucznej inteligencji i *big data*

W wymiarze globalnym znanych jest już wiele programów edukacyjnych, które nie tylko wstępnie oswajają świat mediów z AI, ale wręcz praktycznie uczą korzystania z narzędzi oferowanych przez sztuczną inteligencję.

Po przebadaniu 71 organizacji informacyjnych w 32 krajach Europy, Ameryki Północnej, Ameryki Południowej i Azji, Charlie Beckett, dyrektor międzynarodowego projektu edukacyjnego JournalismAI, poinformował, że niecałe cztery na dziesięć podmiotów w tej branży, w badanej grupie, wdrożyło już rozwiązania oparte na sztucznej inteligencji (Beckett, 2019). Według przygotowanego przez jego organizację raportu, główne przeszkody we wprowadzaniu tych technologii w redakcjach leżą w opozycji wobec zmian postrzeganych jako zbędne, niekorzystne lub nawet groźne. Częściowo wiąże się to z obawami o utratę pracy, zakłóceniami w rutynie pracy, a czasem nawet z ogólną wrogością wobec nowych technologii, co jest postawą dobrze znaną praktykom z czasów wprowadzania do mediów Internetu jako kanału publikacji.

Z tego oraz z wielu innych raportów jasno wynika konieczność edukowania dziennikarzy, edytorów i innych pracowników mediów w dziedzinie wciąż tak słabo rozumianej jak sztuczna inteligencja. Jednym z najaktywniejszych podmiotów prowadzących działalność szkoleniowo-uświadamiającą w tej dziedzinie jest Google ze swoim Digital News Innovation Fund, uruchomionym w 2015 r. W połowie 2021 r. Google News Initiative wraz z Polis, dziennikarskim think tankiem London School of Economics, uruchomiły „Akademię AI” dla pracowników małych mediów na obszarze Europy, Bliskiego Wschodu i Afryki (EMEA). Będą w niej prowadzone szkolenia i warsztaty na temat wykorzystywania techniki AI w pracy dziennikarsko-redakcyjnej. Podczas kilkutygodniowych kursów ludzie mediów poznają m.in. przykłady wykorzystania algorytmów sztucznej inteligencji do automatyzacji powtarzalnych zadań, takich jak transkrypcja wywiadów lub wyszukiwanie ilustracji, a także sposoby optymalizacji procesów publikacyjnych przez monitoring poziomu zaangażowania odbiorców (Google News Initiative, 2020).

Ten pilotażowy program, który ma wystartować w 2022 r., jest częścią szerszej zakrojonego przedsięwzięcia edukacyjnego: wspomnianego już, prowadzonego od trzech lat globalnego programu JournalismAI. Przedstawiciele Google i Polis informują o ponad stu tysiącach uczestników szkoleń online dostępnych w Google News Initiative Training Center. Od niedawna JournalismAI oferuje również AI

Journalism Starter Pack, materiał szkoleniowy dla redakcji z przykładami narzędzi AI, mogących rozwiązywać podstawowe potrzeby małych i lokalnych wydawców.

Programowanie redakcyjne w zautomatyzowanej agencji

W ramach Google News Initiative, wsparcie finansowe łączną kwotą 150 milionów euro otrzymały setki projektów mających charakter eksperymentalny, jak też edukacyjny. Jednym z najbardziej znanych jest RADAR (Reporters and Data and Robots) z Wielkiej Brytanii. Jak można przeczytać na stronie projektu, „Zbudowaliśmy jedyną na świecie zautomatyzowaną lokalną agencję informacyjną. Dostarczamy artykuły oparte na danych do setek serwisów informacyjnych, gazet i stacji radiowych w całej Wielkiej Brytanii”. System wytwarza około ośmiu tysięcy artykułów informacyjnych miesięcznie, nie działając jednak całkowicie automatycznie. Razem z algorytmami w RADAR pracuje zespół dziennikarzy, zapewniając kontrolę redakcyjną. System przeszukuje i przetwarza dostępne rządowe bazy danych zestawione według obszarów geograficznych, identyfikuje interesujące i godne uwagi wątki, rozwija te pomysły w szablony oparte na danych. Zautomatyzowana jest również lokalizacja geograficzna fragmentów treści. Materiały te są następnie przekazywane drogą bezprzewodową do lokalnych mediów, które podejmują decyzje o publikacji.

Dziennikarze RADAR korzystają m.in. z narzędzia o nazwie Arria Studio, które daje im wgląd w generowane automatycznie treści. To nic innego jak rozbudowany interfejs edytora tekstowego. Oparta na danych edycja sterowana jest regułami logicznymi, znanymi raczej z branży programowania komputerów niż z dziennikarstwa, czyli „if – then – else” (jeśli – to – w innym razie). Na przykład w relacji z trzęsienia ziemi można zaprogramować, aby inny przymiotnik opisywał trzęsienie ziemi o magnitudzie 8, a inny – o magnitudzie 3. Więc mielibyśmy regułę w rodzaju: „jeśli” magnituda > 7, „to” tekst = silne trzęsienie ziemi, „w innym razie” magnituda < 4 „to” tekst = niewielkie trzęsienie ziemi.

RADAR opracował też trzyetapowy proces kontroli jakości. Pierwszy: dziennikarz czyta próbkę wszystkich wyprodukowanych artykułów. Drugi: inny dziennikarz śledzi i bada informacje zawarte w artykule, porównując je z oryginalnym źródłem. Trzeci etap kontroli polega na sprawdzeniu przez redaktora logiki szablonu w celu wykrycia ewentualnych błędów lub pominięć. Przypomina to pracę, jaką zespół programistów wykonuje przy usuwaniu błędów w skrypcie. Wciąż musi ją wykonać człowiek, aby upewnić się, że automatyczny generator tekstu wykonuje swoje zadanie dokładnie. Analogia z programowaniem nasuwa myśl o konieczności nabycia kompetencji i umiejętności, z którymi dziennikarstwo tradycyjnie nie miało nic wspólnego. Jednocześnie istnieje również analogia z tradycyjnymi procedurami typowo redakcyjnej korekty, kolejnych przeczytań treści w celu wyeliminowania błędów językowych, stylistycznych, merytorycznych.

Jeśli modele takie jak RADAR i wykorzystanie AI upowszechnią się w mediach, dziennikarze nieuchronnie będą musieli pozyskać umiejętności w zakresie projektowania, aktualizowania, poprawiania, zatwierdzania, korygowania, nadzorowania i ogólnego utrzymania tych systemów. Od wielu, być może ostatecznie od wszystkich wymagane będą kompetencje dotyczące pracy z danymi i logiki programistycznej. W konsekwencji prowadzi to do traktowania umiejętności

programowania i znajomości logiki algorytmicznej jako istotnego atutu, jeśli nie wręcz wymagania zawodowego w środowisku pracy w mediach w przyszłości (Reporters and Data and Robots – RADAR).

Nowe kwalifikacje dziennikarskie czekają na precyzyjny opis

Według medioznawcy Nicka Diakopoulosa w Stanach Zjednoczonych, które są pionierem w dziedzinie automatyzacji newsów, pojawiły się już nowe profile zawodowe obejmujące zadania zarówno na poziomie „upstream” we współpracy z systemami automatycznymi (czyli przygotowanie szablonów tekstów do automatyzacji, parametryzacja oprogramowania, kontrola jakości danych), jak i prace typu „downstream” (monitorowanie jakości danych i treści) (Diakopoulos, 2019).

Włączenie tego typu umiejętności do edukacji dziennikarskiej stanowi wyzwanie ze względu na znaczne rozszerzenie zakresu przedmiotów w kształceniu dziennikarskim, jeśli chcemy zachować też edukację w zakresie tradycyjnych umiejętności. Do zwykłego programu trzeba by wprowadzić przynajmniej podstawy algorytmiki, elementy programowania, *big data*, statystyki i rachunku prawdopodobieństwa, a także zagadnienia związane z inżynierią lingwistyczną i jakością danych.

W środowiskach polskich dziennikarzy ta tematyka jest słabo rozpowszechniona i rzadko poważnie omawiana. Trudno dostrzec także na polskich uczelniach i w innych instytucjach zajmujących się kształceniem kadr dla mediów znaczącą i widoczną tendencję zmierzającą do zmiany metod, form i treści kształcenia dziennikarzy, a także innych pracowników mass mediów, która zmierzałaby do rozwinięcia nowych umiejętności, będących odpowiedzią na ekspansję algorytmów AI.

Warto mieć na uwadze konieczność uwzględnienia specyficznych uwarunkowań ekosystemu zawodowego środków masowego przekazu i zadań, które są realizowane przez dziennikarzy, w kontekście wdrażanego przez Instytut Badań Edukacyjnych na mocy ustawy z 22 grudnia 2015 r. Zintegrowanego Systemu Kwalifikacji. Jest to istotne także w odniesieniu do opisywanych wyżej powiązań nowych (wynikających w sposób bezpośredni i pośredni ze stosowania algorytmów) umiejętności profesjonalnych w mediach z innymi zakresami kompetencji, np. programistycznymi, analitycznymi i związanymi z przetwarzaniem *big data*.

Jeśli strategia nakreślona m.in. w uchwale nr 196 Rady Ministrów z dnia 28 grudnia 2020 r. w sprawie ustanowienia „Polityki dla rozwoju sztucznej inteligencji w Polsce od roku 2020” będzie konsekwentnie i skutecznie realizowana, to zastosowanie algorytmów i AI będzie się upowszechniać także w dziedzinach, które obecnie wydają się stać nieco obok przemysłowych zmian technologicznych, czyli również w pracy ludzi mediów. Tego środowiska zawodowego dotyczy również, nawet jeśli nie jest to dostatecznie jasno wyrażone w dokumentach, rządowa „Zintegrowana Strategia Umiejętności 2030” przyjęta uchwałą nr 195/2020 tego samego dnia co strategia rozwoju sztucznej inteligencji w Polsce, czyli 28 grudnia 2020 r.

Oczywiście nawet najlepiej napisane ustawy, uchwały i strategie, a także uporządkowanie i uzupełnienie systemu kwalifikacji nie wystarczą, jeśli w medialnych

środowiskach zawodowych nie zajdą określone zmiany mentalne, w tym przede wszystkim – jeśli nie zmniejszy się niechęć i lęk wobec nowych technologii, na co wskazują cytowane wyżej wyniki badań ankietowych (Kim and Seongcheol, 2017; Beckett, 2019). Zmiany prawdopodobnie będą, jak to bywało w przeszłości, wymuszane przez szukających optymalizacji kosztowej wydawców, co również było wyżej sygnalizowane. W tej sytuacji przygotowane w systemie oraz w rejestrach wymogów wobec instytucji edukacyjnych precyzyjne opisy, rejestry i klasyfikacje kwalifikacji mogą pomóc pracownikom lub kandydatom na pracowników mediów poszukującym nowych umiejętności i zdefiniowania na nowo swojej roli zawodowej.

Podsumowanie

Właściciele i menedżerowie firm operujących w branży środków masowego przekazu, zwłaszcza w krajach wysoko rozwiniętych, wykazują coraz lepszą orientację, jeśli chodzi o dostępne narzędzia AI, a także – rosnącą wolę korzystania z rozwiązań algorytmicznych, polegających na przetwarzaniu języka i danych. Świadczą o tym opisywane w artykule projekty i testy praktyczne nowych rozwiązań, opartych na algorytmach przetwarzania języka naturalnego oraz dużych zasobów danych. Silnym argumentem przemawiającym za podejmowaniem takich prób, z punktu widzenia korporacji medialnych, jest obniżanie kosztów połączone ze wzrostem wydajności bez strat na jakości produktu. W przypadku prostych informacji nie ma już zasadniczo jakościowych różnic pomiędzy pracą ludzką a maszynową. Wskazują na to wyniki przedsięwzięcia Associated Press wykorzystującego automatyzację prostych raportów finansowych i późniejsze kolejne podejścia, takie jak angażowanie automatycznego „reportera sejsmicznego” Quakebot przez „Los Angeles Times” oraz generatora prostych doniesień sportowych Heliograf opracowanego przez redakcję „The Washington Post”.

Opisywane w artykule obawy przedstawicieli zawodów typowych dla mass mediów, dziennikarzy i edytorów, są w oczach zwolenników wprowadzania nowych technologicznych rozwiązań (np. cytowanego wyżej obszernie Kristiana Hammonda z firmy Narrative Science) nieuzasadnione i oparte na niskim poziomie wiedzy o sztucznej inteligencji, jej możliwościach, a także o szansach na rozwój zawodowy, jakie mogą się z nią wiązać. Niepokojącym się o miejsca pracy propagatorzy AI wskazują możliwości pozyskania kwalifikacji i umiejętności wykraczających poza tradycyjne modele zawodów w środkach masowego przekazu.

Korzyści, jakich oczekują po wprowadzeniu i rozwoju technik opartych na uczeniu maszynowym firmy medialne i kierownictwa wydawnictw, nie zawsze jednoznacznie utożsamiane są z interesami zawodowymi środowiska dziennikarskiego. To jest m.in. podłoże wspomnianych obaw i wyrażanej przez przedstawicieli zawodów medialnych w badaniach rezerwy, jeśli nie wprost niechęci do nowych technologii. Wzrostowi pozytywnych uczuć wobec algorytmów nie sprzyjają również efektownie wizualizowane prezentacje możliwości botów dziennikarskich, takich jak „prezenterka” wiadomości chińskiej agencji Xinhua lub też rozwój konwersacyjnej sztucznej inteligencji typu Alexa lub Google Home, które już w tej chwili potrafią zastąpić spikerów tradycyjnego radia lub, po dodaniu zaawansowanej generacji obrazu 3D, także telewizji.

Oczywistym w tej sytuacji dążeniem powinno być, jak się wydaje, poszukiwanie sposobów edukacji ludzi mediów w zakresie nowych umiejętności, wynikających z ekspansji wyżej opisanych rozwiązań. W ostatnich latach rośnie na świecie liczba inicjatyw edukacyjnych, niekiedy już nawet rozbudowanych kompleksowych programów szkoleniowych, związanych z nauką metod wykorzystywania wyników pracy algorytmów, przetwarzania danych, a nawet programowania. Także na polskim rynku pożądanym wydaje się uruchomienie tego rodzaju edukacji dla ludzi mediów, zarówno w ramach struktur kształcenia uczelnianego, jak też za pomocą wszelkiego rodzaju szkoleń, oferowanych przez podmioty państwowe lub komercyjne, przeznaczonych dla osób już pracujących w zawodach związanych ze środkami masowego przekazu. Uzupełnienie Zintegrowanego Rejestru Kwalifikacji o pozycje odzwierciedlające szczegółowe potrzeby mediów w tym zakresie pomogłoby ukierunkować i uporządkować ten nurt edukacji zawodowej.

Bibliografia

Aldhous, P. (2017). How BuzzFeed News revealed hidden spy planes in US airspace. *Columbia Journalism Review*. Pobrano z <https://www.cjr.org/watchdog/how-buzzfeed-news-revealed-hidden-spy-planes-in-us-airspace.php>

BBC (2020). *BBC Global News launches AI-powered synthetic voice which*. Pobrano z <https://www.bbc.co.uk/mediacentre/worldnews/2020/life-project>

Beckett, C. (2019). *New powers, new responsibilities. A global survey of journalism and artificial intelligence*. Pobrano z <https://drive.google.com/file/d/1utmAMCmd4rfJHrUfLLfSJ-clpFTjyef1/view>

Caixiong, Z. (2017). Robot reporter makes newspaper debut. *China Daily*. Pobrano z http://www.chinadaily.com.cn/china/2017-01/18/content_27989654.htm

Carlson, M. (2014). The Robotic Reporter. *Research Gate*. Pobrano z https://www.researchgate.net/publication/276168178_The_Robotic_Reporter

Casselmann, B. (2019). In Data Journalism, Tech Matters Less Than the People. *The New York Times*. Pobrano z <https://www.nytimes.com/2019/11/13/technology/personaltech/data-journalism-economics.html>

Castro, A. (2020). OpenAI's latest breakthrough is astonishingly powerful, but still fighting its flaws. *The Verge*. Pobrano z <https://www.theverge.com/21346343/gpt-3-explainer-openai-examples-errors-agi-potential>

Chua, R. (2018). The cybernetic newsroom: horses and cars. *Reuters*. Pobrano z <https://www.reuters.com/article/rpb-cyber-idUSKCN1GO0Z0>

Dans, E. (2019). Meet Bertie, Heliograf And Cyborg, The New Journalists On The Block. *Forbes*. Pobrano z <https://www.forbes.com/sites/enriquedans/2019/02/06/>

meet-bertie-heliograf-and-cyborg-the-new-journalists-on-the-block/?sh=2c0fab93138d

Dedman, B. (1989). *The Color of Money*. *The Atlanta Journal-Constitution*. Pobrano z http://powerreporting.com/color/color_of_money.pdf

Diakopoulos, N. (2019). *Automating the News. How Algorithms Are Rewriting the Media*. *Harvard University Press*. Pobrane z <https://www.hup.harvard.edu/catalog.php?isbn=9780674976986>

Echobox (2020). *Coronavirus impact on publishers* [Blog]. Pobrano z <https://www.echobox.com/resources/blog/coronavirus-impact-on-publishers>

Fanta, A. (2017). *Putting Europe's Robots on the Map: Automated journalism in news agencies*. *Reuters Institute, University of Oxford*. Pobrano z <https://reutersinstitute.politics.ox.ac.uk/our-research/putting-europes-robots-map-automated-journalism-news-agencies>

Frey, C. B. and Osborne, M. A. (2013). *The future of employment: how susceptible are jobs to computerisation?* *Oxford Martin School*. Pobrano z https://www.oxfordmartin.ox.ac.uk/downloads/academic/The_Future_of_Employment.pdf

Gannes, L. (2019). *Hey Google, play me the news* [Google Blog]. <https://blog.google/products/news/your-news-update/>

Google News Initiative (2020). *Digital News Innovation Fund Impact Report*. Pobrano z <https://newsinitiative.withgoogle.com/dnifund/report/>

Hao, K. (2020). *OpenAI is giving Microsoft exclusive access to its GPT-3 language model*. *MIT Technology Review*. Pobrano z <https://www.technologyreview.com/2020/09/23/1008729/openai-is-giving-microsoft-exclusive-access-to-its-gpt-3-language-model/>

Hermann, E. (2021). *Artificial intelligence and mass personalization of communication content – An ethical and literacy perspective*. *SAGE Journals*. Pobrano z <https://journals.sagepub.com/doi/abs/10.1177/14614448211022702>

Holmes, A. (2020). *A fake blog written by AI shot to the top of Hacker News after people thought it was real*. *Business Insider*. Pobrano z <https://www.businessinsider.com/fake-ai-generated-gpt3-blog-hacker-news-2020-8?IR=T>

Kahn, J. (2019). *The AI that can write a fake news story after being given just a few words*. *The Sydney Morning Herald*. Pobrano z <https://www.smh.com.au/business/companies/the-ai-that-can-write-a-fake-news-story-after-being-given-just-a-few-words-20190215-p50xxv.html>

Kayser-Bril, N., Valeeva, A., Radchenko, I., ITMO University (2016). *Transformation of communication processes: data journalism*. *Research Gate*. Pobrano z https://www.researchgate.net/publication/302381355_Transformation_of_Communication

nication_Processes_Data_Journalism/fulltext/57302b6f08aeb1c73d13ac40/Transformation-of-Communication-Processes-Data-Journalism.pdf

Kim, D. and Seongcheol, K., (2017). Newspaper journalists' attitudes towards robot journalism. *Research Gate*. Pobrano z https://www.researchgate.net/publication/321749580_Newspaper_journalists'_attitudes_towards_robot_journalism

La Nation (2019). *Driver's notebooks exposed Argentina's greatest corruption scandal ever: ten years and millions of cash bribes in bags* [Blog]. Pobrano z <https://blogs.lanacion.com.ar/projects/data/the-drivers-corruption-notebooks-argentine-massive-bribery-scandal/>

Levy, S. (2012). Can an Algorithm Write a Better News Story Than a Human Reporter? *Wired*. Pobrano z <https://www.wired.com/2012/04/can-an-algorithm-write-a-better-news-story-than-a-human-reporter/>

López, T. M., Fieiras-Ceide, C., Vaz-Álvarez, M. (2021). Impact of Artificial Intelligence on Journalism: transformations in the company, products, contents and professional profile. *Uniuersytet w Santiago de Compostela*. Pobrano z https://www.researchgate.net/publication/348431573_Impact_of_Artificial_Intelligence_on_Journalism_transformations_in_the_company_products_contents_and_professional_profile

Los Angeles Times (2021). *The Homicide Report*. Pobrano z <https://homicide.latimes.com>

Mayhew, F. (2020). Most journalists see AI robots as a threat to their industry: This is why they are wrong. *Press Gazette*. Pobrano z <https://www.pressgazette.co.uk/ai-journalism/>

McKinsey Global Institute (2017). *Jobs lost, jobs gained: What the future of work will mean for jobs, skills, and wages*. Pobrano z <https://www.mckinsey.com/featured-insights/future-of-work/jobs-lost-jobs-gained-what-the-future-of-work-will-mean-for-jobs-skills-and-wages>

Merrill, J. B. (2017). Chamber of Secrets: Teaching a Machine What Congress Cares About. *ProPublica*. Pobrane z <https://www.propublica.org/nerds/teaching-a-machine-what-congress-cares-about>

Miller, R. (2015). AP's 'robot journalists' are writing their own stories now. *The Verge*. Pobrano z <https://www.theverge.com/2015/1/29/7939067/ap-journalism-automation-robots-financial-reporting>

Peiser, J. (2019). The Rise of the Robot Reporter. *The New York Times*. Pobrano z <https://www.nytimes.com/2019/02/05/business/media/artificial-intelligence-journalism-robots.html>

Pew Research Center (2014). *AI, Robotics, and the Future of Jobs*. Pobrano z <https://www.pewresearch.org/internet/2014/08/06/future-of-jobs/>

Plattner, T. and Orel, D. (2019). Addressing Micro-Audiences at Scale. *Prezentacja na forum Computation + Journalism w Miami*. Pobrano z <https://drive.google.com/file/d/1CJvITDxHEbPKMUO4Pq457N8BvuEZHRGk/view>

Rampersad, G. (2020). Robot will take your job: Innovation for an era of artificial intelligence. *Journal of Business Research*. Pobrano z <https://doi.org/10.1016/j.jbusres.2020.05.019>

Reporters and Data and Robots – RADAR (bdw.). Pobrano 30 sierpnia 2021 z <https://pa.media/radar-news/>

Reuters (2020). *Reuters and Synthesia unveil AI prototype for automated video reports*. Pobrano z <https://www.reuters.com/article/rpb-synthesia-prototype-idUSKBN201103>

Rogers, S. (bdw.). Behind the Scenes at the Guardian Datablog. *DataJournalism.com*. Pobrano 28 sierpnia 2021 z <https://datajournalism.com/read/handbook/one/in-the-newsroom/behind-the-scenes-at-the-guardian-datablog>

Sahota, N. (2018). A.I. May Have Written This Article. But Is That Such a Bad Thing? *Forbes*. Pobrano z <https://www.forbes.com/sites/cognitiveworld/2018/09/16/did-ai-write-this-article/?sh=112df09e1885>

Simonite, T. (2015). Robot Journalist Finds New Work on Wall Street. *MIT Technology Review*. Pobrano z <https://www.technologyreview.com/2015/01/09/169664/robot-journalist-finds-new-work-on-wall-street/>

Stahl, A. (2021). How AI Will Impact The Future Of Work And Life. *Forbes*. Pobrano z <https://www.forbes.com/sites/ashleystahl/2021/03/10/how-ai-will-impact-the-future-of-work-and-life/>

Steger, I. (2019). This is China's AI female news anchor. *World Economic Forum*. Pobrano z <https://www.weforum.org/agenda/2019/02/chinese-state-media-s-latest-innovation-is-an-ai-female-news-anchor>

The Guardian (2020). A robot wrote this entire article. Are you scared yet, human. Pobrano z <https://www.theguardian.com/commentisfree/2020/sep/08/robot-wrote-this-article-gpt-3>

The Washington Post (2016). *The Washington Post experiments with automated storytelling to help power 2016 Rio Olympics coverage*. Pobrano z <https://www.washingtonpost.com/pr/wp/2016/08/05/the-washington-post-experiments-with-automated-storytelling-to-help-power-2016-rio-olympics-coverage/>

Uchwała nr 196 Rady Ministrów z dnia 28 grudnia 2020 r. w sprawie ustanowienia „Polityki dla rozwoju sztucznej inteligencji w Polsce od roku 2020”. Pobrano 1 sierpnia 2021 z <https://isap.sejm.gov.pl/isap.nsf/download.xsp/WMP20210000023/O/M20210023.pdf>

Ustawa z dnia 22 grudnia 2015 r. o Zintegrowanym Systemie Kwalifikacji. Pobrano 1 sierpnia 2021 z <http://isap.sejm.gov.pl/isap.nsf/download.xsp/WDU-20160000064/U/D20160064Lj.pdf>

Waterson, J. (2020). Microsoft sacks journalists to replace them with robots. *The Guardian*. Pobrano z <https://www.theguardian.com/technology/2020/may/30/microsoft-sacks-journalists-to-replace-them-with-robots>

Willens, M. (2019). Forbes is building more AI tools for its reporters. *Digiday*. Pobrano z <https://digiday.com/media/forbes-built-a-robot-to-pre-write-articles-for-its-contributors/>

World Economic Forum (2018). *Can you tell if this was written by a robot? 7 challenges for AI in journalism*. Pobrano z <https://www.weforum.org/agenda/2018/01/can-you-tell-if-this-article-was-written-by-a-robot-7-challenges-for-ai-in-journalism/>

Zalecenie Rady z dnia 22 maja 2017 r. w sprawie europejskich ram kwalifikacji dla uczenia się przez całe życie. Pobrano 16 sierpnia 2021 z [https://eur-lex.europa.eu/legal-content/PL/TXT/?uri=CELEX:32017H0615\(01\)](https://eur-lex.europa.eu/legal-content/PL/TXT/?uri=CELEX:32017H0615(01))

Zintegrowana Strategia Umiejętności 2030 (część szczegółowa) – dokument przyjęty przez Radę Ministrów. Pobrano 14 lipca 2021 z <https://www.gov.pl/web/edukacja-i-nauka/zintegrowana-strategia-umiejtnosci-2030-czesc-szczegolowa--dokument-przyjety-przez-rade-ministrow>

Zintegrowany System Kwalifikacji. Pobrano 29 sierpnia 2021 z <https://kwalifikacje.gov.pl>

Edukacja

Sztuczna inteligencja wkracza do szkół: jak uczyć się o AI i z pomocą AI

prof. dr hab. Maciej M. Sysło*

Jedną z misji szkoły jest intelektualny rozwój uczniów, których obecnie w coraz większym stopniu otaczają urządzenia i przejawy sztucznej inteligencji (AI, ang. *artificial intelligence*). Dzieje się tak, gdy programują roboty, grają w przeróżne gry, korzystają z map czy translatora Google. Obserwują także poza szkołą roboty zastępujące ludzi (np. na liniach montujących samochody) oraz wiele innych urządzeń, maszyn i przedmiotów codziennego użytku przejawiających pewne cechy kojarzone z inteligencją człowieka.

Głównym celem tego rozdziału jest przybliżenie AI kręgom edukacyjnym oraz zwrócenie uwagi i dostarczenie argumentów, że nadszedł już czas, by sztuczna inteligencja jawnie pojawiła się w szkole. Ze względu na ścisły związek AI z metodami komputerowymi i informatyką, środowisko edukacji informatycznej proponuje, by AI stała się modułem kształcenia informatycznego (zajęć z informatyki), ale także integrowała się z innymi przedmiotami. Struktura proponowanego modułu (zob. podrozdział 4.1.) została zaczerpnięta ze sprawdzonego źródła (będzie o nim mowa w dalszej części rozdziału), jego wdrożenie wymagać jednak będzie ściślejszych powiązań z zapisami obowiązującej podstawy programowej. Zamieszczono wybrane przykłady środowisk, w których uczniowie mogą rozwijać znajomość AI, poszerzać swoją wiedzę i umiejętności informatyczne oraz z innych dziedzin, jak również zwracać uwagę na istotne aspekty społeczne związane z ekspansją AI.

Znaczącą część tego rozdziału zajmują rozważania dotyczące historycznego tła rozwoju AI i jej powiązań głównie z matematyką i informatyką (zob. podrozdział 3.) – historia już tradycyjnie jest dobrą nauczycielką. Te powiązania obejmują zarówno aspekty naukowe, jak i sferę edukacji, w której ekspansji technologii towarzyszą rozwiązania czyniące z komputerów urządzenia bardziej inteligentne, wspomagające uczniów i nauczycieli w niektórych ich działaniach.

Wskazano także obszary, w których AI może mieć znaczący wpływ na funkcjonowanie szkoły jako instytucji i pracę nauczycieli. Na końcu krótko odniesiono się również do zagrożeń związanych z pojawianiem się AI, w szczególności w edukacji, jak i do wyzwań, z którymi przychodzi się zmierzyć, kiedy stosuje się rozwiązania wykorzystujące AI.

1. Sztuczna inteligencja z lotu ptaka... nad szkołą

Tradycyjną rolą edukacji jest przygotowanie uczniów na przyszłość. Przyszłość zaś jawi się dziś jako nieustanne zmiany w środowiskach uczenia się i pracy, które są coraz bardziej wypełnione technologią zmierzającą do zastępowania rutynowych prac przez zautomatyzowane procedury i urządzenia. Przejmują one z czasem wiele funkcji człowieka, tradycyjnie rozumianych jako działania wymagające

* Warszawska Wyższa Szkoła Informatyki, ORCID: 0000-0002-2940-8400

inteligencji. Pojawiają się nowe zawody korzystające w coraz większym stopniu z technologii, w tym z inteligentnych rozwiązań, jak roboty automatyzujące nie tylko rutynowe prace. Niezbędna więc będzie umiejętność współpracy z nimi.

Podobnie jak to miało miejsce z każdą wcześniejszą technologią, przewiduje się, że AI może być skutecznym narzędziem w edukacji, które odciążą nauczycieli od rutynowych zadań (sprawdzania obecności, oceniania) i będzie wsparciem w pracy z uczniami. Uczniom zaś dostarczy bardziej efektywnych i dostosowanych do ich sylwetek metod uczenia się. Mogłyby to być interaktywne samouczki adaptacyjne tworzące zindywidualizowane środowiska uczenia się i wykorzystujące interfejs człowiek–komputer. Monitorowałyby pracę ucznia, dobierały odpowiednie zadania i przekazywały uczniom pełne informacje zwrotne. Połączenie takich indywidualnych samouczków w system klasowy mogłoby być początkiem zmiany roli nauczycieli. Należy jednak pamiętać o wiecznych obawach nauczycieli, że jakkolwiek technologia wnoszona do szkoły może w rezultacie zmniejszyć ich rolę i w końcu ich wyeliminować – mają tego przykłady na innych zautomatyzowanych stanowiskach pracy. Rola nauczycieli będzie jednak musiała być dostosowana do środowisk, w których będą się uczyć uczniowie wspierani przez AI. Podobnie więc jak z innymi technologiami, AI sama będzie wymagała edukacyjnego wsparcia.

Już na tym etapie pojawiają się pytania o przyszłe losy szkoły. Jeśli wiedza/inteligencja będzie mogła być umieszczona w chipie, to czy człowiek będzie jeszcze potrzebny jako nośnik AI? A szkoła? Kiedy uczeń będzie mógł wybrać chip o odpowiedniej skali inteligencji, to po co miałby chodzić do szkoły, jeśli będzie mógł umieścić swój mózg z dodatkowym chipem w chmurze swoich rówieśników z klasy z dowolnego miejsca, gdzie się znajdzie? Podstawowym błędem w takim wybieganiu w przyszłość jest operowanie dzisiejszymi kategoriami, takimi jak szkoła, uczeń, nauczyciel, klasa, egzamin, wiedza, dla których trudno wyobrazić sobie jeszcze teraz odpowiedniki w czasach mózgow AI.

Warto w tym miejscu przypomnieć, że „mądrością staje się symbioza tego, w czym mózg jest najlepszy, z tym, co komputer potrafi wykonać nawet lepiej” (Mark Prensky, 2013). Ponadto kształtowana jest ważna umiejętność myślenia komputacyjnego, które powinno wyprzedzać posługiwanie się technologią, nawet jeśli jest ona naszpikowana „myślącymi” rozwiązaniami AI.

Zarzuty wobec AI, w szczególności wobec uczenia maszynowego (zob. podrozdział 4.3.) skłaniają do głębokiego rozważenia miejsca i sposobu wykorzystania rozwiązań AI w uczeniu się i w systemie edukacji. Wydaje się, że przynajmniej na tym etapie nie należy całkowicie oddawać pola rozwiązaniom AI, a przyjąć raczej rozwiązania „mieszane”, stanowiące proponowaną przez Prensky’ego symbiozę tradycyjnego myślenia ze sztuczną inteligencją wspieraną uczeniem maszynowym⁸. Na sztuczną inteligencję w edukacji należy zatem spojrzeć z pozycji „sztuczna inteligencja i człowiek”, a nie „sztuczna inteligencja kontra człowiek”, czyli zastanowić się, w jaki sposób człowiek może wykorzystać AI dla własnych celów: indywidualnie – w uczeniu się, jak również w edukacji i w szkole – do organizacji procesu kształcenia.

⁸ Wyrazem takiego podejścia autora do AI był tytuł wystąpienia na konferencji Informatyka w Edukacji – „Inteligencja+” (Sysło, 2019).

Reasumując, zastosowania AI w edukacji obejmują generalnie dwa obszary:

1. AI w klasie – kluczowym zagadnieniem jest to, jak przybliżyć AI uczniom, co uczeń powinien wiedzieć na temat sztucznej inteligencji, a także jak korzystać z rozwiązań AI w nauczaniu i uczeniu się;
2. AI w szkole – transformacja funkcjonowania szkoły jako instytucji w zakresie oceniania postępów uczniów, organizacji zajęć i funkcjonowania szkoły, jak również formy i trybu zajęć.

Fazlagić dokonuje w tej publikacji (zob. rozdział *Między sztuczną inteligencją a „sztuczną kreatywnością” – przyszłość człowieka kreatywnego w epoce sztucznej inteligencji*, s. 38) przeglądu możliwych zastosowań AI w edukacji, skupia jednak uwagę głównie na drugim z powyższych aspektów.

2. Uwagi ogólne

2.1. Rzut oka na historię

Wszystko, co działo się i dzieje wokół AI, jest dziełem inteligencji człowieka i to najczęściej najwybitniejszych osób w swojej dziedzinie, a ich celem – osób i działań – było i jest poszerzenie, wsparcie czy nawet zastąpienie ludzkiego umysłu przez maszyny myślące. Uwaga zostanie tu skierowana na osoby bliskie komputerom, matematyce i informatyce, gdyż dzieje AI są w istocie dziejami technik obliczeniowych, a współczesny rozwój AI i jej sukcesy nie byłyby możliwe bez rosnących możliwości komputerów i metod algorytmicznych. Komputery pozostają jednak nadal skończonymi maszynami, nawet jeśli uruchomimy w nich nieskończony proces z interakcją⁹ – taki charakter mają systemy czasu rzeczywistego, jak np. sztuczna nerka. Na temat inteligencji komputerów można przytoczyć słowa eksperta od inteligencji, Edwarda Nęcki (2005), że „maszyna jest inteligentna inteligencją programisty”.

Jeszcze przed erą komputerów Blaise Pascal (1623–1662) i Gottfried W. Leibniz (1646–1716) budowali pierwsze instrumenty do obliczeń¹⁰. Koncepcje Leibniza wykraczały znacznie dalej niż tylko automatyzacja obliczeń¹¹. Uważał on, że każdą myśl można sformalizować i wykonywać na niej obliczenia, co mogłoby prowadzić do rachunkowego rozstrzygnięcia sporów, np. między filozofami.

W pierwszej połowie XIX wieku Charles Babbage (1792–1871) podjął się zbudowania maszyny analitycznej, której koncepcja niewiele odbiegała od funkcjonowania dzisiejszych komputerów. Nie zbudował jej, ale zachwyciła się nią Augusta Ada Lovelace (1815–1852), córka Byrona, i napisała dla tej nieistniejącej maszyny

⁹ Bardzo ciekawy punkt widzenia prezentuje Peter Wegner (Comm. ACM 40, 1997, 81–91), którego zdaniem systemy z interakcją mają większą moc w rozwiązywaniu problemów niż klasyczne rozwiązania bazujące na algorytmach w modelu Maszyny Turinga.

¹⁰ Zaprojektowany przez Leibniza bęben schodkowy, którego użył w swojej „żywej ławie do obliczeń” skonstruowanej w 1694 roku, był wykorzystywany po ostatnie dni mechanicznych kalkulatorów w latach 70. XX w.

¹¹ Leibniz jest też uznawany za prekursora liczb i obliczeń binarnych.

program, dzięki czemu uznaje się ją za pierwszą programistkę¹². W swoich *Notes* o maszynie analitycznej, Lovelace zachwyciła się jej koncepcją, w której widziała możliwości wykraczające poza tradycyjne przeznaczenie komputerów jako urządzeń do obliczeń¹³, i:

- uznała, że będzie ona tkać wzory algebraiczne tak, jak krosno Jacquarda tka kwiaty i liście;
- przewidziała stworzenie rachunku symbolicznego, który mógłby posłużyć na przykład do komponowania muzyki.

Jednak realnie oceniła możliwości tej maszyny, stwierdzając, że „Maszyna analityczna nie ma aspiracji, by zapoczątkować cokolwiek. Potrafi wykonać cokolwiek, a my wiemy, jak to wykonać” (ang. *The Analytical Engine has no pretensions to originate anything. It can do whatever we know how to order it to perform* [wyróżnienia Lovelace]). To stwierdzenie skomentował Alan M. Turing w swojej słynnej pracy z 1950 roku *Computing machinery and intelligence*, uznając je za *Lady Lovelace's Objection*. Napisał tam (na podstawie Feigenbaum et al., 1972):

Wierzę, że za pięćdziesiąt lat stanie się możliwe programowanie maszyn cyfrowych [...] tak, aby grały w grę w naśladownictwo tak dobrze, że przeciętny pytający po pięciu minutach zadawania pytań nie będzie miał więcej niż 70 procent szansy dokonania prawidłowej identyfikacji [...], wierzę, że pod koniec tego stulecia [XX wieku] używanie słów i ogólna opinia ludzi wykształconych zmieni się tak bardzo, że będzie można mówić o maszynach myślących, nie spodziewając się sprzeciwu.

Wspomniana „gra w naśladownictwo” znana jest dzisiaj pod nazwą testu Turinga. Polega on na tym, że człowiek próbuje odróżnić człowieka od maszyny, rozmawiając z każdym z nich, ale nie wiedząc z kim. Jeśli nie jest w stanie odróżnić człowieka od maszyny, to mówimy, że maszyna przeszła test. Innymi słowy, test ten ma na celu określenie zdolności maszyny do opanowania przez nią (w dialogu z człowiekiem) umiejętności myślenia w sposób podobny do ludzkiego. Test Turinga stał się impulsem dla rozwoju AI¹⁴, a Turinga uznaje się za inicjatora AI.

Pierwsza połowa XX wieku to początek elektronicznej techniki komputerowej, pod którą podwaliny położył Claude Shannon (1916–2001), przedstawiając w swojej pracy magisterskiej na MIT (Massachusetts Institute of Technology) z 1935 roku implementację operacji algebry Boole’a w postaci obwodów elektrycznych. Shannon jest też twórcą teorii informacji i kodowania (1948). Interesowała go również automatyzacja gry w szachy (zob. podrozdział 4.2.). Wspomnijmy jeszcze o optymizmie Johna von Neumanna¹⁵ (1912–1957) z 1948 roku: „Twierdzisz, że jest coś, czego

¹² Warto ten fakt przytaczać dzisiaj uczniom i innym adeptom informatyki, w tym programistom, oraz przypominać, że komputer nie jest specjalnie potrzebny do zaprojektowania algorytmu i napisania programu. Jest on oczywiście potrzebny, gdy program trzeba wykonać, wtedy wcześniej trzeba go zakodować w języku zrozumiałym dla konkretnej maszyny.

¹³ Przewidywania Ady Lovelace są realizowane dzisiaj w postaci maszynowo malowanych obrazów i utworów muzycznych stworzonych przez AI.

¹⁴ Proste programy konwersacyjne, takie jak ELIZA Josepha Weizenbauma z 1967 roku, były w stanie sprawić, że ludzie z pewnego kręgu wierzyli, iż rozmawiają z żywym człowiekiem.

¹⁵ John von Neuman jest uznawany za twórcę tzw. architektury von Neumanna (First Draft, 1945), według której są budowane i funkcjonują współczesne komputery. Uczestniczył także w budowie jednego z pierwszych komputerów w IAS w Princeton.

maszyna nie może wykonać? Powiedz mi, co to takiego, a stworzę komputer, który właśnie wykona to zadanie". To było dość optymistyczne spojrzenie na powstające wtedy komputery, chociaż znane już były problemy, które są nierozwiązywalne. A dzisiaj cała gama problemów NP-zupełnych i NP-trudnych nie poddaje się szybkim obliczeniom nawet dla niewielkich danych¹⁶.

Wielu wielkich myślicieli stawia jednak zdecydowane granice ekspansji AI. Autorowi, jako matematykowi, bliski jest pogląd Kurta Gödla¹⁷, że „ludzki umysł nieskończenie przewyższa moc jakiegokolwiek skończonej maszyny” (ang. *The human mind infinitely surpasses the powers of any finite machine*) – są to słowa wypowiedziane w 1951 roku jeszcze przed powołaniem do życia dziedziny AI – oraz opinia Rogera Penrose’a z 1996 roku, że „mamy dostęp do matematycznych prawd, które są poza zasięgiem możliwości jakiegokolwiek robota (ang. *We have access to mathematical truths that are beyond any robot’s capabilities*).

Docieramy wreszcie do Johna McCarthy’ego (1927–2011), informatyka, twórcy dziedziny AI, który w 1956 roku zorganizował w Dartmouth konferencję naukową, po raz pierwszy z AI w tytule. Inicjatorami tej konferencji byli również m.in. Marvin Minsky (1927–2016) z Harvardu i Claude Shannon z Bell Telephone Labs. McCarthy określił tę dziedzinę jako „naukę i inżynierię tworzenia inteligentnych maszyn”, czyli komputerów zachowujących się jak ludzie. Chciał tą nazwą odróżnić swoją inicjatywę od popularnej wtedy cybernetyki Norberta Wienera (1894–1964), która zajmowała się badaniem sterowania i komunikacji u zwierząt i maszyn.

Obecnie, w debacie publicznej i w odbiorze społecznym, sztuczna inteligencja podąża drogą, którą wcześniej rozwijały się (mikro)komputery osobiste (przez trzy ostatnie dekady XX wieku) i Internet (od ostatniej dekady XX wieku). Te dwie technologie powodowały duże zmiany technologiczno-społeczne, chociaż nie następowały znaczące przełomy w funkcjonowaniu społeczeństw, zwłaszcza w sferze edukacji, nauki, dobrobytu i aktywności umysłowej. Od jakiegoś czasu AI nabiera większego znaczenia społecznego niż wymienione dwie technologie, pozostające w wielorakich powiązaniach z AI m.in. jako narzędzia, środowisko i medium komunikacji. Historycznie nie powinno się jednak używać tych trzech technologii do określania kolejnych i rozłącznych epok, gdyż każda kolejna technologia faktycznie bazuje na wszystkich poprzednich. W szczególności systemy AI są systemami komputerowymi, a Internet jest dla nich medium komunikacyjnym, również w odbiorze przez osoby czy obiekty, na które wywiera wpływ.

2.2. Pierwsze przymiarki do komputerów w edukacji

Wzrost możliwości komputerów na przełomie dekady 1950–1960 zbiegł się z rosnącą popularnością nauczania programowanego. Na potrzeby edukacji rozpoczęł się rozwój systemu PLATO (ang. *Programmed Logic for Automated Teaching*

¹⁶ Przyjmując dzisiaj podejście zaprezentowane przez von Neumanna, można by odłożyć na jakiś czas problemy nierozwiązane i poczekać, aż pojawi się odpowiednia AI, która pomoże nam je rozwiązać. Jednak nawet poważne zajmowanie się rozwojem uczenia maszynowego nie powinno być wymówką przed tworzeniem wysokiej jakości i niezawodnych rozwiązań, np. w inżynierii oprogramowania.

¹⁷ Kurt Gödel (1906–1978), autor słynnego twierdzenia o niezupełności, z którego można wywnioskować, że żadnego komputera nie da się zaprogramować, by zdołał rozstrzygnąć wszystkie problemy matematyczne. Wyznacza to w pewnym sensie również granice informatyki oraz AI.

Operations – Programowana Logika dla Automatycznej Operacji Nauczania), będącego komputerowym wspomaganie nauczania (ang. *Computer Assisted Instruction* – CAI). Zagorzałym krytykiem systemów CAI był Seymour Papert (1928–2016), który przesiąknięty ideami konstruktywistycznymi uważał, że uczeń, jako użytkownik systemu typu CAI, zachowuje się biernie, wykonując głównie polecenia komputera. Przeciwwstawiając się rodzącym się pomysłom, by komputery, przynajmniej w jakimś zakresie, mogły przejąć rolę nauczyciela, odwrócił relację uczeń–komputer i pisał w swoich *Burzach mózgow* (Papert, 1980/1997):

Można by sądzić, że komputer jest wykorzystywany do programowania dziecka. W mojej wizji to dziecko programuje komputer [wyróżnienia Paperta].

I dalej¹⁸:

Komputer może być tworem, który posługuje się językiem matematycznym i alfabetycznym. Uczymy się, jak stworzyć komputery, z którymi dzieci lubiłyby się porozumiewać. Gdy już takie porozumienie zostaje nawiązane, dzieci uczą się matematyki tak jak żywego języka. Co więcej, porozumiewanie się w języku matematycznym i alfabetycznym ulega zmianie: z rzeczy całkowicie obcych, a więc trudnych dla większości dzieci, na rzeczy naturalne i dzięki temu łatwe. Pomysł komunikowania się z komputerem w „języku matematyki” można uogólnić na pomysł uczenia się matematyki w „Matlandii”, czyli w warunkach, które są dla uczenia się matematyki tym, czym mieszkanie we Francji jest dla uczenia się języka francuskiego.

W programowaniu, jako umiejętności wydawania poleceń komputerowi, Papert widział sposób na porozumiewanie się ucznia z komputerem w języku, który rozumieją obie strony. Stworzył w tym celu Logo¹⁹, pierwszy język programowania dla dzieci, który jest pomostem między ich światem a komputerami.

Z perspektywy czasu widać, że Papert wyprzedził swoją epokę, głosząc idee, które mogą być realizowane dopiero w XXI wieku, gdy uczeń może być współtwórcą treści i środowiska kształcenia. Nie uniknął jednak błędów. Mało realistycznie uważał, że już wtedy komputery plus Logo wzbogacą edukację w sytuacji, gdy nie było ani dostatecznej liczby komputerów w szkołach, ani one same nie umożliwiały tworzenia odpowiednich środowisk kształcenia oraz – co najważniejsze – nauczyciele nie byli przygotowani do realizacji jego pomysłów. Dekadę później, w kolejnej swojej książce Papert (1993) nie krył rozczarowania, że szkoły z tak wielkim oporem przyjmują jego idee. Stosują komputery, nie zmieniając nawyków tradycyjnej dydaktyki, nie modyfikując odpowiednio programów nauczania ani nie przygotowując nauczycieli na nowe wyzwania. Należy już teraz przedsięwziąć odpowiednie kroki, by nie popełnić podobnych błędów przy wprowadzaniu AI do szkół.

Warto wspomnieć, że w 1963 roku pionier AI Marvin Minsky zaprosił Paperta do współpracy i kierowania Laboratorium Sztucznej Inteligencji w MIT. W 1969 roku opublikowali książkę *Perceptrons*, poświęconą matematycznej analizie maszyny zbudowanej na bazie sztucznych sieci neuronowych do modelowania mózgu, która wywarła znaczący

¹⁸ Zafascynowanie Paperta Francją w tym cytacie można przypisać jego bliskim kontaktom z tym krajem w latach 1958–1963, gdy w pobliskiej Genewie współpracował z Jeanem Piagetem, ojcem konstruktywizmu.

¹⁹ Pomysł wprowadzenia do szkół języka programowania Logo z kolei nie podobał się wtedy twórcom systemów CAI, którzy uważali, że w szkole nie ma miejsca ani na programowanie komputerów, ani na informatykę.

wpływ na badania nad AI. Maszyna ta miała rozpoznawać ręcznie napisane cyfry od 0 do 9. W 1985 roku Papert utworzył Media Lab MIT, w którym wraz ze współpracownikami zajmował się epistemologią, nauczaniem i przyszłością uczenia się. Efektem prac tej grupy jest popularny dzisiaj wśród najmłodszych uczniów język Scratch, ideowy następcą Logo, za pomocą którego można porozumiewać się z większością robotów.

2.3. Co to jest sztuczna inteligencja?

Określenie, czym jest sztuczna inteligencja, wypada zacząć od wyjaśnienia, czym jest inteligencja, w domyśle – inteligencja człowieka.

W Wikipedii można znaleźć, że „inteligencja to [...] zdolność rozumienia, uczenia się oraz wykorzystywania posiadanej wiedzy i umiejętności w różnych sytuacjach²⁰. Edward Nęcka (2005) dyskutuje o inteligencji w szerszym kontekście i powiada, że „inteligentny człowiek to ktoś sprawnie przetwarzający informacje, dobrze rozwiązujący problemy, rozumiejący złożone kwestie i dobrze radzący sobie w sytuacjach nowych”. Zapytany „Czy maszyna może być inteligentna?” odpowiada tamże: „Uściślijmy, że nie chodzi po prostu o komputery, ale o programy komputerowe. Większość z nich nie jest inteligentna w takim sensie jak człowiek. Wykonuje tylko polecenia według zadanego porządku, czyli algorytmu”. W konkluzji stwierdza, że „[...] maszyna jest inteligentna inteligencją programisty”²¹. Wracamy jakby do przepowiedni Ady Lovelace z połowy XIX wieku.

Przechodząc do określenia sztucznej inteligencji, należy zacytować ważniejsze źródła. Na początek serwis sztucznaInteligencja.org.pl, w którym znaleźć można dział poświęcony również AI w edukacji. Słownik w tym serwisie może być także źródłem definicji wielu pojęć związanych z AI. W szczególności AI jest definiowana jako „naśladowanie przez maszyny, zwłaszcza systemy komputerowe, procesów decydujących o inteligencji człowieka. Inaczej mówiąc, sztuczna inteligencja to nauka o tym, jak produkować maszyny wyposażone w niektóre cechy ludzkiego umysłu, takie jak umiejętność rozumienia języka, rozpoznawania obrazów, rozwiązywania problemów i uczenia się”.

Na koniec warto powrócić do określenia AI podanego przez inicjatora tej dyscypliny, Johna McCarthy’go (Johnson, 2018, s. 15): „[...] koncepcje stworzenia programów komputerowych zdolnych do takiego zachowania, które uznalibyśmy za inteligentne, gdyby przejawiali je ludzie” to „proces, który sprawia, że maszyna zachowuje się w sposób, który nazwalibyśmy inteligentnym, gdyby w ten sposób zachowywał się człowiek”.

Powyższe określenia AI są bardzo pojemne, podobnie jak określenie ludzkiej inteligencji.

Przy okazji definiowania AI trzeba nadmienić, że informatycy mają cały czas kłopot ze zdefiniowaniem, czym jest informatyka, chociaż z pomocą przychodzi im

²⁰ Uczą się także zwierzęta – psy, koty czy nawet ptaki; zdobywają nową wiedzę i umiejętności, rozwijają się, coraz lepiej wykonując złożone czynności w jedzeniu i poruszaniu się.

²¹ W innej wypowiedzi E. Nęcka (2005) odniósł się do koncepcji inteligencji wielorakich Howarda Gardnera z 1983 roku i uznał, że są to po prostu wyodrębnione talenty lub specjalne zdolności. Można by je nazwać inteligentnymi, gdyby ich podłożem było myślenie, rozwiązywanie problemów lub inne czynności poznawcze.

oryginalny odpowiednik *computer science*. Można więc powiedzieć, że informatyka jest dziedziną zajmującą się nauką i praktyką związaną z komputerami, programowaniem komputerów (a faktycznie programowaniem algorytmów dla komputerów), sieciami komputerów oraz oczywiście budową i konstruowaniem coraz potężniejszych maszyn. W jakimś sensie narzędzie określa dziedzinę, ale niezupełnie. Jak mawiał E. W. Dijkstra: informatyka jest w takim samym sensie nauką o komputerach, jak biologia jest nauką o mikroskopach, a astronomia – nauką o teleskopach. A więc komputer to narzędzie, oczywiście mało inteligentne, by powołać się na Adę Lovelace, ale o szalenie dużych możliwościach. I właśnie inteligencja człowieka sięga po komputery, by stworzyć sztuczną inteligencję.

2.4. Uczenie maszynowe

Popularną technologią sztucznej inteligencji są sztuczne sieci neuronowe. Pomyśły dotyczące ich komputerowej realizacji rodziły się od początku ery komputerów. Sieci te stanowią podstawowy mechanizm uczenia maszynowego. Taka sieć jest systemem matematycznym, składającym się z wielu warstw sztucznych neuronów, między którymi biegną połączenia opatrzone pewnymi wagami, a system jest tak zbudowany, by maksymalizować określony cel. Te sieci nie są programowane w tradycyjny sposób według określonych algorytmów, ale są trenowane – można mówić o ich uczeniu się – za pomocą olbrzymiej ilości przykładowych danych i dostosowują wagi wewnętrznych połączeń tak, aby określić model, który będzie maksymalizował określony cel. W rezultacie macierz wag połączeń może zajmować gigabajty pamięci. W ten sposób są tworzone systemy, które same się uczą, jak mają się zachowywać w szczególności na danych, na których nie były trenowane – ekstrapolują wtedy to, „czego się nauczyły”²² (np. grając w szachy, malując obrazy).

Dość naturalnym wykorzystaniem uczenia maszynowego jest tworzenie informacji celowych (zindywidualizowanych) na podstawie olbrzymich zasobów danych gromadzonych w serwisach społecznościowych, systemach poczty elektronicznej, wyszukiwarkach internetowych, sieciach telefonów mobilnych. Jako rezultat otrzymujemy w miarę dokładnie adresowane do nas reklamy i rekomendacje (po ujawnieniu naszych zainteresowań), podejrzane maile są uznawane za spam, przeglądarki podpowiadają nam tematy poszukiwań, itd., itp. Nie mniej użyteczne są podpowiedzi słów w smartfonie podczas pisania wiadomości i wszelkiego typu programy pełniące rolę tłumaczy. Duże korzyści przynosi stosowanie uczenia maszynowego w handlu i w biznesie, zwłaszcza w większych firmach, dysponujących dużymi zasobami danych, zbieranymi podczas elektronicznej komunikacji z klientami.

W edukacji systemy uczenia maszynowego dopiero torują sobie drogę. Oczekuje się, że takie systemy okażą się bardzo pomocne w automatycznym ocenianiu uczniów, jak również w roli tutorów, czyli indywidualnych korepetytorów. W tym drugim przypadku może pojawić się wątpliwość w rodzaju: co było pierwsze, jajko czy kura. Tutor, np. języka angielskiego, będzie najpierw trenowany na różnych tekstach, następnie zaczną używać go uczniowie, a on nadal będzie się uczył na

²² Te dane do nauki, jak system ma się zachowywać, mogą być generowane przez ten sam system. Tak uczą się grać mistrzowskie systemy grające w szachy albo w Go – rozgrywając partie ze sobą.

danych, które będą dostarczali mu uczący się. W pewnym momencie może pojawić się wątpliwość, kto w tej sytuacji będzie kogo uczył?

3. Sztuczna inteligencja w szkole

Strategicznym wyzwaniem dla społeczeństwa jest to, by edukacja każdego obywatela rozciągała się od narodzin po grobową deskę – formalnie jako uczenie się przez całe życie (LLL – *lifelong learning*). Tutaj ograniczymy się do edukacji w K-12, a więc od przedszkola po koniec szkoły ponadpodstawowej²³, czyli do okresu edukacji formalnej, w przypadku naszego kraju – zarządzanej centralnie. Jej głównym dokumentem jest podstawa programowa określająca dla poszczególnych przedmiotów²⁴: cele kształcenia – wymagania ogólne – i treści nauczania – wymagania szczegółowe. Te drugie zapisy są sformułowane w języku osiągnięć uczniów. Podstawie dla poszczególnych etapów kształcenia towarzyszy opis warunków i sposobów jej realizacji. Informatyka jest wydzielonym przedmiotem od pierwszej po ostatnią klasę w szkole i przeznaczono na nią 1 godzinę zajęć tygodniowo. W szkole ponadpodstawowej uczeń może dodatkowo wybrać informatykę w zakresie rozszerzonym i zdawać maturę z tego przedmiotu.

Podstawa programowa z informatyki nie zawiera żadnych elementów sztucznej inteligencji²⁵, podobnie jest w podstawach (*curriculum*) przedmiotu *computer science* (w USA) i *computing* (w UK)²⁶. Powody tego stanu rzeczy są przynajmniej dwa: tradycyjne rozumienie informatyki w edukacji szkolnej, bazujące na klasycznej definicji algorytmu i programowania, oraz brak dostępu do rozwiązań AI adresowanych do uczniów w ich uczeniu się oraz do nauczycieli jako organizatorów procesu nauczania i uczenia się. Nawet jeśli takie się pojawiają, to nauczyciele nie są przygotowani do ich wdrożenia i stosowania.

W klasycznym rozumieniu algorytm to proces, który może wykonać Maszyna Turinga, czyli abstrakcyjny model komputera, składający się z jednostki sterującej, głowicy odczytującej i zapisującej oraz nieskończonej taśmy. W każdej komórce taśmy może się znaleźć jeden symbol, głowica jest ustawiona nad jedną z komórek i znajduje się w jednym ze stanów. W zależności od stanu i symbolu na taśmie, głowica może zapisać nową wartość w komórce, nad którą stoi, zmienia stan i może przesunąć się nad komórkę po prawej lub po lewej stronie. Taką pojedynczą operację można uznać za rozkaz dla tej maszyny, a listę wszystkich rozkazów traktować jako program.

Powyższe określenie obliczeń Alan Turing zdefiniował w 1936 roku w odniesieniu do obliczeń wykonywanych przez człowieka²⁷. Wiele innych modeli pojawiło się wcześniej i później, wszystkie były równoważne w sensie swojej mocy. Szkoła

²³ Ten okres edukacji określa się skrótem K-12, gdzie K to Kindergarten. Określenie to jest powszechnie stosowane w USA.

²⁴ W polskim systemie edukacyjnym utrzymuje się model uczenia osobno poszczególnych przedmiotów i związany z tym system klasowo-lekcyjny.

²⁵ Al występuje natomiast w podstawie przedmiotu etyka w szkole ponadpodstawowej, w wymaganiach szczegółowych działu Etyka a nauka i technika – uczeń: „identyfikuje i analizuje wybrane problemy moralne związane z postępem naukowo-technicznym (np. [...] rozwój sztucznej inteligencji [...]).” Do realizacji tego zapisu nie wystarczy jednak powierzchowna znajomość mechanizmów funkcjonowania rozwiązań sztucznej inteligencji.

²⁶ Al jest natomiast w narodowym programie nauczania w Chinach od 2018 roku (patrz Konox, 2020; Wang et al. 2020).

²⁷ Jeszcze w latach 60. w oxfordzkim słowniku języka angielskiego pierwszym znaczeniem słowa *computer* było – *a person who computes*, a dopiero drugim – *a tool for computing*.

oczywiście nie jest miejscem odwoływania się do tak elementarnych podstaw informatyki. Podobnie jak w innych kręgach użytkowników algorytmów, w szkole korzysta się z faktu, że algorytmy wykonujące podstawowe operacje arytmetyczne oraz logiczne i organizujące obliczenia za pomocą podstawowych konstrukcji programistycznych (jak iteracja i instrukcje warunkowe) mają swoją realizację w postaci Maszyny Turinga.

Od jakiegoś czasu pojęcie algorytmu zaczęło się rozszerzać, pojawiły się algorytmy interaktywne, przebiegające w czasie rzeczywistym, analogowe i hybrydowe, kwantowe i wiele innych. Maszyna Turinga nie jest już odpowiednim modelem dla tak poszerzonych obliczeń, np. jest w stanie jednocześnie uaktualniać wszystkie swoje komórki, jak to dzieje się w niektórych grach o przeżycie. W tej sytuacji za Davidem Harelem (1992) można przyjąć, że algorytm jest tworem, który może być wyrażony w języku programowania.

Efekty działania AI, w większości tylko obserwowane, mogą być w szkole okazją do znacznego poszerzenia pojęcia algorytmu i obliczeń. Najprostszym przykładem może tutaj być łatwy dostęp uczniów do posługiwania się zdarzeniami w programowaniu interakcji – jest to możliwe w Scratchu, w łamigłówkach code.org i w wielu innych środowiskach. To jest też prosty przykład komunikacji z komputerem, który niestety nie był obecny w czasach powstawania i rozwijania języka Logo, ale o którym zapewne myślał Papert, marząc, by to dziecko programowało komputer i komunikowało się z nim.

W podrozdziale 3.1 przedstawiono propozycję modułu zajęć, których celem jest przybliżenie AI uczniom w K-12 (zob. przyp. 23) na przykładach pewnych rozwiązań, dostępnych na poziomie szkolnym. Chociaż AI wyrosła na komputerach i jest „napędzana” ich mocą, proponowane zajęcia nie powinny być ograniczone tylko do informatyki, jako m.in. ilustracja potęgi tych maszyn. W każdej dziedzinie, w każdym szkolnym przedmiocie można znaleźć sytuacje, problemy i wyzwania rozwiązywane z wykorzystaniem AI. Poniżej przedstawiono wybrane przykłady, a pełniejsza ich lista będzie przedmiotem osobnego opracowania metodycznego do zaproponowanego modułu.

Jako że AI jest nierozzerwalnie kojarzona z komputerami, jej aspekty informatyczne, w szczególności algorytmiczne i programistyczne, polecamy na zajęcia z informatyki.

Rozwiązania sztucznej inteligencji nie są jeszcze elementem systemów zarządzania szkołą, nie dotarły również do nauczycieli, by mogli lepiej pomagać uczniom w uczeniu się. Tych zagadnień nie ma w proponowanym module, zaś w podrozdziale 4.4 opisano krótko ważniejsze z rozwiązań wraz z zachętą dla nauczycieli, by podjęli próbę włączenia ich do swojego warsztatu edukatora.

3.1. Sztuczna inteligencja w klasie

Edukacja od najmłodszych lat powinna kształcić umiejętność rozumienia AI i komunikowania się z systemami wykorzystującymi metody/algorytmy AI. Właściwe odczytywanie oraz interpretacja efektów działania sztucznej inteligencji jest warunkiem odpowiedniego i bezpiecznego korzystania z jej rozwiązań. Już dzisiaj

powszechne stają się rozwiązania bezobsługowe (kasy, samochody). Użytkownik powinien rozumieć, jak działają, a przez to mieć zaufanie do ich bezpiecznego i bezawaryjnego działania. Z drugiej strony ważne jest także poznanie, jak takie systemy powinny być i są budowane, by lepiej zrozumieć ich działanie. Wiele z tych elementów już można przekazywać uczniom w szkole.

Na co dzień uczniowie słyszą o AI i często uważają, że działa ona w telefonach, na ekranach komputerów, w urządzeniach domowych, które automatycznie reagują na warunki. W wielu takich przypadkach to zwykle efekt działania czujników i reakcji na ich wskazania. Wiele wyolbrzymionych, często magicznych wyobrażeń uczniów o sztucznej inteligencji pochodzi z lektur, książek, filmów i gier SF. AI w nich to bardziej wyobrażenia i wizje autorów niż realia, może to jednak być inspiracją dla uczniów na zajęciach w szkole, a przede wszystkim w przyszłości, gdy będą mieli okazję sami wymyślać, projektować i tworzyć rozwiązania z wykorzystaniem AI.

W niedalekiej przyszłości dotychczasowa znajomość technologii i jej praktycznych aspektów będzie musiała zostać poszerzona o podstawową wiedzę na temat AI. Już teraz należy zacząć przygotowywać uczniów od najmłodszych lat do korzystania z rozwiązań AI i poruszania się w świecie „napędzanym” AI, jednocześnie uczulając ich na aspekty etyczne i społeczne. AI ma możliwość zmiany form i organizacji nauczania i uczenia. Stanie się tak np., gdy w edukacji językowej zaczną być wykorzystywane aplikacje do rozpoznawania i przetwarzania języka naturalnego. Ta ekspansja sztucznej inteligencji wymaga uwzględnienia w podstawie programowej informatyki zapisów dotyczących AI. Ich realizacji powinno towarzyszyć wyprzedzająco zaopatrzenie szkół w odpowiednie urządzenia i oprogramowanie, a zwłaszcza przygotowanie i wsparcie nauczycieli.

Poniżej, w oparciu o propozycję CSTA (Computer Science Teachers Associated) (patrz: <https://github.com/touretzkyds/ai4k12/wiki> oraz Touretzky et al., 2019), przedstawiamy zarys tematyczny **Modułu AI**, adresowanego do szkół. Ta propozycja bazuje na 5 głównych ideach AI, które odnoszą się do najważniejszych aspektów AI i na tym etapie wprowadzania AI do szkół nie są zbyt zaawansowane dla nauczycieli. Taki moduł, uzupełniony o osiągnięcia uczniów, określający również zakres przygotowania nauczycieli i standardy wyposażenia szkół, powinien zostać przygotowany jak najprędzej, by móc rozpocząć jego pilotaż w szkołach.

W poniższych zapisach jest wiele elementów, które można odnaleźć w aktualnej podstawie programowej informatyki. W wielu przypadkach to kwestia położenia nacisku na odpowiednie cele kształcenia, metody pracy oraz wykorzystywane aplikacje i urządzenia oraz programowalne i „inteligentne” roboty.

1. Postrzeganie otoczenia

Komputery i roboty postrzegają i odbierają świat za pomocą czujników, w które są wyposażane, przeznaczonych m.in. do:

- rozpoznawania mowy lub twarzy,
- rozpoznawania obiektów, odczytywania i rozumienia otoczenia/scen,

- rozpoznawania innych form przekazu: dźwięków, temperatury, promieniowania itp.

Uczniowie powinni umieć określić typ czujników (samodzielnych i w innych urządzeniach), ich funkcje, przeznaczenie i ograniczenia.

2. Reprezentowanie, rozumowanie i podejmowanie decyzji

Agenci²⁸ komputerowi, dysponując reprezentacją i modelem otoczenia (świata), podejmują na ich podstawie decyzje. Dotyczy to m.in.:

- reprezentacji wiedzy, np. w postaci schematów graficznych,
- komputerowych sieci semantycznych, które rozumieją nasze pytania,
- wyszukiwania, w tym wyszukiwania heurystycznego,
- algorytmów wnioskowania, w tym w szczególności: dowodzenia twierdzeń, rozumowania i uzasadniania na podstawie reguł, optymalizacji, czyli efektywnych działań.

Uczniowie począwszy od 4 klasy szkoły podstawowej powinni umieć utworzyć logiczny schemat rozumowania i podejmowania decyzji, w szczególności drzewo wyszukiwania obiektów w różnych kontekstach sytuacji problemowych.

3. Uczenie się

Komputery mogą się uczyć na podstawie danych. Obejmuje to m.in.:

- uczenie maszynowe, w tym: klasyfikatory, dyskryminatory, przybliżenia funkcji; naukę o danych, zestawy treningowe,
- sieci neuronowe jako narzędzie wnioskowania na podstawie dużych zasobów danych.

Uczniowie powinni umieć szkolić klasyfikatora, w pierwszych dwóch klasach trenować dyskryminatora gestów, a w klasach 6–8 – definiować odpowiednie funkcje, trenując klasyfikatora w postaci drzewa decyzyjnego.

4. Naturalne interakcje

W ramach AI dąży się do stworzenia agentów, które w naturalny sposób będą oddziaływały z ludźmi, m.in. w zakresie:

- rozumienia języka naturalnego,

²⁸ Agent to program komputerowy, na ogół rozbudowany, działający w pewnym środowisku systemów oprogramowania, monitorujący swoje otoczenie i podejmujący autonomiczne decyzje dla osiągnięcia określonych dla niego celów działania.

- prowadzenia dialogu,
- afektywnych obliczeń,

interakcji człowieka z robotem.

Uczniowie w pierwszych dwóch klasach powinni umieć porozmawiać z agentem, a w klasach 6–8 – stworzyć prostego chatbota.

5. Konsekwencje społeczne

Sztuczna inteligencja może wpływać na społeczeństwo zarówno pozytywnie, jak i negatywnie, m.in. w zakresie:

- etyki, a w jej ramach na następujące zagadnienia:
 - ocena, które aplikacje są pożądane i dopuszczalne,
 - przejrzystość i odpowiedzialność systemów AI,
 - prywatność versus bezpieczeństwo,
 - określenie, kto powinien mieć dostęp do naszych danych i odpowiedzialnie zarządzać nim;
- spodziewanych efektów wpływania technologii AI na społeczeństwo, np.:
- robot jako pomoc, ratownik, współpracownik,
- efekty gospodarcze, zmiany w charakterze pracy,
- niezamierzonych konsekwencji.

Uczniowie, począwszy od klasy 6, powinni być w stanie zidentyfikować i opisać kwestie etyczne wywoływane przez aplikacje AI.

W realizacji powyższych celów kształcenia użyteczne mogą być odpowiednie aplikacje, z których wiele jest dostępnych w naszych szkołach (jak roboty), a do większości jest otwarty dostęp w sieci. Wśród nich można wyróżnić aplikacje do: (1) rozpoznawania i pamiętania twarzy, ludzi, (2) rozpoznawania i identyfikacji obiektów, manipulowania obiektami, np. robotami lub za pomocą robotów (np. przemysłowych), (3) nawigacji w terenie (robotami na zajęciach, samochodami, ludźmi), (4) automatycznego tłumaczenia tekstów (np. tłumacz Google), (5) generowania mowy, rozpoznawanie mowy (boty).

3.2. Wybrane propozycje zajęć

Przytaczamy tutaj wybrane przykłady wykorzystania AI w różnych sferach aktywności człowieka, które mogą się stać przedmiotem zajęć przybliżających AI i angażujących uczniów do aktywnego poznawania możliwości AI.

Roboty

Roboty to dzisiaj najpopularniejsze zabawki edukacyjne, wypełniające sale lekcyjne począwszy od przedszkoli, przez nauczanie wczesnoszkolne (klasy 1–3), po starsze klasy niemal do końca szkoły ponadpodstawowej. Bardziej zaawansowane ich konstrukcje są wykorzystywane i samodzielnie budowane w technikach, jako realizacja zapisów podstawy programowej informatyki: „Uczeń: [...] projektuje, tworzy i testuje oprogramowanie sterujące robotem lub innym obiektem na ekranie lub w rzeczywistości”. Stosowane roboty są wyposażone w różnorodne czujniki do rozpoznawania otoczenia, operują dźwiękiem oraz światłami, na ogół są programowalne w różnych językach, jak Scratch, Blockly, Python. Bardziej zaawansowane roboty, jak humanoidy, pozostają poza finansowym zasięgiem szkoły.

Gry z komputerem

Ciekawą opowieścią dla uczniów może być historia prób zautomatyzowania gry w szachy, co przyciągało najtęższe umysły matematyczne (więcej szczegółów na ten temat można przeczytać u Sysło (2019)). Na długo przed erą komputerów próbowano konstruować automaty szachowe, a pod koniec lat 40. maszynami szachowymi interesowali się Alan Turing i Claude Shannon. Turing napisał oprogramowanie do rozegrania pełnej partii szachów przez maszynę MADM, a Shannon zbudował maszynę Caissac do rozgrywania końcówek szachowych i w 1956 r. uruchomił program do gry w szachy na jednym z pierwszych komputerów MANIAC I. W 1950 r. Shannon oszacował, że wielkość drzewa przeszukiwań w tej grze wynosi 10120 (tzw. liczba Shannona), nie zachęca to jednak wielu amatorów do tworzenia programów komputerowych grających w szachy, opartych na pełnym przeglądzie przestrzeni możliwych sytuacji (tzw. *brute force*).

Pod koniec lat 80. w firmie IBM zaczęto tworzyć maszynę, która miała pokonać ówczesnego mistrza szachowego Garriego Kasparowa. Pierwszy mecz Kasparow wygrał 4:2 (1996), ale drugi pojedynek przegrał 3.5:2.5 (1997). Był to jednak sukces potęgi systemu obliczeniowego, potraktowano bowiem szachy jako złożony problem obliczeniowy, a nie wyzwanie z zakresu sztucznej inteligencji. Maszyna nie imitowała procesu myślowego i nie miała funkcji samodzielnego uczenia się, a jej moc polegała na wielkiej sile obliczeniowej (metodą *brute force*) oraz możliwości szybkiego korzystania z olbrzymiej ilości zgromadzonych danych o rozgrywkach szachowych.

Uczciwym wyzwaniem są mistrzostwa świata w szachach komputerowych. W połowie drugiej dekady tego stulecia mistrzem był program Stockfish 8, który dysponował dostępem do gromadzonych przez stulecia doświadczeń w grze w szachy i potrafił analizować 70 milionów pozycji na sekundę. Jednak pod koniec 2017 roku przegrał z programem AlphaZero stworzonym przez Google, który analizował tylko 80 tysięcy ruchów, nie dysponował danymi z innych partii, ale wykorzystał uczenie maszynowe, by opanować grę w szachy poprzez grę przeciw samemu sobie. Duże sukcesy w grze w Go, znacznie trudniejszej niż szachy, odniósł program AlphaGo stworzony przez firmę DeepMind należącą do Google, pokonując najlepszych graczy z Korei i Chin. Zastosowano

w nim algorytm będący kombinacją technik sieci neuronowych, uczenia maszynowego oraz wyszukiwania metodą Monte Carlo. Nasuwa się pytanie i wątpliwość o granice inteligencji tych programów. Czy na przykład AlphaGo jest na tyle inteligentny, aby usiąść do gry w szachy z AlphaZero i wygrać? Lub przynajmniej zagrać w warcaby i wygrać? Na czym polega inteligencja tych programów? Niestety te systemy, jak większość systemów AI, są bardzo wąsko wyspecjalizowane i daleko im do reprezentowania ogólnej AI²⁹.

Nie wchodząc w szczegóły tego, jak gra komputer, można zaproponować uczniom rozgrywanie partii szachów z komputerem na stronie www.chess.com/pl. W Internecie jest dostępnych wiele innych gier, które można polecić uczniom jako materiał do dyskusji, na ile komputer w tych grach wykazuje się inteligencją.

Test Turinga

Opisany w podrozdziale 3.1 test Turinga doczekał się współcześnie nowej wersji z odwróconymi rolami. W teście Turinga 2 program komputerowy podejmuje tekstowy dialog z człowiekiem i innym komputerem. Zadaniem programu jest odróżnienie człowieka od komputera. Popularną wersją tego testu jest CAPTCHA (ang. *Completely Automated Public Turing test to tell Computers and Humans Apart*), z którą uczniowie spotykają się w wielu serwisach internetowych. Najczęściej jest to wyświetlany zniekształcony obraz losowo wybranych znaków, a człowiek ma wpisać z klawiatury znaki poprawnie odczytane z obrazu. W innej wersji należy wpisać rozwiązanie prostego równania. Oczekuje się przy tym, że komputer nie jest w stanie „odczytać” obrazka lub znaleźć rozwiązania. Zdarza się jednak nieuczciwa gra komputera, gdy „prosi” on o odpowiedź osobę, do której nie jest skierowana prośba, o odpowiedni wpis.

Translator Google

Wśród wielu programów tłumaczących teksty na różne języki najpopularniejszym jest obecnie tłumacz Google na stronie translate.google.pl. Szacuje się, że dziennie korzysta z niego ponad 500 mln użytkowników posługujących się ponad 100 językami. Wcześniej ten translator bazował na tłumaczeniu fraza na frazę, a od 2016 r. wykorzystuje uczenie maszynowe. Uczy się stale na nowych tekstach wpisywanych do przetłumaczenia: pojedynczych słowach, parach słów, całych zdaniach. Każdy język ma swoją specyfikę, są różne alfabety (jak arabski, rosyjski, japoński, chiński), np. w języku niemieckim występują rodzajniki, a w polskim – przypadki. Język angielski jest pośrednim językiem w przypadku przekładów między dwoma innymi językami, można więc uznać, że przekłady, w których jednym z języków jest angielski, są najwierniejsze.

Komputerowy tłumacz jest znakomitym narzędziem przy posługiwaniu się językiem obcym, nie tylko w poprawnym jego stosowaniu, ale także przy kształceniu umiejętności korygowania (debugowania) tekstów. Uczniowie mogą także posługiwać się tym programem, pracując z tekstami źródłowymi w innych językach, nie znając ich.

²⁹ Ogólną AI utworzą, bo jeszcze ich nie ma, inteligentne systemy potrafiące samodzielnie myśleć i wykonywać zadania tak sprawnie jak człowiek, w tym także zadania, których wcześniej nie znały.

Posługiwanie się tłumaczem Google może być świetną okazją, wręcz lekcją, by uświadomić uczniom, że rozwiązania AI mogą być niedoskonałe w swojej inteligencji. Należy więc każde tłumaczenie zweryfikować i często poprawić. Na ogół ten program ma problem z idiomami, nie mówiąc o przysłowiach. Nauczył się już, że „it's raining cats and dogs” to po polsku „leje jak z cebra”, ale zapytany o przekład „raining cats and dogs” podaje „deszcz kotów i psów”, nie domyślając się naszej pomyłki. Nie kojarzy też, że „east or west home the best” to „wszędzie dobrze, ale w domu najlepiej”. Uczy się jednak, przyjmując poprawki i sugestie użytkowników. Przekładów raczej nie da się zalgorytmizować w pełni, nawet metodami sieci neuronowych, te bywają bowiem unikatowe. Trzeba go wytrenować na przekładach słów lub większych fragmentów o kulturowych odcieniach.

Dostępnych jest wiele programów tłumaczących nie tylko teksty drukowane, ale również odręczne pismo, strony internetowe, wypowiedzi słowne i inne formy przekazu.

Mapy Google

To kolejny serwis wykorzystujący uczenie maszynowe. Ta aplikacja i inne o podobnym przeznaczeniu są podstawą przy planowaniu i kierowaniu pojazdami z funkcją autonomicznego kierowcy. Często stosujemy takie systemy, żeby podpowiadały nam kolejne ruchy na drodze: jedź prosto czy skręć w prawo. Dodatkowo pokazany jest w nich przebieg całej trasy, przybliżony czas przejazdu, niektóre znaki drogowe (np. ograniczenie prędkości). Niestety, już się okazało, że całkowite zawierzenie takiemu systemowi w samochodzie autonomicznym może prowadzić do śmiertelnego wypadku.

Ciekawym ćwiczeniem z tym systemem może być przeprowadzenie przez uczniów eksperymentu, polegającego na weryfikacji parametrów ich różnych dróg z domu do szkoły różnymi środkami komunikacji: na piechotę, idąc po drodze po koleżankę, na rowerze, tramwajem, autobusem, rodzinnym samochodem.

Sztuka

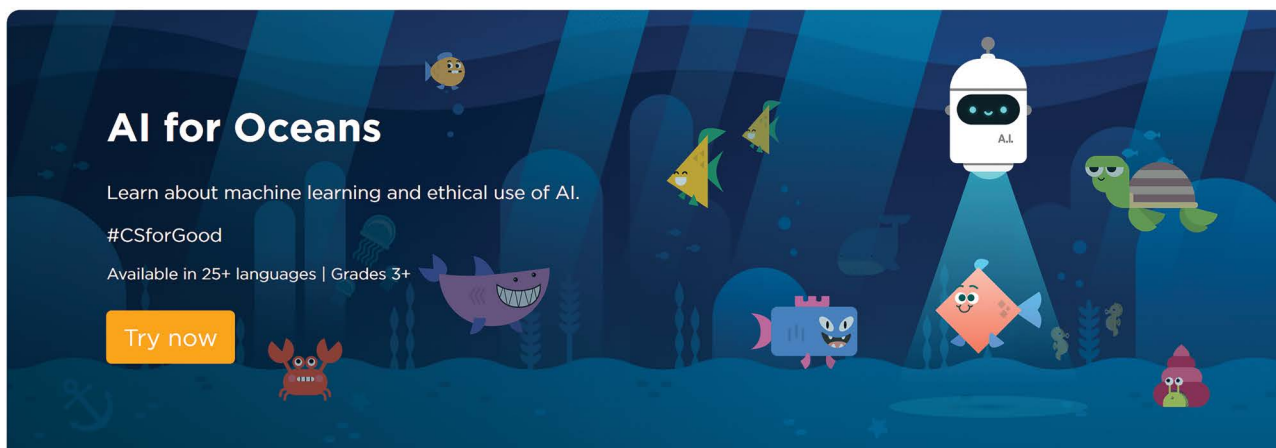
Świat obiegił obraz „Portret mężczyzny”, namalowany przez algorytm uczenia maszynowego, który, wystawiony za mniej niż 10 tys. dolarów, został sprzedany za 400 tys. dolarów. Portret ten powstał jako efekt uczenia maszynowego na podstawie danych zebranych z ponad 15 tysięcy innych portretów. Patrząc z boku, można by przyrównać proces powstawania tego dzieła do procesu, jaki towarzyszy artyście przy tworzeniu dzieł tradycyjną metodą. Artysta również ogląda wiele innych dzieł, rzeczywistych wzorów i wzorców, wykonuje wiele szkiców, zbiera w ten sposób dane do swojego dzieła.

Jednak tradycyjnemu artyście towarzyszy cały bagaż doświadczeń życiowych, dawnych i tych z chwili tworzenia. Maszynie jest to obce. Faktycznie dziełem sztuki nie jest sam obraz, ale cały proces jego powstawania. Różnice między procesami, tym tradycyjnym i wspartym AI, rzutują na finalny efekt. Zdaniem ekspertów (Hertzmann, 2020), współczesne technologie, takie jak AI, nie tworzą sztuki, są głównie narzędziem w rękach artystów. Sztuka jest bowiem aktywnością społeczną, a AI to nadal oprogramowanie.

Uczenie maszynowe

Uczniowie już teraz mogą być partnerami w tworzeniu rozwiązań AI, posługując się uczeniem maszynowym. Najprostsze przykłady takich możliwości oferuje środowisko code.org. Jest to zbiór łamigłówek „Sztuczna inteligencja dla oceanów” code.org/oceans. Podczas interaktywnej zabawy uczniowie uczą robota A.I., jak odróżniać ryby od zanieczyszczeń, aby robot usuwał śmieci z oceanów. Łamigłówkom towarzyszą filmy, z których uczniowie dowiadują się, co to jest AI, na czym polega uczenie maszynowe oraz co to są dane treningowe. Jednocześnie poznają, jak sztuczna inteligencja może być wykorzystywana do rozwiązywania rzeczywistych problemów na świecie. Te łamigłówki są przystępne nawet dla przedszkolaków. Rozwiązując je, dzieci mają okazję zrobić pierwsze kroki w poznawaniu metod i zastosowań AI.

Fot. 1. „Sztuczna inteligencja dla oceanów” code.org/oceans



3.3. AI a kształcenie informatyczne

Wiele aktywności uczniów wymienionych w podrozdziale 3.1. pojawia się w kształceniu informatycznym, w którym podstawowym podejściem do rozwiązywania problemów i realizacji projektów jest myślenie komputacyjne. To jest kolejny argument za tym, by szkolne zajęcia związane z AI były ściśle związane z informatyką. Praktyce edukacyjnej związanej z myśleniem komputacyjnym będzie poświęcona książka Sysło (2022). O myśleniu komputacyjnym pisał Seymour Papert (1980/1997), znacznie wyprzedzając swoimi ideami konstruktywistycznymi możliwości technologii. Odgrzewając to pojęcie w 2006 roku, Jeanette Wing (2022) określiła tym terminem „użyteczne postawy i umiejętności, jakie każdy, nie tylko informatyk, powinien starać się wykształcić i stosować”. Nie należy więc traktować tego pojęcia jako skrótu od „myśleć jak informatyk”. Przyjmuje się obecnie, że:

myślenie komputacyjne to procesy myślowe angażowane w formułowanie problemu i przedstawianie jego rozwiązania w taki sposób, aby komputer – człowiek lub maszyna – mógł skutecznie je wykonać.

Za najważniejsze metody rozumowania (*mental tools*) w myśleniu komputacyjnym uznaje się (Sysło, 2018):

- abstrakcję – umożliwiającą modelowanie najważniejszych cech badanej sytuacji problemowej, przy zaniechaniu cech drugorzędnych;
- rozpoznawanie wzorów i wzorców – wzorce mogą umożliwić modelowanie, algorytmizację i analizę, a później – automatyzację obliczeń;
- redukcję i dekompozycję złożonego problemu na mniejsze podproblemy, których rozwiązania są znane lub łatwiejsze do rozwiązania;
- algorytmizację, czyli tworzenie procedur dla podejmowania decyzji na podstawie odpowiednio przygotowanych danych;
- uogólnianie, czyli przenoszenie efektów rozumowania na sytuacje ogólniejsze, bogatsze.

Podstawową rolę w przetwarzaniu dużych ilości danych, które ma miejsce w uczeniu maszynowym, odgrywa abstrakcja, czyli pomijanie drugorzędnych cech danych, rozpoznawanie w nich wzorców z jednoczesnym przyjęciem odpowiedniej ich reprezentacji dla dalszego przetwarzania. Wstępną analizę danych ułatwia ich dekompozycja pod względem posiadanych cech. Abstrakcja i dekompozycja w uczeniu maszynowym odgrywają rolę przygotowania danych do dalszego przetwarzania w odpowiednio budowanych sieciach neuronowych, które można uznać za algorytm całego systemu AI. Najważniejszą cechą systemu uczenia maszynowego, zresztą każdego uczenia się, jest umiejętność generalizacji (uogólniania), umożliwiająca zastosowanie zdobytych doświadczeń do bieżących, na ogół nowych sytuacji. W uczeniu maszynowym te doświadczenia to efekt treningu, a uogólnienia to decyzje podejmowane przez system dla nowych danych.

3.4. Sztuczna inteligencja w rękach nauczyciela, w szkole

Ze względu na stale rosnącą obecność AI w naszym otoczeniu, powinniśmy określić miejsce dla AI w edukacji i jej wkład, jak również rolę tradycyjnej edukacji w *środowisku* wypełnianym przez AI. Przydatna może być też wiedza o korzyściach użycia AI w administrowaniu procesem edukacji. Nie mniej ważne są kwestie etyczne, np. odnoszące się do celu i zakresu wykorzystywania danych zbieranych przez AI.

Odzywają stare wątpliwości, czy tym razem rozwiązania AI nie zastąpią nauczyciela, jeśli nie w pełni, to w jakim możliwym zakresie. Co wtedy z odpowiedzialnością za wyniki kształcenia, kompetencje uczniów, ich wychowanie? Generalnie, jeśli AI w wielu obszarach zmierza do zastępowania lub przynajmniej wyręczania człowieka, to edukacja musi przemyśleć, jakie kompetencje powinien posiadać człowiek w *środowisku* rozwiązań AI.

Jak zawsze, i jest to powtarzane przy każdej nowej technologii czy metodzie kształcenia, zapewnia się, że jej celem jest poprawa warunków i sposobów uczenia się oraz osiągnięcie przez uczniów lepszych wyników. Nauczycielom zaś mówi się,

że celem technologii nie jest zastąpienie ich tą technologią. Nauczyciele są jednak świadomi, że każda nowa technologia to nowe obowiązki, nie tylko związane z koniecznością doksztalcenia się, ale także z codziennymi obowiązkami w klasie i poza nią. AI nie będzie tutaj wyjątkiem, a wręcz wydaje się, że będzie wymagać od nauczycieli znacznie większego przygotowania warsztatowego. I nie dotyczy to tylko nauczycieli informatyki, którzy będą przybliżali uczniom, jak działa AI, ale wszystkich nauczycieli, gdy nadzorowane/prowadzone przez nich zajęcia będą przebiegały w środowisku rozwiązań AI. Nie ma jeszcze żadnych badań na dużą skalę, pokazujących korzyści ze środowisk uczenia się wspartych AI.

Największe szanse w zastosowaniach AI w edukacji upatruje się w systemach adaptacyjnego (maszynowego) uczenia się, które dostosowują metody i materiały nauczania i uczenia się do możliwości i potrzeb każdego indywidualnego uczącego się³⁰. W takim systemie świat zewnętrzny jest reprezentowany przez trzy modele: pedagogiczny – który określa dydaktyczne metody nauczania i uczenia się, dziedzinowy – jest to wiedza dotycząca dziedziny kształcenia, i uczenia się – zawiera informacje o działaniach i postępach uczniów. Taki system może być stosowany w klasie, jak również w przypadkach indywidualnych tutorów. Przykładowy system, dotyczący uczenia się o ułamkach, jest dostępny w prezentacji, do której odsyła pozycja 3 w podrozdziale „Polecamy” (s. 98). Inną popularną dziedziną takich systemów są języki obce. Osobisty tutor jest zwykle systemem otwartym w tym sensie, że umożliwia dialog z uczącym się, zadawanie pytań i dyskusję, weryfikację rozwiązań i dynamiczną pomoc. W każdym przypadku stosowania takiego systemu uczy się on na danych związanych ze środowiskiem, w którym jest stosowany.

Systemy adaptacyjne mają wiele zalet, głównie dla uczących się – umożliwiają uczniom spersonalizowane, elastyczne i angażujące uczenie się. Wspierać mogą również współpracę, pracę w grupach, świetnie nadają się do pracy metodą projektów. Jeśli chodzi o nauczycieli, takie systemy mogą być katalizatorem zmian ich roli w nauczaniu. Wymaga to jednak znacznych przygotowań do posługiwania się takimi systemami. Nauczyciel powinien znać i rozumieć rolę takiego systemu, poznać interpretację danych i wyników, jakie dostarcza, umieć formułować odpowiednie pytania do systemu, a także współpracować z asystentem takiego systemu, będącym jego integralną częścią (inteligencją). Obecnie droga do takich systemów w klasie wydaje się długa: stworzenie systemu, przygotowanie nauczyciela, nauczenie systemu na danych z klasy, wreszcie zajęcia z klasą. Tę drogę może wydłużyć niezbędna rozbudowa środowisk AI w szkołach, co w tym momencie wydaje się mało realne, chociaż rezygnacja z systemu klasowo-lekcyjnego i szkoły niewiele skróci tę drogę. Rzeczywisty postęp mogłyby przyspieszyć wyniki badań prognostycznych, które określałyby mapę drogową szkół do stopniowego nasycenia technologią AI.

Nie mniej ważne niż aspekty techniczne i logistyczne są kwestie etyczne stosowania sztucznej inteligencji w edukacji. Możemy mieć wątpliwości co do przejrzystości działania systemów AI, rozumienia podejmowanych przez nich decyzji, przewidywalności, możliwość ich audytu, czyli kontroli oraz nadzoru nad ich działaniem. Po stronie nauczyciela jest zaś odpowiedzialność za wyniki kształcenia. A jeśli taki

³⁰ Podobna idea przyświecała twórcom systemu PLATO (Sysło, 2022), nie dysponował on jednak takimi narzędziami jak sieci neuronowe, by się mógł uczyć, jak najlepiej pomagać uczącym się.

system z jakichś powodów zacznie źle działać, z powodu błędów w „algorytmie” lub umyślnego działania? Takie przypadki już się zdarzały. Jednym z ważniejszych problemów jest również ochrona danych osobowych nauczycieli i osób uczących się oraz prawo dostępu do nich i ich wykorzystania. Jest jeszcze wiele innych problemów, z którymi przyjdzie się zmierzyć AI w swej ekspansji w obszarze edukacji, na przykład zapewnienie równych szans wszystkim uczącym się, w szkole i poza nią³¹.

4. Zagrożenia i wyzwania

4.1. Zagrożenia

Wraz ze wzrostem wpływu rozwiązań AI na codzienne życie jednostek, społeczności i całych społeczeństw, coraz poważniejsze stają się kwestie etyczne, prawne i społeczne. Skomentujemy tutaj kilka medialnych informacji związanych z AI dotyczących jej wpływu i jej postrzegania.

1. Na pierwszej stronie jednej z broszur Google (*Graw with Google*) można przeczytać, że „Google dokłada wszelkich starań, aby wszyscy czerpali korzyści z możliwości, jakie stwarza nowa technologia (ang. *Google is committed to making sure everyone benefits from the opportunities created by new technology*). A na ostatniej stronie tej broszury czytamy, że „Zawsze nas inspiruje, kiedy widzimy, co ludzie robią, gdy mają dostęp do technologii” (ang. *We are always inspired to see what people do when they have access to technology*). Google jest więc zainteresowany podglądaniem nas (*see what people do*) i to go inspiruje do działania (*We are always inspired*)! Podglądani na ogół nie są świadomi tego podglądania (czytaj – korzystania z danych, które pozostawiają w sieci, nie zawsze świadomie) i nie wiedzą, do czego zostaną wykorzystane te dane.

2. Można mieć wątpliwości, czy każde rozwiązanie z zakresu AI jest rzeczywiście przejawem inteligencji. Czy jest tym bot wytworzony przez osobę, która nie grzeszy inteligencją? Kto ma to ocenić? Maszyna? Samo posłużenie się inteligentnym narzędziem nie gwarantuje tego samego w finalnym wytworze. A w odniesieniu do edukacji – jak można ocenić metodyczną poprawność tutora AI, po wynikach uczniów? A może tutora AI będzie oceniał wizytator AI?

5. Autonomiczny samochód Ubera zabił już pieszego w Arizonie – system pokładowy zbyt dużo czasu spędził na analizie „obiektu”, który „widział” przed sobą, zamiast natychmiast zatrzymać się. Kto ponosi odpowiedzialność za taki wypadek? Właściciel (może nim być wypożyczalnia), pasażerowie, konstruktor, a może programista?

Nie będziemy dalej mnożyć przykładów na niekorzyść AI. Edukacja ma na szczęście dobrze określone cele, których realizacja ma wskazać uczniowi pożytki z AI w bliższym i dalszym otoczeniu i właściwe sposoby korzystania z niej. Ma również zwrócić uwagę na aspekty etyczne i społeczne oraz na zagrożenia. Polem ekspansji AI, może w jeszcze większym stopniu niż w edukacji, jest niemal każdy aspekt współczesności. Można mieć tylko nadzieję, że postawa uczniów wyniesiona ze

³¹ Szczegółowe omówienie możliwości, problemów i zagrożeń związanych z uczeniem maszynowym zaprezentowała w raporcie Webb i in. (2020) grupa ekspertów związanych z Technical Committee on Education federacji IFIP.

szkoły skieruje ich zainteresowania na właściwe tory wykorzystania współczesnej technologii w coraz większym stopniu „naszpikowanej” rozwiązaniami AI i przeważą w tym ich ludzka inteligencja i wrażliwość.

4.2. Wyzwania

Przy korzystaniu z rozwiązań AI jednym z poważniejszych problemów jest zrozumienie i akceptacja decyzji podejmowanych przez systemy AI. Problem związany z automatyzacją decyzji nie jest całkowicie nowy. Nawet jeśli jedna ze stron podejmuje decyzje, bazując na możliwym do odczytania i zrozumienia w pełni modelu decyzyjnym, druga strona może mieć wątpliwości co do słuszności podejmowanych decyzji: dlaczego użyto właśnie takiego modelu, takiej a nie innej metody wnioskowania? Głośny był w USA sprzeciw przyszłych lekarzy, gdy zaczęto ich przydzielać do szpitali, stosując metodę bazującą na technice stabilnych związków³². Protestowano, odwołując się do argumentów czysto życiowych – dlaczego po tylu latach kształcenia decyzja o ich losie jest podejmowana przez jakiś algorytm?! Była to sytuacja, gdy obie strony ujawniały i w pełni znały swoje preferencje, „algorytm” również był jawny, jednak lekarze uznawali decyzje o ich zatrudnieniu za niesprawiedliwe społecznie, nie wątpiąc przy tym w słuszność podejścia, że obie strony, lekarze i szpitale, chcą tak się dobrać, by zapewnić sobie stabilne warunki pracy, tzn. zadowolenie obu stron. Winien był algorytm.

W powyższym przypadku w miarę łatwo jest uzasadnić podejmowaną decyzję. Dodatkowo, można operować pewną gamą rozwiązań, od optymalnych dla szpitali po optymalne dla kandydatów. Ponadto można wprowadzić dodatkową funkcję jakości wszystkich przydziałów i sparametryzować jej współczynniki. Te elementy podejmowania decyzji mogą być nadal w pełni jawne, jednak im bardziej złożony model, tym trudniej jest go zrozumieć i zaakceptować drugiej stronie.

Modele i metody AI przestają być tak transparentne, jak te oparte na prostych modelach decyzyjnych bazujących na metodach optymalizacji, nawet wielokryterialnych. Trudniejsza staje się też ingerencja w te modele i przekonujące wyjaśnienie ich działania. Dodatkowe wyjaśnienia i ingerencje w model mogą jednak służyć uratowaniu go w opinii jego użytkowników.

4.3. Uczenie maszynowe

Uczenie maszynowe jest także przedmiotem badań³³, które wskazują na jego teoretyczne bariery.

W aspekcie praktycznym najpoważniejszym ograniczeniem i wadą uczenia maszynowego jest brak przejrzystości (*transparency*) w ich działaniu – użytkownicy nie mają bowiem dostępu do wyjaśnienia, w jaki sposób są podejmowane decyzje.

³² Ta metoda jest oparta na strategii, która, akceptując preferencje obu stron, przydziela lekarzy do szpitali tak, aby ten przydział był dla obu stron stabilny, by się „nie rozchodzili” (*stable marriage*). Podstawy teoretyczne tej metody stworzyli David Gale i Lloyd Shapley w 1962 roku, za co po pięćdziesięciu latach w 2012 roku L. Shapley (D. Gale już nie żył) otrzymał Nagrodę Nobla w dziedzinie ekonomii za teorię stabilnych przydziałów.

³³ Na początku 2019 roku wykazano (Ben-David et al., 2019), że rozwiązanie problemu estimating the maximum za pomocą uczenia maszynowego jest równoważne hipotezie kontinuum w teorii mnogości – nie można więc stwierdzić, czy ten problem ma rozwiązanie, czy go nie ma. To jedna z teoretycznych barier uczenia maszynowego.

Największym wyzwaniem jest więc obecnie umożliwienie użytkownikom systemów AI opartych na tej technologii pełnego zrozumienia ich działania, co jest niezbędne dla uzyskania pełnego zaufania. W przypadku tradycyjnych algorytmów, programista ma pełny wgląd w kod aplikacji, może go objaśnić i ewentualnie naprawić błąd lub zmodyfikować algorytm. W przypadku algorytmów AI opartych na neuronowych sieciach uczących się, ich operator może jedynie mieć wgląd w olbrzymią macierz wag, która jednak nie daje pełnego wyjaśnienia, w jaki sposób pojawiają się mniej lub bardziej nieoczekiwane decyzje. Brak jest takim systemom warstwy, która mogłaby służyć za wyjaśnienie działania całego systemu. Jest to niezbędne w sferze edukacji, aby nauczyciel wspomagany takim systemem AI potrafił wyjaśnić swoją decyzję uczniom i ich rodzicom.

Zgodnie ze stanowiskiem ACM (2017), „Modele obliczeniowe mogą zostać zniekształcone w wyniku błędów w danych i/lub w algorytmach”, co w konsekwencji może powodować, że „zautomatyzowane podejmowanie decyzji odnośnie do pojedynczych osób może prowadzić do ich bolesnej dyskryminacji”. Najpotężniejsi gracze w obszarze AI, jak Facebook, GitHub, Google, IBM wykorzystują już rozwiązania, które służą wykrywaniu i zapobieganiu stronniczości i uprzedzeń (*AI bias*) w rozwiązaniach AI na drodze do zapewnienia uczciwości i sprawiedliwości takich systemów (*AI fairness*) (Johnson, 2018). Niezbędne jest, by takie rozwiązania jak najszybciej trafiły do systemów AI w edukacji, stosowanych na skalę indywidualną (np. jako tutor) i globalną (w warunkach szkolnych).

Innym wyzwaniem w uczeniu maszynowym jest radzenie sobie z problemami, które są związane z jakością danych. Systemy oparte na uczeniu maszynowym są bardzo czułe na małe zmiany w danych treningowych, mogą łatwo powielać błędy w danych i na ogół nie potrafią rozstrzygać sporów w danych na określony temat, pochodzących z różnych źródeł. Z tego względu bardzo poważne zastrzeżenia budzi wykorzystanie uczących się systemów w dziedzinach odpowiedzialnych za przestrzeganie prawa i bezpieczeństwa, jak sądownictwo, policja i wojsko. Niemniej poważny jest problem etyczny – systemy trenowane na danych z uprzedzeniami (kulturowymi, rasowymi) i tendencjami, mogą wykazywać te uprzedzenia i tendencje w użyciu. Autorzy zbiorczego zestawienia 10 dylematów związanych ze stosowaniem systemów AI (Denning et al., 2020) podkreślają, że do większości przypadków ma zastosowanie pierwsze prawo Asimova: „bez względu na to, jakie działanie zostanie podjęte (lub nie), ucierpi człowiek (ang. *no matter what action is taken (or not taken), a human will get hurt*).

Bardzo poważnym problemem w sferze edukacji jest ograniczona przenoszalność (*portability*) systemów AI – utworzone, czyli wytrenowane dla jednych warunków (uczniów, nauczycieli, szkoły) na ogół są bezużyteczne dla innych grup użytkowników. Tutor matematyki dla Jasia nie zrozumie problemów z matematyką Marysi, będzie musiał długo się z nią sam uczyć, chociaż matematyka będzie ta sama. Podobnie z tutorem języka angielskiego. Translator Google pokazuje, że można być inteligentnym w kilku językach, chociaż trudno jest ocenić, w jakim stylu przemawia do nas ten tłumacz. Zakres dziedzinowy (przedmiotów szkolnych) jest w miarę łatwy do odpowiedniego zakodowania w systemie AI, zaś metodyka i personalizacja to bardzo indywidualne cechy. Ich poznanie, jeśli w ogóle jest możliwe, wymaga bardzo rozległych szkoleń takiego systemu. Dopiero ogólna sztuczna inteligencja być może będzie mogła temu zaradzić.

Podsumowanie

Uczniowie obecnie niemal na co dzień stykają się z urządzeniami, których efekty działań mogą odbierać jako przejawy inteligencji. Ten rozdział dostarcza argumentów na korzyść włączenia sztucznej inteligencji do programów nauczania w szkołach. Środowisko edukacji informatycznej proponuje, by po uwzględnieniu związku AI z komputerami i informatyką, odpowiedni moduł AI wszedł w zakres kształcenia informatycznego (zajęć z informatyki), a ponadto by integrował się z innymi przedmiotami. Strukturę takiego modułu zaczerpnięto z energicznie rozwijanych propozycji amerykańskich, jednak jego wdrożenie będzie wymagać uwzględnienia obowiązującej podstawy programowej z informatyki i innych przedmiotów. Tę propozycję rozwiązań programowych uzupełniono przykładami środowisk, w których uczniowie już teraz mogą rozwijać znajomość AI, jak również zwracać uwagę na istotne aspekty społeczne związane z ekspansją AI. Wskazano także obszary, w których rozwiązania korzystające z AI mogą mieć znaczący wpływ na pracę nauczycieli i na funkcjonowanie szkoły, chociaż nie wydaje się, by w najbliższej przyszłości AI mogło zagrozić roli nauczycieli w kształceniu. Krótko odniesiono się również do zagrożeń związanych z AI oraz wyzwania, jakie stwarza stosowanie rozwiązań wykorzystujących AI.

Rozważania w tym rozdziale są w wielu miejscach prowadzone na tle historycznego rozwoju AI oraz jej powiązań z matematyką i informatyką – dziedzinami, na których wyrastała i nadal ma z nimi związek. Te powiązania dotyczą zarówno aspektów naukowych, jak i edukacji, w której ekspansji komputerów towarzyszą przedsięwzięcia czyniące z nich urządzenia bardziej inteligentne, wspomagające nauczyciela i uczniów w ich działaniach prowadzących do lepszych efektów kształcenia.

Bibliografia

ACM (2017). *Statement on Algorithmic Transparency and Accountability*, ACM U.S. Public Policy Council, ACM Europe Policy Committee. Pobrano z: <https://www.acm.org/articles/bulletins/2017/january/usacm-statement-algorithmic-accountability>

AI4K12: <https://github.com/touretzkyds/ai4k12/wiki>

Ben-David, S., Hrubec, P., Moran, S., Shpilka, A. and Yehudayoff, A. (2019). Learnability can be undecidable, *Nature Machine Intelligence* 1/2019, 44–48.

Denning, P.J. and Denning, D.E. (2020). Dilemmas of Artificial Intelligence, *CACM* No. 3, 63(2020), 22–24.

Feigenbaum, E. and Feldman, J. (red.). (1972). *Maszyny matematyczne i myślenie*. Warszawa: PWN.

Harel, D. (1992). *Algorytmika. Rzecz o istocie informatyki*. Warszawa: Wydawnictwo Naukowo-Techniczne.

- Hertzmann, A. (2020) Computers do not make art., people do. *CACM* 5, 63. 45–48.
- Holmes, W., Bialik, M. and Hadel, C. (2021). *Artificial Intelligence in Education. Promises and Implications for Teaching and Learning*, Boston: Center for Curriculum Redesign.
- Johnson, R.C. (2018). Overcoming AI Bias with AI Fairness, *CACM News*.
- Kaplan, J. (2019). *Sztuczna inteligencja*. Warszawa: PWN.
- Knox, J. (2020). Artificial intelligence and education in China, *Learning, Media and Technology*. DOI: 10.1080/17439884.2020.1754236
- Lane, D. (2021). *Machine Learning for Kids*. San Francisco: No Starch Press [książce towarzyszy serwis <https://machinelearningforkids.co.uk/>]
- Moursund, D. (2021). *The Future of AI in Our Schools*, http://iae-pedia.org/The_Future_of_AI_in_Our_Schools
- Nęcka, E. (2020). *Pobudzenie intelektu. Zarys formalnej teorii inteligencji*. Kraków: Univeritas.
- Nęcka, E. (2005). *Człowiek – umysł – maszyna*. Kraków: Znak.
- Papert, S. (1997). *Burze mózgów*. Warszawa: WN PWN [oryginalne wydanie BasicBooks 1980].
- Papert, S. (1993). *The Children's Machine. Rethinking School in the Age of the Computer*. BasicBooks. New York: MSY.
- Sztuczna inteligencja: <https://www.sztucznainteligencja.org.pl/>
- Syso, M. M. (2018). Jak myśleć komputacyjnie [materiały z konferencji „Informatyka w Edukacji, XV”, UMK Toruń 2018, s. 3–14].
- Syso, M. M. (2019). Inteligencja+ [materiały z konferencji „Informatyka w Edukacji, XVI”, UMK Toruń 2019, 5–17].
- Syso, M. M. (2022). *Myślenie komputacyjne w praktyce edukacyjnej*, PWN [w przygotowaniu].
- Touretzky, D., Gardner-McCune, C., Martin, F., Seehorn D. (2019), Envisioning AI for K-12: What should every child know about AI?, 33rd AAAI Conference on AI, 9795–9799.
- Walsh, T. (2018). *To żyje! Sztuczna inteligencja*. Warszawa: PWN.
- Webb, M. E. Fluck, A., Magenheimer, J., Malyn-Smith, J., Waters, J., Deschênes, M., Zagami, J. (2020). Machine learning for human learners: opportunities, issues, tensions and treats, *Education Tech Research Dev*, Springer 2020.

Wing J., Computational thinking benefits society. Blog: Social Issues in Computing, <http://socialissues.cs.toronto.edu/index.html%3Fp=279.html> 08.03.2022.

Wong, G. K. W., Ma, X., Dillenbourg, P., Huan, J. (2020). Broadening Artificial Intelligence Education in K-12: Where to Start? *ACM Inroads* 1, 11(2020), 20–29.

Zimmerman, M. (2018). *Teaching AI. Exploring new frontiers for learning*. ISTE.

Polecamy

Wymieniamy tutaj wybrane inicjatywy związane ze sztuczną inteligencją, odnoszące się do edukacji.

Finlandia: postawiła bardzo ambitne wyzwanie, by nauczyć podstaw sztucznej inteligencji 1% swoich obywateli. Na stronie: <https://course.elementsofai.com/pl/>, dzięki funduszom europejskim, ten kurs jest dostępny po polsku.

Kurs „Podstawy sztucznej inteligencji”:

https://navoica.pl/courses/course-v1:OPI_PIB_DZI+Podstawy_SI+Podstawy_SI_02/about

Prezentacja nt. AI: <https://www.youtube.com/watch?v=osqV6AT1Rhw>. Wykład „Inteligencja dla prawie początkującego programisty” A. Borowieckiej i K. Olędzkiej.

Nauka matematyki: <https://www.italk2learn.com/> – inteligentna platforma korepetycji (*intelligent tutoring platform*) typu *open-source*, która wspiera naukę matematyki dla uczniów w wieku od 5 do 11 lat.

Film poświęcony współpracy firmy Intel z PCSS przy realizacji projektów poświęconych AI, w których biorą udział nauczyciele i uczniowie szkół ponadpodstawowych: <http://www.bbc.com/storyworks/digitally-enlightened/intel>

<https://raise.mit.edu> – inicjatywa MIT – Responsible AI for Social Empowerment and Education (M. Resnick) – opis wielu projektów edukacyjnych.

<https://oecd.ai/en/> – strona OECD zawierająca rekomendacje dotyczące AI.

Obszerny blog Ryszarda Tadeusiewicza, poświęcony sztucznej inteligencji: <https://natemat.pl/blogi/ryszardtadeusiewicz/174271,uporzadkowane-wiadomosci-na-temat-sztucznej-inteligencji>

Edukacja cyfrowa: e-learning, blended learning

prof. dr hab. Dariusz Jemielniak*

Wprowadzenie

Rok 2020 przyniósł ogromne zmiany dla świata, w tym także dla edukacji cyfrowej. Jednym z niewielu pozytywów tej – dla większości pozostałych obszarów katastrofalnej – sytuacji okazało się podniesienie poziomu kompetencji cyfrowych bardzo dużej liczby osób, które przeszły w tryb nauki zdalnej.

To o tyle istotne, że sama dostępność narzędzi i technologii nigdy nie przesądza o faktycznej zmianie kulturowej i behawioralnej – zazwyczaj potrzebne są dziesięciolecia drobnych adaptacji. Tymczasem pandemia COVID-19 wymusiła na większości ludzi gwałtowne dostosowanie się do realiów komunikacji wirtualnej, a także zaznajomienie z istniejącymi narzędziami edukacji cyfrowej.

Jednocześnie pandemia uświadomiła nam, w jak dużym stopniu te istniejące narzędzia są nieadekwatne i niedoskonałe (Almaiah et al., 2020).

W niniejszym tekście przyjrę się uwarunkowaniom prawnym edukacji cyfrowej i jej otoczeniu rynkowemu, aby następnie przedstawić możliwą przyszłość edukacji, w tym wykorzystującą AI, a także nieodległą przyszłość rozwoju edukacji cyfrowej.

Otoczenie prawne

Uchwała nr 196 Rady Ministrów z dnia 28 grudnia 2020 dotycząca „Polityki dla rozwoju sztucznej inteligencji w Polsce od roku 2020” zwraca uwagę na to, że rozwój AI w dużym stopniu jest zależny od tego, jaki kapitał ludzki mamy do dyspozycji, a ten związany jest z edukacją społeczeństwa, zwłaszcza z zakresu nauk ścisłych, i z umiejętnością kreatywnego myślenia. Dokument ten podkreśla istotną wagę przygotowywania programów nauczania na wszystkich szczeblach edukacji, także na potrzeby osób już pracujących i kształcących się poza ramami formalnymi. Jednym z celów tak sformułowanej polityki jest tam „wysoka dostępność w Polsce narzędzi edukacyjnych, w tym online, pozwalających wszystkim chcącym kształcić się w obszarze AI zdobywać wiedzę, zarówno teoretyczną, jak i praktyczną”.

Analogicznie, jednym z elementów polityki publicznej, przyjętym uchwałą nr 195/2020 z 28 grudnia 2020 r. przez Radę Ministrów, jest „Zintegrowana Strategia Umiejętności 2030”. Zakłada ona m.in. „wszechstronne przygotowanie osób realizujących zadania związane z ich profesjonalnym kształceniem”, co obejmuje stałe podnoszenie kwalifikacji zgodnie z najnowszymi teoriami naukowymi. Aby to stałe podnoszenie kwalifikacji było w ogóle możliwe, niezbędne jest wypracowanie odpowiednich modalności i trajektorii uczenia, także przez osoby już wykonujące pracę zawodową.

* Akademia Leona Koźmińskiego, ORCID: 0000-0002-3745-7931

Wreszcie, szeroką ramę kształcenia w tym zakresie definiują także „Kompetencje kluczowe w uczeniu się przez całe życie – europejskie ramy odniesienia”, stanowiące załącznik do zalecenia Parlamentu Europejskiego i Rady z dnia 18 grudnia 2006 r. w sprawie kompetencji kluczowych w procesie uczenia się przez całe życie. Odnoszą się co prawda do szeroko rozumianych kompetencji informatycznych, ale jest jasne, że we współczesnym kontekście powinny dotyczyć także ich aktualnych aplikacji, jak AI.

Zarówno wspomniana polityka, jak i strategia rozwoju zakładają, że Polska w długim okresie może być jednym z przodujących krajów w zakresie wyznaczania trendów rozwoju sztucznej inteligencji. Aby jednak tak się stało, niezbędne jest dostosowanie systemów edukacji do realiów XXI wieku.

W szczególności musimy wyjść naprzeciw potrzebom edukacji osób dorosłych. O ile kształcenie dzieci i młodzieży jest powszechnie ustrukturyzowane i wystandaryzowane, o tyle ustawiczna nauka dorosłych wciąż raczkuje z punktu widzenia wypracowania jednolitych reguł i typowych jednostek kształcenia. Jest to także szczególnie ważne w kontekście rozwijania kluczowych kompetencji proinnowacyjnych i promowania twórczego potencjału osób pracujących (Fazlagić, 2021) – bo wiele wskazuje na to, że zawody kreatywne mogą w dłuższej perspektywie opierać się automatyzacji.

Zintegrowany System Kwalifikacji (ZSK), obowiązujący w Polsce i wprowadzony ustawą z dnia 22 grudnia 2015, uwzględnia możliwość włączania kwalifikacji rynkowych do ZSK. Określa także sposoby walidacji i pozyskiwania środków na podnoszenie kwalifikacji obywateli i obywaterek. Podobnie zalecenie Rady UE z dnia 22 maja 2017 r. w sprawie europejskich ram kwalifikacji dla uczenia się przez całe życie jasno podkreśla potrzebę elastyczności systemu kwalifikacji, a także stałego jego dostosowywania się do warunków rynkowych.

Regulacje należy rozpatrywać w kontekście światowego trendu: model edukacji, w którym przez kilkanaście lat podnosi się kwalifikacje, aby następnie przez kilkadziesiąt lat czerpać z tego zasobu wiedzy, jest już nieaktualny. Jednocześnie wciąż nie mamy jasnej sytuacji formalnego uznawania kwalifikacji powstałych w wyniku edukacji cyfrowej, choć rynek pracy już sobie z tym problemem radzi. Warto zatem przyrzeć się otoczeniu biznesowemu edukacji zdalnej.

Otoczenie biznesowe edukacji zdalnej asynchronicznej

Rynek usług edukacji zdalnej wart globalnie 4,6 miliarda dolarów rocznie w 2020 r., rośnie błyskawicznie i według obecnych projekcji może osiągnąć 20 miliardów już w 2026. Według innych szacunków Global Market Insights, z uwzględnieniem także m.in. platform szkolnych, obecnie wartość tego rynku sięga już 250 miliardów dolarów i urośnie do trylionu w najbliższych latach. Niezależnie od wielkości szacunków, pewne jest to, że szybki trend wzrostowy się utrzymuje. Nic dziwnego, że jest to rynek bardzo konkurencyjny i zdominowany przez duże firmy amerykańskie, zarówno w zakresie ogólnej edukacji (Coursera, edX, Skillshare, Udemy, Udacity, czy LinkedIn Learning), jak i edukacji specjalistycznej (DataCamp, Treehouse, Creativelive, MasterClass). Jest to edukacja realizowana przede wszystkim asynchronicznie, tj. uczestniczące

osoby oglądają nagrane wykłady i rozwiązują przygotowane uprzednio zadania – a nawet, jeżeli są zobligowane do oglądania wykładu na żywo lub o określonej porze, to ich możliwość reakcji zwrotnej jest mocno ograniczona.

Coursera w marcu 2021 roku dokonała debiutu giełdowego z wyceną na poziomie 4,3 miliarda dolarów. W tym samym roku pojawiła się wiadomość o tym, że Harvard i MIT, które wspólnie stworzyły platformę edukacyjną edX, zdecydowały o jej sprzedaży za 800 milionów dolarów (Shaw, 2021). Ten krok może przesądzić o kierunkach rozwoju edukacji cyfrowej na dziesięciolecia – bo powoduje, że model biznesowy, w którym elitarne uczelnie decydowały się na tworzenie materiałów edukacyjnych *online* wysokiej jakości i na zasadach nie w pełni komercyjnych (wiele kursów było bezpłatnych), traci rację bytu. Jest to o tyle istotne, że platformy edukacyjne ze wsparciem uczelni były rozwiązaniem pozwalającym na oferowanie kursów, które kończyły się formalnym dyplomem – pod kontrolą uczelni rozwijających platformy. Obecnie głównym graczem stają się korporacje rozwijające platformy. Podpisują one umowy na realizację kursów dyplomowych z różnymi uczelniami, przykładowo Coursera oferuje je z pięcioma różnymi uczelniami już od 2018 roku. Ponadto model edukacji misyjnej (czyli kształcenia dla dobra ludzkości), który przynajmniej retorycznie przyświeca wielu uczelniom, ustępuje modelowi edukacji komercyjnej, czysto produktowej (Volmar, 2021).

To przesunięcie decyzyjnego środka ciężkości z uczelni na platformy będzie miało dalekosiężne konsekwencje. Co prawda uczelnie nadal tworzą treści edukacyjne, ale już ich dystrybucja staje się zależna od komercyjnych platform. O ile uczelnie takie jak MIT, Harvard czy Stanford, z bardzo silnym brandem i prestiżem, mogą sobie pozwolić na zignorowanie kontroli nad kanałami dystrybucji, bo zainteresowanie ich ofertą i tak będzie bardzo wysokie, o tyle pozostałe uczelnie w coraz większym stopniu mogą się uzależniać od dystrybutorów, którzy z kolei są żywotnie zainteresowani tworzeniem własnych produktów edukacyjnych. Już teraz platformy oferują wiele kursów z własnymi certyfikatami – przykładem może być, chociażby, DataCamp, czyli platforma specjalizująca się w nauczaniu języków programowania. Wycena rynkowa wartości tego typu certyfikatów jest trudna do oszacowania, ale zainteresowanie certyfikacją wskazuje, że przynajmniej osoby szukające pracy uważają tego typu poświadczenie kompetencji za użyteczne.

Jednocześnie warto dostrzec ogromne zapotrzebowanie na ofertę edukacyjną wysokiej jakości dostępną bezpłatnie lub w niskiej cenie, czego dowodzi popularność Khan Academy, projektu rozwijającego się w formule non profit, z kilkoma milionami aktywnych użytkowników miesięcznie (zob. więcej <https://khanacademyannualreport.org/#a-message-from-sal-why-khan-academy>). W pewnym stopniu oczekiwania rynkowe odzwierciedla także model biznesowy wykorzystywany np. przez Coursera – oferowania za darmo wykładów, ale pobierania opłat za kursy z certyfikatem.

Rozważania te prowadzą do kilku wniosków na przyszłość. Po pierwsze, rola wystawcy certyfikatu jest istotna, ale w coraz mniejszym stopniu jakość edukacji walidują uniwersytety. Co prawda jest to zgodne z ZSK, ale ma długofalowe implikacje. Powoduje, że uczelnie w niewielkim stopniu mogą kontrolować wartość dodaną: nie mają kontroli nad łańcuchem dystrybucji, a na znaczeniu rośnie marka własna dystrybutora. Jest tak zwłaszcza w zakresie kursów nieprowadzących do

uzyskania magisterium i licencjatu. W dłuższym okresie może się to przekładać na utratę przez uczelnie dominacji/monopolu rynku studiów MBA i innych form edukacji podyplomowej. Światowi giganci będą w stanie oferować podobną lub lepszą jakość, a jednocześnie dostosować ofertę do indywidualnych potrzeb osób uczących się. Trend ten ulegnie nasileniu w momencie, gdy translatoryka komputerowa pozwoli na tłumaczenia symultaniczne wystarczająco dobrej jakości. Można się spodziewać, że nastąpi to w ciągu najbliższych kilku lat – względnie, gdy dystrybutorzy kursów dostrzegą, że tzw. lokalizacje językowe są dla nich kolejnym ważnym rynkiem zbytu. Jest to bezpośrednie zagrożenie dla krajowych uczelni realizujących komercyjne programy szkoleń i studiów.

Po drugie, można spodziewać się konsolidacji graczy. Fuzje i przejęcia są na tym szybko rozwijającym się rynku jedną z podstawowych form rozwoju – i wspomniane przejęcie edX, czy choćby zakup platformy Lynda przez LinkedIn, są jedynie wczesnymi sygnałami nadchodzącej fali. Docelowo łatwo można sobie wyobrazić, że na rynku platform edukacji cyfrowej zostanie jedynie kilka dominujących rozwiązań.

Po trzecie, i chyba najciekawsze, w najbliższych latach można spodziewać się stabilizacji dominującego modelu edukacji cyfrowej – z racji konsolidacji rynkowej graczy. Dopiero wtedy okaże się, czy tradycyjny e-learning, w przyszłości wspomagany przez AI, czy raczej *blended learning* będą wiodły prym – choć niezależnie od rezultatu, oba rozwiązania z pewnością zdobędą mocną pozycję rynkową i łącznie będą nadal wypierać naukę stacjonarną.

Otoczenie biznesowe edukacji zdalnej synchronicznej

W poprzedniej części rozdziału opisany został rynek największych graczy edukacji cyfrowej. Opis w zasadzie całkowicie skoncentrował się na rynku MOOC (*Massive Open Online Courses*), czyli kursów oferowanych masowo i niemal całkowicie jednokierunkowo. Osoby uczące się za pośrednictwem wymienionych platform mogą co prawda oglądać wykłady i wypełniać interaktywne ćwiczenia, ale nie mogą aktywnie uczestniczyć w konwersacji z prowadzącymi kurs, z innymi kursantami i kursantkami. Było to zasadne o tyle, że ten rynek jest obecnie dominujący w zakresie kursów zdalnych i według raportu *Research and Markets 2021* urośnie do kilkudziesięciu miliardów rocznie do 2027 roku.

Pandemia, jak wspomniano wcześniej, zmieniła jednak nastawienie szerokich rzesz odbiorców i obecnie duża część populacji ma świadomość, jak mogą wyglądać kursy realizowane synchronicznie i z interakcją – bo tak po prostu w większości przypadków wyglądała edukacja zdalna na całym świecie (Xie et al., 2021; Onyema et al., 2021).

Rynek ten także uległ dynamicznym zmianom i ma wyraźnych liderów. Google Meet (w połączeniu z Google Classroom), Microsoft Teams oraz Zoom to produkty, które rozwinęły się bardzo mocno, ale jest także sporo innych graczy – choćby z rynku korporacyjnych wideokonferencji, jak Cisco Webex czy Bluejeans, albo bezpośrednio z rynku zajęć zdalnych, jak Big Blue Button, Adobe Connect czy Schoology.

Wyraźnie widać, że o ile przed pandemią narzędzia te koncentrowały się przede wszystkim na umożliwianiu komunikacji, zarówno w spotkaniach jeden na jeden, jak i grupowych czy wręcz kongresowych, o tyle obecnie silnie rozwija się segment czysto edukacyjny. Google ułatwia łączenie rozwiązań dedykowanych dla szkół z platformą do telekonferencji, która także zawiera opcje zarządzania pytaniami i odpowiedziami czy proste quizy. Microsoft i Zoom znacząco rozwinęły zarówno podstawową platformę do prowadzenia zajęć, jak i liczne dodatkowe moduły edukacyjne.

Istotnym pytaniem strategicznym jest to, czy ten sposób uczestnictwa w zajęciach będzie akceptowalny dla szerokiej grupy ludzi. Pandemia pokazała, że bez odpowiednich procedur jest zdecydowanie niedoskonały: uczniowie i studenci często dołączają bez włączonych kamer i nie uczestniczą w pełni w zajęciach. Z drugiej strony są także pozytywne przykłady – w przypadku restrykcyjnie wymaganego połączenia video, odtworzenie doświadczenia uczestnictwa w klasie jest coraz bliższe. Co prawda niektórych rzeczy nie da się zastąpić, ale zastosowanie formuły nauki zdalnej synchronicznie umożliwia z kolei wykorzystanie wielu narzędzi, których nie da się użyć w tradycyjnej edukacji. Patrząc na problem z jeszcze innej strony, synchroniczna edukacja cyfrowa pokazała w pewnym stopniu, czym może stać się tradycyjna szkoła, gdy rozpowszechni się AR (ang. *augmented reality*, rozszerzona rzeczywistość). AR ma niewątpliwie ogromny potencjał nauczania, co widać choćby w technologiach trenażerów chirurgicznych, ale wciąż pozostaje nam czekać na powstanie platform, które będą miały masowe zastosowanie.

Jednym z możliwych wariantów rozwoju edukacji cyfrowej jest zatem utrzymanie formuły nauczania zbliżonej do tradycyjnego, w sensie uczenia w sposób dialogiczny, w małych grupach i synchronicznie, a jedynie z zastosowaniem nowoczesnych metod komunikacji. Ostatnią opcją wartą rozważenia jest wykorzystanie *blended learningu*.

Wady i zalety e-learningu i *blended learningu*

Dwa sposoby realizacji edukacji cyfrowej omówione wcześniej dotyczyły e-learningu. W teorii łatwo sobie wyobrazić, dlaczego e-learning może świetnie działać – w końcu zwłaszcza w przypadku jego synchronicznej wersji wydaje się mało różnić od tradycyjnej szkoły, a jednocześnie ma wiele dodatkowych zalet. W praktyce jednak trzeba pamiętać, że w edukacji jako takiej problemem nie jest sam dostęp do wiedzy. W końcu wiedza jest dostępna za darmo w bibliotekach, a współcześnie choćby w Wikipedii (Jemieliński, 2013). Realnym wyzwaniem jest natomiast długotrwała motywacja do systematycznego poszerzania wiedzy, zwłaszcza w obszarach, które nie są akurat dla osoby uczącej się najciekawsze i naturalne.

Dlatego, jak wiemy z badań (Rovai, Ponton et al., 2007), e-learning jest skuteczny jedynie wtedy, gdy osoby z niego korzystające mają bardzo silną motywację wewnętrzną. W tradycyjnej nauce rolą nauczyciela czy nauczycielki jest w znacznie większym stopniu wzbudzanie zainteresowania i skłanianie do opanowania materiału, niż sama jego prezentacja – i dlatego właśnie tradycyjna nauka tak bardzo się sprawdza, bo fizyczna współobecność mocno to ułatwia. Podobnie zresztą jest także choćby w przypadku uprawiania sportu – najtrudniejsze nie jest wcale opanowanie ćwiczeń, a zmuszenie się do ich regularnego wykonywania

– czy wszelkiego rodzaju diet (Hagger, Chatzisarantis et al., 2006), jak i porzucania nałogów. Stąd popularność programów takich jak AA: ludzie są istotami społecznymi, współpraca i wypracowywanie nawyków w interakcji z innymi są dla nich naturalne (Jemielniak i Przegalińska, 2020). Powstanie więzi z nauczycielem, wytworzenie specyficznej kultury danej klasy i norm zachowania (Koźmiński, Jemielniak i in., 2009) są znacznie łatwiejsze w przypadku fizycznej współobecności.

To jeden z głównych powodów, dla których e-learning asynchroniczny w masowym wydaniu jest bardzo trudny w praktyce: aby z niego korzystać, trzeba mieć bardzo silną wewnętrzną motywację. E-learning synchroniczny poprawia sytuację, ale jedynie częściowo – bo nawiązanie relacji z grupą i prowadzącą osobą jest znacznie trudniejsze niż w klasie spotykającej się na żywo.

Dlatego po wielu latach prób i doświadczeń z e-learningiem narodziła się koncepcja *blended learningu*: realizacji części nauki w formule tradycyjnej, a części z wykorzystaniem edukacji cyfrowej. O ile początki nauki zdalnej datuje się nawet na XIX wiek, kiedy to firma Pitman Training oferowała pierwsze kursy na odległość, o tyle *blended learning* to przede wszystkim ostatnie 20–30 lat³⁴.

Oczywiście takie podejście także ma liczne wady: przede wszystkim nie nadaje się do realizacji całkowicie zdalnej, a zerwanie z koniecznością geograficznej bliskości w przestrzeni jest jedną z istotnych zalet e-learningu. Jednakże jest to podejście, które unika wad związanych z motywacją typowych dla e-learningu (Norvig, Petersen et al., 2018), jednocześnie umożliwiając wprowadzanie istotnych elementów edukacji cyfrowej i, w łącznym rezultacie, nawet lepszych niż w nauce tradycyjnej.

Przykładem zastosowania *blended learning* jest chociażby, istniejąca od 2013, platforma InstaLing, współtworzona przez autora, z której korzysta blisko pół miliona uczniów w każdym roku. InstaLing to narzędzie, które pozwala nauczycielom łatwo przydzielać słownictwo i materiał gramatyczny do powtarzania całym klasom – służy zatem przede wszystkim do nauki języków obcych, choć ma także moduły do języka polskiego i matematyki. Algorytm dostosowuje czas powtórki danych jednostek wiedzy w taki sposób, aby go zoptymalizować z tzw. krzywą zapamiętywania, czyli nie wyznaczać powtórki słów, które dana osoba prawie na pewno wciąż dobrze pamięta, ale jednocześnie powtarzać słowa, które sprawiają wciąż trudność lub są prawdopodobnie na granicy zapomnienia.

InstaLing i inne podobne platformy uzupełniają naukę tradycyjną, jednocześnie wprowadzając element edukacji cyfrowej, który byłby niemożliwy do realizacji bez technik komputerowych: całkowitą customizację trajektorii powtórek materiału. Każdy uczeń i uczennica uczą się danego dnia trochę innego zestawu słów – bo jest on zależny od tego, jak im szło w poprzednich dniach i które słowa akurat powinni utrwaląć.

Przykład ten pokazuje dobrze, że przyszłość edukacji cyfrowej, przynajmniej w średnim okresie, to raczej uzupełnianie tradycyjnej nauki niż próby zastępowania

³⁴ Zob. <https://elearningindustry.com/history-of-blended-learning>

jej. Technologie IT mogą naprawdę doskonale poszerzać doświadczenie edukacyjne – zarówno w czasie lekcji (wystarczy wspomnieć choćby narzędzia takie jak Mentimeter czy Kahoot, służące do błyskawicznego pozyskiwania informacji zwrotnej i quizów), jak i poza nią, w ramach utrwalania i prac domowych.

Można się jednak spodziewać, że przyspieszenie tempa rozwoju edukacji cyfrowej nastąpi w pełni dopiero wtedy, gdy zostanie wykorzystany w niej potencjał sztucznej inteligencji.

AI w edukacji oświatowej

Przykład InstaLing pokazuje, jak dużo można osiągnąć dzięki wykorzystaniu narzędzi cyfrowych, ale jednocześnie jak dużo jeszcze jest do zrobienia. Algorytm powtórek materiału, zgodny z aktualnym stanem wiedzy na temat tzw. *spaced repetition* (Ausubel i Youssef, 1965; Tabibian, Upadhyay et al., 2019), pozwala na optymalizację momentu powtórki danego słowa, ale traktuje każde słowo tak samo. Rozsądne jest przypuszczenie, że można dodatkowo dopasowywać materiał leksykalny do potrzeb indywidualnych – ale tego rodzaju dynamiczne dostosowania będą wymagać już zastosowania uczenia maszynowego.

Indywidualizacja trybu nauczania na znacznie bardziej granularnym poziomie jest podstawą systemu Squirrel AI – wiodącej platformy cyfrowego wsparcia uczniów szkół podstawowych i średnich w Chinach. Co ciekawe, choć Squirrel AI opiera się na algorytmie *spaced repetition*, wspomaganym przez uczenie maszynowe, oferuje dodatkowo także możliwość e-learningu synchronicznego, aby zwiększać motywację uczniów (Hao, 2019).

Drugim obszarem, gdzie AI może dokonać radykalnego przewrotu technologicznego w edukacji szkolnej, jest automatyczne ocenianie prac. Już od kilku lat testy TOEFL są oceniane częściowo z wykorzystaniem algorytmów uczenia maszynowego (ETS, 2021). Dzięki ogromnej bazie ocenionych prac są w stanie z dużą dokładnością dokonać wstępnej oceny zarówno prac pisemnych, jak i wypowiedzi ustnych.

Wreszcie, wykorzystanie sztucznej inteligencji pozwala na zastąpienie kosztownych korepetycji nauką w praktyce. W tym obszarze bardzo ciekawym nowym projektem, wykorzystującym uczenie maszynowe do edukacji, jest CoPilot, oferowany przez GitHub. CoPilot nie ma funkcji stricte edukacyjnych, ale podpowiada fragmenty kodu w trakcie jego pisania, a także typowe komentarze i pytania związane z wykorzystywanymi funkcjami. Ponieważ funkcjonalność jest na razie bardzo prosta, trudno ocenić jej długofalową przydatność. Jednakże pokazuje ona niezwykle istotny kierunek rozwoju edukacji cyfrowej z wykorzystaniem AI: realizację koncepcji *learning by doing*, edukacji w działaniu. Zamiast teoretycznych rozważań i sztucznych, treningowych przykładów, które dopiero następnie przekładać można na swoje potrzeby, wykorzystanie narzędzi takich jak CoPilot pozwoli w przyszłości na bardzo szybkie przechodzenie od absolutnych podstaw do praktyki – bo algorytmy AI będą podpowiadać prawidłowe rozwiązania na podstawie prawdopodobnego kontekstu. Nie sposób ocenić, jak dalece rozwiązanie tego typu będzie realnie użyteczne, ale idea jest niezwykle obiecująca.

W wykorzystaniu AI w edukacji cyfrowej wciąż jednak przeszkadza wiele wyzwań, skądinąd typowych dla rozwoju uczenia maszynowego w ogóle: niekompletne lub ułomne zbiory danych, wąskie rozumienie „edukacji” czy problemy metodologiczne (Perrotta i Selwyn, 2020). Trudno więc na dziś ocenić, jak szybko i w jak dużym stopniu się rozpowszechni.

Przyszłość edukacji cyfrowej

Nie ulega wątpliwości, że zastosowanie sztucznej inteligencji w edukacji będzie postępować. Jest także oczywiste, że polityka rozwoju AI w Polsce musi opierać się także na edukacji i tworzeniu kadr. Aby ZSK i Zintegrowana Strategia Umiejętności 2030 mogły w pełni wykorzystać potencjał nowych technologii, potrzebne jest dostrzeżenie, że platformy edukacji cyfrowej, choć oferują customizację na poziomie indywidualnym, najlepiej rozwijają się wtedy, gdy mogą opierać się na standardowych programach masowych. Inaczej mówiąc: platforma może świetnie dostosować trajektorie powtórek z użyciem AI dla pojedynczej osoby, ale oferowany na platformie materiał będzie taki sam dla milionów uczniów i uczennic.

Wynika z tego dosyć prosta konstatacja: w interesie polskiej edukacji jest maksymalne ujednoczenie i ustandaryzowanie programów nauczania z innymi krajami dla tych przedmiotów, dla których to możliwe – a zatem w dużym zakresie przedmiotów ścisłych, a w niewielkim humanistycznych. Jest tak przede wszystkim dlatego, że przy wykorzystaniu AI w edukacji szczególnie widoczny jest efekt skali: zastosowanie globalnie używanych narzędzi bardzo mocno zwiększa ich skuteczność i zdolność oddziaływania.

Dlatego tworzenie europejskich podstaw programowych to niepowtarzalna szansa na to, aby stworzyć rynek, dla którego będzie się opłacało oferować zaawansowane platformy edukacyjne, które obecnie powstają przede wszystkim na rynek amerykański lub chiński.

Jednocześnie nie sposób nie dostrzec poważnych zagrożeń: wobec zaawansowanego rozwoju amerykańskich i chińskich systemów edukacji z zastosowaniem AI, istotnym elementem ryzyka będzie pozyskiwanie danych na temat indywidualnych osób przez podmioty zagraniczne, a także potencjalnie gorsze dostosowanie do potrzeb społeczno-kulturowych europejskiego sektora edukacji.

Minimalizacja tych zagrożeń i wykorzystanie szans staną możliwe tylko wtedy, gdy edukacja z użyciem AI w Polsce oprze się na technologiach, które będą miały szansę na konkurencję na rynku światowym. Będzie to możliwe w zasadzie bezdyskusyjnie na poziomie ponadnarodowym. Ujednoczenie programów nauczania na poziomie europejskim daje możliwość stworzenia jednego, dużego rynku, który będzie stanowił dla nich zaplecze.

Podsumowanie

W niniejszym rozdziale omówione zostały podstawowe uwarunkowania otoczenia prawnego AI w edukacji, stan obecny zdalnego nauczania synchronicznego i asynchronicznego oraz ich możliwą nieodległą przyszłość, wady i zalety e-learningu

i *blended learningu*, obszary, w których AI w edukacji szkolnej już działa, a także wnioski dotyczące szans i zagrożeń edukacji cyfrowej.

Na podstawie analizy obecnych trendów można ostrożnie założyć, że już niedługo AR (ang. *augmented reality*, rozszerzona rzeczywistość) i VR (ang. *virtual reality*, rzeczywistość wirtualna) znacząco zaczną wpływać na rynek edukacji zdalnej, także z wykorzystaniem AI. Rozwój projektów takich jak StarLine Google (Coldewey, 2021), pozwalających na przeprowadzanie zdalnych rozmów z widokiem rozmówców w 3D, jak i rozwój technologii AR i VR silnie sugerują też, że wspomniane dysfunkcje synchronicznej nauki cyfrowej będą coraz mniejsze, a podział na naukę tradycyjną (w fizycznej współobecności) i synchroniczny e-learning straci na znaczeniu.

E-learning asynchroniczny będzie rynkiem rosnącym, ale należy wątpić, aby trwale zdominował edukację: pozostanie raczej coraz lepszym sposobem na podnoszenie kwalifikacji i wiedzy osób, które są w stanie skutecznie się motywować samodzielnie.

Z pewnością możemy spodziewać się różnego rodzaju przetasowań rynkowych i obiecujących innowacji – czekają nas ciekawe czasy!

Bibliografia

Almaiah, M. A., Al-Khasawneh, A. and Althunibat, A. (2020). Exploring the critical challenges and factors influencing the E-learning system usage during COVID-19 pandemic. *Education and Information Technologies*, 25, 5261–5280.

Ausubel, D. P. and Youssef, M. (1965). The Effect of Spaced Repetition on Meaningful Retention. *The Journal of general psychology* 73, 147–150.

Coldewey, D. (2021). *Google is making a 3D, life-size video calling booth*. TechCrunch.

ETS (2021). Understanding your TOEFL iBT scores (for test takers). Pobrano z <https://www.ets.org/toefl/test-takers/ibt/scores/understanding/>

Fazlagić, J. (2021). *Dobre praktyki w zakresie wspierania kreatywności, innowacyjności i samodzielności uczniów szkół ponadpodstawowych*. Warszawa: Ośrodek Rozwoju Edukacji.

Hagger, M. S., Chatzisarantis, N. L. D. et al. (2006). The Process by Which Relative Autonomous Motivation Affects Intentional Behavior: Comparing Effects Across Dieting and Exercise Behaviors. *Motivation and emotion* 30, 306.

Hao, K. (2019). China has started a grand experiment in AI education. It could reshape how the world learns. *MIT's technology review* 123.

Jemielniak, D. (2013). *Życie wirtualnych dzikich*. Warszawa: Poltext.

Jemielniak, D. i Przegalińska, A. (2020). *Społeczeństwo współpracy*. Warszawa: Wydawnictwo Naukowe Scholar.

Koźmiński, A. K., Jemielniak, D. i in. (2009). Współczesne spojrzenie na kulturę organizacji. *e-mentor* 3, 4–13.

Nortvig, A. M., Petersen, A. K. et al. (2018). A Literature Review of the Factors Influencing E-Learning and Blended Learning in Relation to Learning Outcome, Student Satisfaction and Engagement. *Electronic Journal of e-Learning* 16, 46–55.

Onyema, E. M., Eucheria, N. C., Obafemi, F. A., Sen, S., Atonye, F. G., Sharma, A. and Alsayed, A. O. (2020). Impact of Coronavirus pandemic on education. *Journal of Education and Practice*, 11(13), 108–121.

Perrotta, C. and Selwyn, N. (2020). Deep learning goes to school: toward a relational understanding of AI in education. *Learning, media and technology* 45, 251–269.

Rovai, A., Ponton, M. et al. (2007). A comparative analysis of student motivation in traditional classroom and e-learning courses. *International Journal on E-learning* 6, 413–432.

Shaw, J. (2021). Harvard and MIT to sell edX for \$800 million. W: Harvard Magazine. Pobrano z <https://www.harvardmagazine.com/2021/06/sale-of-edx>.

Tabibian, B., Upadhyay, U. et al. (2019). Enhancing human learning via spaced repetition optimization. *Proceedings of the National Academy of Sciences of the United States of America* 116, 3988–3993.

Volmar, E. (2021). Mission and Money: Unpacking Competition between Hybrid Organizations in the Nascent MOOC Market. In *Academy of Management Proceedings* (Vol. 2021, No. 1, p. 10177). Briarcliff Manor, NY 10510: Academy of Management.

Xie, X., Siau, K. and Nah, F. F. H. (2020). COVID-19 pandemic—online education in the new normal and the next normal. *Journal of Information Technology Case and Application Research*, 22(3), 175–187.

Edukacja medialna i sztuczna inteligencja w kontekście społecznym

dr Joanna Rabięga-Wiśniewska*
Wojciech Stęchły**
dr Marcin Będkowski***

Wprowadzenie

W artykule podejmujemy temat postrzegania i rozumienia sztucznej inteligencji przez społeczeństwo. W kontekście zwiększającej się liczby technologii opartych na sztucznej inteligencji i ich rosnącym wpływie na codzienność wszystkich ludzi, kluczowe wydaje się rozpoznanie poziomu świadomości społecznej w tym zakresie. Z kolei zdolność identyfikowania artefaktów sztucznej inteligencji, rozumienia jej mechanizmów oraz interpretacji wyników stanowią istotny przedmiot współczesnej edukacji medialnej. W niniejszym artykule chcielibyśmy przedstawić główne wątki wybranych raportów dotyczących edukacji medialnej i sztucznej inteligencji oraz sformułować na ich podstawie wstępne wnioski oraz rekomendacje.

Warto zauważyć, że daleko idący wpływ na to, w jaki sposób różne grupy społeczne rozumieją i oceniają sztuczną inteligencję; jak postrzegają możliwość jej wykorzystania w swoim życiu prywatnym i zawodowym; jak oceniają jej wpływ na swoje życie, ma to, jakie posiadają kompetencje medialne – w szczególności cyfrowe. Kompetencje te przekładają się m.in. na zdolność do rozumienia zjawisk takich jak wpływ inteligentnych algorytmów na rekomendacje w różnych serwisach streamingowych i sieciach społecznościowych, fake newsy, bańki informacyjne, mechanizmy profilowania w marketingu internetowym.

W społeczeństwie, w którym znaczna część interakcji odbywa się za pośrednictwem Internetu, kompetencje oparte na rozumieniu tego typu zjawisk wydają się niezbędne, by krytycznie konstruować własny obraz rzeczywistości oraz współdzielić go z innymi. W tym sensie kompetencje medialne stanowią fundament dla budowania społeczeństwa współpracy, rozumianego jako współoddziałująca w grupach oddolna struktura społeczna korzystająca z technologii w budowaniu relacji ekonomicznych, kulturowych czy międzyludzkich (za: Jemielniak i Przegalińska, 2020, s. 16).

W raportach o sztucznej inteligencji i technologiach z ostatnich dwóch lat wskazuje się, które kompetencje spełniają postulat systemowej edukacji medialnej – począwszy od pierwszego etapu edukacji szkolnej, zob. np. DESI (Digital Economy and Society Index, <https://digital-agenda-data.eu/datasets/desi>). Cenne rozpoznania przynoszą także wyniki międzynarodowych badań kompetencji PISA i PIAAC (Burski i in., 2013; Federowicz i Sitek, 2017).

* Instytut Badań Edukacyjnych, ORCID: 0000-0003-3194-5261

** Instytut Badań Edukacyjnych, ORCID: 0000-0003-1359-6272

*** Uniwersytet Warszawski ORCID: 0000-0002-2787-9487

Nowe media są definiowane jako technologie informacyjne i komunikacyjne, które obejmują trzy komponenty: 1) fizyczne przedmioty lub narzędzia, które tworzą i poszerzają możliwości komunikacji i wymiany, 2) działania i praktyki realizowane podczas projektowania tych urządzeń oraz 3) formy społecznej organizacji wokół tych przedmiotów i praktyk (Ptaszek, 2019). W tym opracowaniu odnosimy się do *nowych mediów*, rozumianych w kontekście nie tylko technologicznym (komponent 1.), ale i społecznym (komponenty 2. i 3.).

Badacze nowych mediów zwracają szczególną uwagę na technologię obiegu informacji oraz pozyskiwania i analizy dużej ilości danych. Dlatego zadaniem edukacji medialnej staje się także wzrost w społeczeństwie poziomu zrozumienia dla transformacji technologicznej i ekonomicznej opartych na tych technologiach. Edukacja medialna będzie w coraz większym stopniu przygotowywać osoby w różnym wieku do posługiwania się narzędziami codziennego użytku w bezpośrednim otoczeniu, a medialnymi środkami wymiany komunikacji są przede wszystkim narzędzia cyfrowe – smartfony, wyszukiwarki, internet rzeczy, chmury obliczeniowe.

Odbiór społeczny AI z perspektywy edukacji medialnej

W ciągu ostatnich dwóch lat powstało kilka raportów ukazujących, jak jest odbierana obecność technologii sztucznej inteligencji w życiu zawodowym i społecznym w Polsce. Pokazują one nie tylko to, czy społecznie udział rozwiązań AI jest zauważalny, ale też czy Polacy są gotowi na czerpanie z nich korzyści. Czy jako społeczeństwo rozumiemy, czym jest AI?

Większość raportów potwierdza pozytywne nastawienie społeczeństwa do nowych technologii. Zdecydowana większość badanych osób spotkała się z terminem *sztuczna inteligencja* (89,2% respondentów badania przeprowadzonego przez Naukową i Akademicką Sieć Komputerową NASK (Lange i in., 2019). Dopiero jednak analiza odpowiedzi na pytania szczegółowe pokazuje, że poziom kompetencji cyfrowych wpływa na kształtowanie oczekiwań i obaw związanych z wykorzystaniem AI w życiu codziennym.

Zatrzymajmy się przy dwóch stwierdzeniach:

- Dla większej części polskiego społeczeństwa (55,8%) w definiowaniu *sztucznej inteligencji* najważniejszym elementem jest twierdzenie, że obejmuje ona urządzenia i procesy, w których człowiek nie bierze udziału.
- Połowa respondentów uważa, że sztuczna inteligencja ma wpływ na ich codzienne życie (Lange i in., 2019).

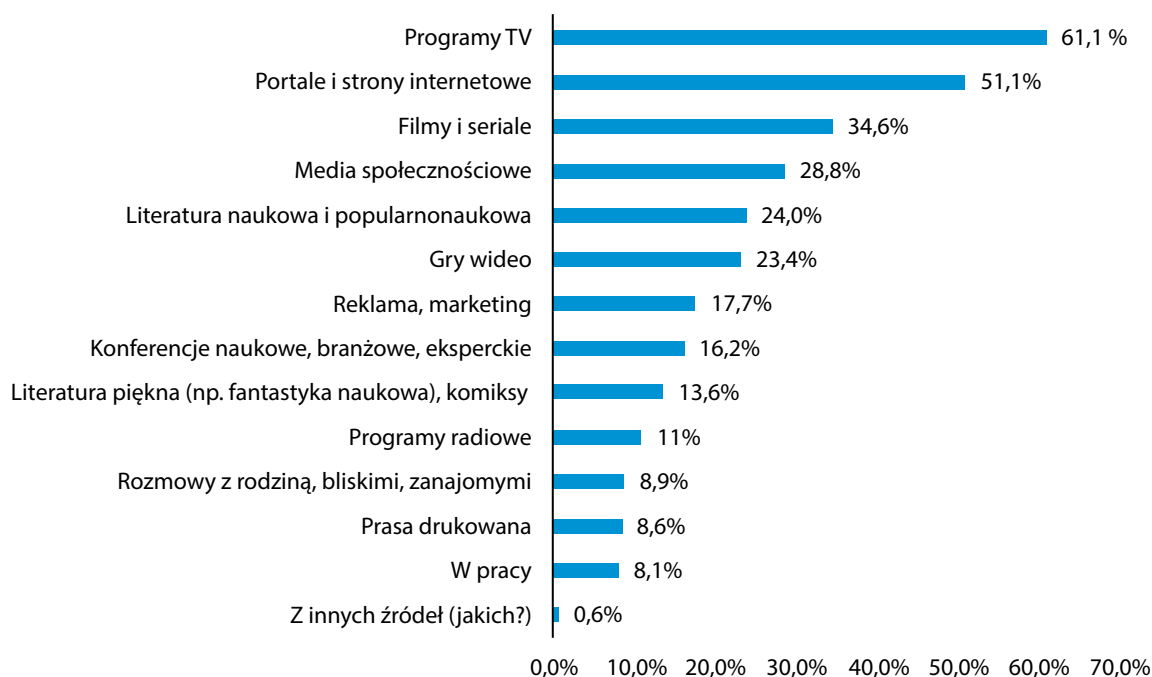
Błędne rozumienie i definiowanie sztucznej inteligencji skutkuje brakiem zaufania do nowych technologii. Respondenci sądzą, że technologia oparta na sztucznej inteligencji będzie niebawem niezależna od kontroli człowieka (55,9%). Prawie co czwarty badany nie był w stanie stwierdzić, czy AI uniezależni się od nadzoru człowieka. Istnieją też obawy, że rozpowszechnienie technologii sztucznej inteligencji skutkować będzie przede wszystkim zagrożeniami dotyczącymi sfery prywatności. Następnie podnoszony jest problem możliwego wzrostu poziomu bezrobocia. I na koniec duże znaczenie

przypisuje się niebezpieczeństwu cyberataków. Dodatkowo w innym badaniu sygnalizowano możliwość utraty kontroli nad różnorodnymi procesami zachodzącymi w firmach (41,8%) oraz kwestię niekontrolowanego przyrostu danych (23,6%) i ewentualnego spadku zaufania do instytucji (21,8%) (Biczuk, Jamrogiewicz i Malczewski, 2019).

Z powyższych obserwacji wynika, że AI i sposób jej działania wzbudzą niepewność wśród jej przeciętnych użytkowników, często nieposiadających kompetencji do rozpoznania podstawowego faktu, tj. że sztuczna inteligencja powstaje dzięki kreatywności swoich twórców. Jak pisze Torczyńska (2019), „rodzą się wątpliwości i obawy związane z brakiem przydatności człowieka do większości prac, wykorzystywaniem ludzkich ciał, czy też ignorowanie wartości ludzkiego życia – lęki wynikające z niewiedzy”.

Wiemy, że Polacy budują swoje wyobrażenia o AI oraz związanych z nią zagrożeniach w oparciu o medialne i popkulturowe przekazy (np. filmy fantastyczno-naukowe). Warto zwrócić uwagę na to, gdzie najczęściej Polacy spotykają się z pojęciem AI, a więc jednocześnie – skąd czerpią wiedzę o AI.

Wykres 1. Rozkład procentowy odpowiedzi na pytanie: „Gdzie najczęściej spotyka się Pan(i) z pojęciem sztuczna inteligencja?” (n=1023)



Źródło: Lange i in., 2019, s. 13.

Warto zauważyć, że na powyższym wykresie brak źródła związanego z edukacją – Polacy nie czerpią informacji o sztucznej inteligencji ze szkoły, uczelni, kursów zawodowych ani hobbystycznych. Po literaturę naukową lub popularnonaukową sięga zaledwie co czwarty Polak. Pokazuje to, jak ważne i potrzebne jest zadbanie o odpowiednie treści w ramach edukacji medialnej, jak również zapewnienie możliwości zdobycia tej wiedzy w wieku dorosłym (stworzenie przestrzeni dla edukacji medialnej w uczeniu się przez całe życie).

Kompetencje w raportach AI

Na jakie kompetencje zwracają uwagę autorzy raportów o AI? Przede wszystkim na dobrze rozwinięte kompetencje przyszłości, wśród których kluczowe są kompetencje cyfrowe i techniczne (Pokojska, Śledziwska i Włoch, 2020). Ale równie dużą rolę odgrywają kompetencje kognitywne i społeczne.

Odnosimy się tutaj do pojęcia *kompetencji cyfrowych*, a także *kompetencji kluczowych*. Nie są to pojęcia jasno zdefiniowane, nie posiadają ostro wyznaczonych granic – w niektórych przypadkach mogą być stosowane zamiennie. Literatura przedmiotu proponuje co najmniej kilka perspektyw spoglądania na realizację powyższych kompetencji. Na potrzeby naszego artykułu ograniczymy się jedynie do pokazania, dlaczego informacja o poziomie kompetencji cyfrowych czy kluczowych pojawia się w tekście poświęconym edukacji medialnej i kompetencjom medialnym.

W większości ujęć umiejętności cyfrowe obejmują zarówno kompetencje techniczne (korzystanie z technologii cyfrowych), jak też poznawcze, emocjonalne i społeczne niezbędne do korzystania z nich (Kiss, 2017).

W ramach zdefiniowanych przez Komisję Europejską kompetencji kluczowych wskazano m.in. kompetencje cyfrowe, które opisano jako obejmujące „ pewne, krytyczne i odpowiedzialne korzystanie z technologii cyfrowych i interesowanie się nimi do celów uczenia się, pracy i udziału w społeczeństwie. Obejmują one [kompetencje cyfrowe] umiejętność korzystania z informacji i danych, komunikowanie się i współpracę, umiejętność korzystania z mediów, tworzenie treści cyfrowych (w tym programowanie), bezpieczeństwo (w tym komfort cyfrowy i kompetencje związane z cyberbezpieczeństwem), kwestie dotyczące własności intelektualnej, rozwiązywanie problemów i krytyczne myślenie” (Zalecenie Rady z dnia 22 maja 2018 r. w sprawie kompetencji kluczowych w procesie uczenia się przez całe życie: <https://tinyurl.com/558peb39>).

Blizsza lektura funkcjonujących ujęć i koncepcji bliskich kompetencjom kluczowym pokazuje, że umiejętność korzystania z mediów (*media literacy*) jest kategorią przekrojową – powiązaną również z kompetencjami społecznymi, umiejętnością uczenia się itd. (Stęchły i Dębowski, 2020).

Badania międzynarodowe takie jak PISA, PIAAC czy ICILS pokazują poziom umiejętności czytania i bezpośrednio nawiązują do środowisk cyfrowych (*digital literacy*, *digital reading*). Mówią nam m.in. o tym, czy potrafimy wyszukiwać, selekcjonować i oceniać wiarygodność informacji, pokazują również umiejętność korzystania z technologii ICT. Z badania PISA 2018 wynika, że tylko 9% 15-latków w krajach OECD potrafi odróżnić opis faktycznej sytuacji od opinii, a młodzież spędza przeciętnie 35 godzin tygodniowo w Internecie – o 14 godzin więcej niż pokazało badanie PISA 2012 (OECD, 2021, s. 20). Warto się zastanawiać, jak wykorzystać potencjał współczesnej młodzieży.

Na tle innych krajów Unii Europejskiej polscy specjaliści mają niższe kompetencje miękkie: umiejętność dzielenia się wiedzą, uczenia się, rozwiązywania problemów oraz umiejętności komunikacyjne i współpracy w zespole (Fundacja Digital Poland, 2020a). Nie ulega wątpliwości, że wzrasta presja na nabywanie nowych

kompetencji i umiejętności, z których na czoło wysuwają się umiejętność planowania kariery zawodowej oraz kompetencje w zakresie instrumentalnej (narzędziowej) orientacji aktywności. Nie będą to nowe zawody, lecz „wiązki” nowych kompetencji (Fundacja Digital Poland, 2020b). Bez tych kompetencji nie będzie możliwe wykorzystanie ogromu potencjału, który oferuje obecność AI w gospodarce i sektorze publicznym. Pracownicy firm prywatnych i urzędnicy państwowi, wdrażający i wykorzystujący coraz więcej narzędzi, powinni rozumieć szanse i zagrożenia wynikające z ich stosowania. Bez ogólnej bazy wiedzy i umiejętności korzystania z niej w przypadku konkretnych systemów, z którymi będą mieć na co dzień do czynienia, niemożliwa stanie się ocena ich wpływu społecznego czy wewnętrzna ewaluacja ryzyka (Mileszyk, Paszcza i Tarkowski, 2019).

Tabela 6. Typy kompetencji wchodzących w skład kompetencji medialnych i ich opis.

Typ kompetencji	Opis
Zabawa	Umiejętność eksperymentowania z otoczeniem jako forma rozwiązywania problemów
Odgrywanie roli (<i>performance</i>)	Umiejętność przyjmowania alternatywnych tożsamości w celach improwizacji i dokonywania odkryć
Symulacja	Umiejętność interpretowania i konstruowania dynamicznych modeli (odpowiedników) procesów zachodzących w realnym świecie
Dostosowanie	Umiejętność tworzenia remiksów medialnych i tekstów na bazie istniejących przekazów kulturowych
Wielozadaniowość	Umiejętność „skanowania” środowiska i koncentrowania się na poszczególnych jego elementach
Podzielne procesy poznawcze (<i>distributed cognition</i>)	Umiejętność interakcji z narzędziami, które rozszerzają mentalne zdolności jednostki
Kolektywna inteligencja	Umiejętność gromadzenia wiedzy oraz porównywania informacji z innymi w celu osiągnięcia wspólnych celów
Ocena	Umiejętność oceny rzetelności i wiarygodności różnych źródeł informacji
Nawigacja transmedialna	Umiejętność śledzenia przepływu historii i informacji w obrębie różnych modalności medialnych
Praca w sieci (<i>networking</i>)	Umiejętność poszukiwania, syntetyzowania i dyseminacji informacji, a także wymiany informacji, zasobów, wzajemnego poparcia
Negocjacja	Umiejętność przemieszczania się w obrębie różnych wspólnot, przenikania i respektowania różnorodnych perspektyw, opanowywania i stosowania alternatywnych norm i reguł

Źródło: Ogonowska, A. (2015). Kompetencje medialne. W: Fedorowicz, M., Ratajski, S. O potrzebie edukacji medialnej. Warszawa: UNESCO, KRRiTV, s. 106.

Myślenie krytyczne w epoce AI

Kolejną kategorią wiążącą wspólnie pożądane kompetencje cyfrowe czy medialne ze sztuczną inteligencją jest *krytyczne myślenie*. Od kilkunastu lat funkcjonuje ono niemal jak słowo wytrych dla szeregu kompetencji (i zajęć je kształtujących) mających odpowiadać na wyzwania stawiane przez współczesność i plasujących się w czołówce umiejętności pożądanych przez pracodawcę.

Choć pierwsze próby opracowania koncepcji krytycznego myślenia można datować na lata 40. XX w. – a inspiracji doszukiwać się w literaturze filozoficznej wieków minionych – to w obecnie trwającej postaci nurt krytycznego myślenia rozwinął w USA na początku lat 70. XX wieku (Wasilewska-Kamińska, 2016). Stanowił on wówczas odpowiedź na wyzwania tzw. ery wizualnej, którą rozpoczęła debata telewizyjna między Kennedym i Nixonem z roku 1960. Autorzy tego nurtu wykazywali brak użyteczności narzędzi oferowanych przez logikę formalną do analizy argumentacji codziennych, w tym debat politycznych. Do dziś teoria argumentacji i umiejętności oceny argumentów stanowi rdzeń większości form kursów krytycznego myślenia, łączy się z umiejętnością logicznej oceny stopnia akceptowalności konkluzji, rozpoznawania chwytów erystycznych czy udziału w różnego typu debatach.

Z czasem koncepcja krytycznego myślenia ewoluowała w stronę szerokiej i interdyscyplinarnej dziedziny mającej na celu wypracowanie umiejętności samodzielnego wnioskowania, rozumienia komunikatów (np. tekstów kultury), niezależnego od autorytetów, skrzywień poznawczych. Sprzeciwiała się lub miała charakter komplementarny względem edukacji nastawionej na przyswajanie wiedzy encyklopedycznej, kładła nacisk na metapoznanie i uczyła tego, jak się uczyć. Z tego względu koncepcja krytycznego myślenia rozwija się z jednej strony w kierunku szeroko rozumianej epistemologii (zob. Lau, 2011), z drugiej zaś – praktycznego przedmiotu nastawionego na konkretne umiejętności, który może obywać się bez szczególnej podbudowy teoretycznej.

Pokrewne formy kształcenia nastawionego na rozwój krytycyzmu i interdyscyplinarnej zasób narzędzi pojęciowych, można znaleźć w różnych postaciach w różnych systemach kształcenia – podobną funkcję pełnią zajęcia z teorii wiedzy w ramach matury międzynarodowej (Alchin and Henly, 2014), nasza rodzima koncepcja logiki pragmatycznej (Ajdukiewicz, 1964) czy... średniowieczna koncepcja *trivium* (Sayers, 1948). Podobnym celom służą także rozmaite przedmioty o charakterze praktycznym, takie jak technologia cyfrowa, umiejętności akademickie, warsztaty pisania czy wprowadzenie do metodologii badań.

Obecne wyzwania, przed którymi stoimy – związane z rozwojem i wzrostem dostępności Internetu, nowych technologii i nowych mediów, ekonomii uwagi – domagają się nowych form reakcji – podobnych do tych z lat 70. Z jednej strony potrzebujemy przedmiotów i zajęć informujących o teoretycznych aspektach nowych mediów i technologii, z drugiej – ćwiczenia umiejętności pozwalających na lepsze odnajdywanie się w otaczającej rzeczywistości. Zostało to dostrzeżone przez autorów podstawy programowej (podstawaprogramowa.pl, 2017), którzy piszą: „Szkoła ma również przygotowywać ich [uczniów] do dokonywania świadomych i odpowiedzialnych wyborów w trakcie korzystania z zasobów dostępnych

w internecie, krytycznej analizie informacji, bezpiecznego poruszania się w przestrzeni cyfrowej, w tym nawiązywania i utrzymywania opartych na wzajemnym szacunku relacji z innymi użytkownikami sieci”.

Rzeczywistość edukacyjna jak mało która musi się godzić na rozliczne ustępstwa i kompromisy. Era Internetu, sztucznej inteligencji, nowych mediów i ekonomii uwagi to zjawiska o niespotykanej dotychczas skali i sile rażenia. Rozwój kompetencji cyfrowych i kompetencji przyszłości musi przebiegać w wielu kierunkach:

- kompetencji informatycznych umożliwiających korzystanie z powszechnie stosowanego oprogramowania użytkowego,
- przynajmniej podstawowych kompetencji programistycznych umożliwiających rozumienie otaczających nas maszyn, z których czynimy codzienny użytek lub które automatyzują podstawowe czynności,
- świadomości działania i być może umiejętności trenowania modeli AI, co obok podstawowych kompetencji programistycznych powinno angażować także elementy wiedzy statystycznej,
- kompetencji o charakterze społecznym oraz wiedzy z zakresu funkcjonowania mediów i wykorzystywania, zwłaszcza w nowych mediach, inteligentnych algorytmów.

Kompetencje te powinny towarzyszyć rozwijaniu umiejętności rozumianych w sposób tradycyjny, takich jak sprawność komunikacyjna, kreatywność czy budowanie współpracy w grupie.

Edukacja medialna i podnoszenie świadomości społecznej

Poruszone wyżej kwestie odzwierciedlają oczekiwania wielu stron dyskursu wobec edukacji. Raport podsumowujący pierwsze spotkanie w ramach projektu Digital Sustainability Forum *Sztuczna inteligencja jako element zrównoważonego rozwoju gospodarczo-społecznego* (2019) wskazuje dwie podstawowe bariery w rozwijaniu pożądaných kompetencji. Przede wszystkim polski system edukacji nie jest skierowany na naukę pracy zespołowej, podczas gdy prace nad sztuczną inteligencją jej wymagają. Polska edukacja i nauka silnie cechują się jednorodnością w opisywaniu wiedzy, podczas gdy sztuczna inteligencja jest interdyscyplinarna i wymaga wiedzy z wielu dziedzin wzajemnie się przenikających.

Wśród priorytetów wskazanych przez sektor korporacji i firm związanych z AI oraz ośrodków akademickich są postulaty podstawowej edukacji – środowiska te proponują wprowadzenie zajęć z programowania (np. języka Python) w szkołach podstawowych i średnich oraz podstaw AI na poziomie szkół średnich (Borowiecki i Mieczkowski, 2021). Wynika to z tego, że w społeczeństwie kształtowanym przez algorytmy, koniecznością jest podstawowa znajomość ich zasad działania oraz umiejętność ich wykorzystania ze świadomością tworzonych przez nie szans i zagrożeń. Dlatego edukacja – często wspominana, lecz równie często bagatelizowana – jest uznana za kluczowy element w zrównoważonym rozwoju (Mileszyk, Paszcza i Tarkowski, 2019).

Jednocześnie w obszarze edukacji, jak w żadnym innym, nie należy szukać nowego otwarcia – kompetencje potrzebne do rozumienia i pracy z algorytmami i sztuczną inteligencją to w dużej mierze te same kompetencje cyfrowe, o których rozwój postuluje się od wielu lat (Fedorowicz i Ratajski, 2015).

Nacisk na edukację medialną kładzie coraz szersze grono badaczy i pedagogów, ponieważ dostępowi do nowoczesnych technologii nie zawsze towarzyszy równie szybki wzrost kompetencji cyfrowych, nie tylko wśród dzieci i młodzieży (Tarkowski i in., 2018). Niemniej kompetencje cyfrowe młodzieży są na coraz wyższym poziomie. Ostatnie badania zachowań w świecie cyfrowym młodych ludzi pokazują, że smartfon jest dla nich najczęściej wykorzystywanym narzędziem do korzystania z Internetu (97%). Daleko na drugim miejscu jest komputer przenośny lub laptop (56,4%). Młodzież samodzielnie używa portali społecznościowych, bez pomocy innych zdobywa informacje potrzebne w nauce, korzysta z Internetu w celu komunikacji z innymi, ściąga pliki czy wykorzystuje Internet, aby rozwijać swoje pasje, hobby i zainteresowania (74–80% odpowiedzi). Kłopotem jest dbanie o zdrowie i poczucie dobrostanu. Co czwarty nastolatek czuje się przeładowany informacjami. Tyle samo uczniów deklaruje rezygnację ze snu na rzecz korzystania ze smartfona. Nadużywanie smartfonów wiąże się nie tylko z odczuwaniem negatywnych emocji, ale również z objawami somatycznymi. 10% nastolatków biorących udział w badaniu zgłosiło: bóle głowy, zawroty głowy, mdłości, zdarzające się pominięcie posiłku z powodu nadużywania smartfona (Dębski i Bigaj, 2019). Wspomnieć należy, że często młodzież pozostaje z nowymi technologiami i wyzwaniem z nimi związanym – sama. Uczestnicy wspomnianego badania przyznali, że: 1) ich rodzice w ogóle nie wiedzą, do czego ich dzieci używają Internetu i smartfona (1/3 uczniów), 2) rodzice nie uczą ich odpowiedzialnego korzystania z Internetu oraz smartfona (60,6%), lub też 3) w znikomym stopniu mogliby liczyć na pomoc swoich rodziców w przypadku wystąpienia czegoś niepokojącego w Internecie (26%). Za to prawie połowa uczniów pomaga rodzicom rozwiązywać problemy związane z korzystaniem z sieci. Rekomendacje prowadzące do podniesienia umiejętności codziennego wykorzystywania Internetu oraz nowych technologii w ramach edukacji medialnej dotyczą więc całego społeczeństwa, nie tylko najmłodszych grup; a wręcz powinny być odpowiednio dobierane w pakiety adresowane do grup: rodziców, nauczycieli, uczniów oraz młodszych dzieci. Szczególnie ważna według autorów jest potrzeba stworzenia odrębnych rekomendacji dla rodziców, którzy w ich opinii urastają do rangi osób kluczowych w wychowaniu cyfrowym swoich dzieci, przede wszystkim w okresie przedszkolnym i wczesnej edukacji (Dębski i Bigaj, 2019).

Wstępne wnioski i rekomendacje

W najbliższym czasie, szczególnie po pandemii COVID-19, zdecydowaną rolę zącą odgrywać unikatowe, pogłębione kompetencje specjalistyczne, oparte m.in. na umiejętności pracy ze sztuczną inteligencją. Pozwolą one rozwijać indywidualne stanowiska pracy, np. doradców i analityków, którzy nie tylko będą potrafili prognozować trendy i analizować duże strumienie danych (wsparci przez technologię), ale przede wszystkim będą rozumieć potrzeby rynku i odpowiednio komunikować je swoim partnerom i klientom.

Jak pokazują badania, wśród kompetencji przyszłości są również społeczne, takie jak umiejętność zarządzania ludźmi oraz inteligencja emocjonalna, która w świecie

powszechnej współpracy z systemami opartymi na algorytmach i sztucznej inteligencji może być nieoceniona. Wreszcie ostatnia z umiejętności, na którą zwrócili uwagę badani, to zdolność do „organicznego” dostosowania się do struktury i funkcjonowania firmy w nowym środowisku cyfrowym (Pokojska, Śledziwska i Włoch, 2020). Należy zwrócić uwagę, że dokładnie na te kompetencje kładzie obecnie nacisk edukacja medialna. Jej celem jest modelowanie umiejętności na trzech poziomach: technicznym – opanowanie konkretnych umiejętności posługiwania się nowoczesnymi narzędziami; zawodowo-społecznym – umiejętność zadbania o rozważne stosowanie narzędzi w kontekstach społecznym, zawodowym i osobistym; oraz poziomie krytycznej refleksji – gdy aktywność cyfrowa jednostki jest motorem jej kreatywności i innowacyjności, pozwala kształtować rozwój zawodowy (Ptaszek, 2019).

Rekomendowane jest pogłębienie wśród społeczeństwa zrozumienia tematu systemów zautomatyzowanego podejmowania decyzji (w tym AI) oraz technologii, na których te systemy są oparte. W społeczeństwie kształtowanym coraz bardziej przez algorytmy, podstawowa alfabetyzacja algorytmiczna jest koniecznością.

Podsumowując obserwacje zawarte w raportach o wykorzystywaniu narzędzi w AI i odbiorze nowych technologii przez społeczeństwo, można wymienić kilka powtarzających się postulatów. Dzięki ich realizacji udałoby się podnieść zaufanie społeczne do zmian technologicznych oraz zwiększyć udział różnych grup społecznych i zawodowych w budowaniu nowych rozwiązań w gospodarce i sektorze publicznym.

Rekomenduje się zwiększenie zrozumienia technologii wspieranych przez AI, nie ograniczając się przy tym do specjalistycznych grup zawodowych (np. polityków, urzędników, przedsiębiorców), ale kierując działania szeroko do społeczeństwa (Marczuk i in., 2019).

Należy podnosić świadomość etyczną oraz kompetencje społeczne w środowisku twórców, ekspertów wdrażających oraz użytkowników AI. Szkolenia na temat etyki i regulacji pracy z dużymi zbiorami danych powinny być częścią szerszego projektu edukacyjnego – przykładem jest fiński kurs „Elements of AI”, który z założenia ma być ukończony przez 1% obywateli Finlandii.

Pilnie trzeba uzupełnić programy nauczania o zagadnienia rozwijania kompetencji miękkich takich jak współpraca w grupie, położyć nacisk na pracę w zróżnicowanych i zmieniających się grupach projektowych.

Pracownicy instytucji publicznych powinni zostać objęci szkoleniami na temat AI i jej praktycznego wykorzystania zarówno w życiu zawodowym, jak i prywatnym.

Zadbanie o interes publiczny i budowanie zrozumienia wokół tematu AI pomogą zbudować społeczne zaufanie do technologii, które jest potrzebne, aby obywatele chcieli korzystać z innowacyjnych rozwiązań i wdrożeń. Zarazem podniesienie kompetencji medialnych osób w różnym wieku, korzystających z coraz nowszych narzędzi, pozwoli im na świadomą realizację swoich celów na wybranym polu – życia towarzyskiego, kulturalnego lub zawodowego.

Bibliografia

- Ajdukiewicz, K. (1964). *Logika pragmatyczna*. Warszawa: PWN.
- Alchin, N. and Henly, P. C. (2013). *Theory of Knowledge for the IB Diploma*. London: Hodder Education.
- Biczuk, J., Jamrogiewicz, P. i Malczewski, Ł. (2019). *Czy leci z nami robot? Badanie postrzegania sztucznej inteligencji przez dziennikarzy, d*fusion communication*.
- Borowiecki, Ł. i Mieczkowski, P. (2021). *State of Polish AI 2021*. Warsaw: Fundacja Digital Poland.
- Burski, J., Chłoń-Domińczak, A., Palczyńska, M., Rynko, M. i Śpiewanowski, P. (2013). *Umiejętności Polaków – wyniki Międzynarodowego Badania Kompetencji Osób Dorosłych (PIAAC)*. Warszawa: IBE.
- Dębski, M. i Bigaj, M. (2019). *Młodzi Cyfrowi. Nowe technologie. Relacje. Dobrostan*. Gdynia: Fundacja Dbam o Mój Z@sięg. <https://dbamomojzasieg.pl/mlodzi-cyfrowi/>
- Fedorowicz, M. i Ratajski, S. (2015). *O potrzebie edukacji medialnej w Polsce*. Warszawa: Polski Komitet do spraw UNESCO, Krajowa Rada Radiofonii i Telewizji.
- Federowicz, M. i Sitek M. (red.). (2017). *Program Międzynarodowej Oceny Umiejętności Uczniów. Wyniki badania PISA 2015 w Polsce*. Warszawa: Instytut Badań Edukacyjnych.
- Fundacja Centrum Cyfrowe, Fundacja Digital Poland, Microsoft (2019). *Sztuczna inteligencja jako element zrównoważonego rozwoju gospodarczo-społecznego*. Warszawa: Fundacja Centrum Cyfrowe, Fundacja Digital Poland, Microsoft.
- Fundacja Digital Poland (2020a). *Sztuczna inteligencja w Polsce – Kompetencje ekspertów AI*. Warszawa: Fundacja Digital Poland.
- Fundacja Digital Poland (2020b). *Technologia w służbie społeczeństwu. Czy Polacy zostaną społeczeństwem 5.0?. #Tech4Society*. Wyd. II, Warszawa: Fundacja Digital Poland.
- Kiss, M. (2017). *Digital skills in the EU labour market*. European Parliamentary Research Service.
- Lange, R., Ładna, A., Konopczyński, F. i Kowalczyk, M. (2019). *Sztuczna inteligencja w społeczeństwie i gospodarce. Analiza wyników ogólnopolskiego badania opinii polskich internautów*. Warszawa: NASK Państwowy Instytut Badawczy.
- Lau, J. (2011). *An Introduction to Critical Thinking and Creativity: Think More, Think Better*. Wiley.
- Marczuk, P., Mieczkowski, P., Calini, L. i Paszcza, B. (2019). *Iloraz sztucznej inteligencji – edycja 2*. Warszawa: Fundacja digitalpoland.

Mileszyk, N., Paszcza, B. i Tarkowski, A. (2019). *AlgoPolska. Zautomatyzowane podejmowanie decyzji w służbie społeczeństwu*. Kraków, Warszawa: Fundacja Centrum Cyfrowe, Klub Jagielloński.

OECD (2021). *21st-Century Readers: Developing Literacy Skills in a Digital World*, PISA, OECD Publishing, Paris, <https://doi.org/10.1787/a83d84cb-en>.

Pokojska, J., Śledziwska, K. i Włoch, R. (2020). *Przyszłość pracy w sektorze finansowym*. Warszawa: Sektorowa Rada ds. Kompetencji Sektora Finansowego; PARP.

Ptaszek, G. (2019). *Edukacja medialna 3.0. Krytyczne rozumienie mediów cyfrowych w dobie Big Data i algorytmizacji*. Kraków: Wydawnictwo Uniwersytetu Jagiellońskiego.

Sayers, D. (1948). The Lost Tools Of Learning. *Hibbert Journal: A Quarterly Review of Religion, Theology, and Philosophy*, 46(1).

Stęchły, W. i Dębowski, H. (2020). *Descriptive categories for Transversal Key Competencies*. Warszawa: SGH.

Tarkowski, A., Majdecka, E., Penza-Gabler, Z., Sienkiewicz, M. i Stunża, G. D. (2018). *Analiza strategii i działań mających na celu rozwój kompetencji cyfrowych w państwach Unii Europejskiej*. Warszawa: Fundacja Centrum Cyfrowe, Fundacja Digital Poland.

Torczyńska, M. (2019). Sztuczna inteligencja i jej społeczno-kulturowe implikacje w codziennym życiu. *Kultura i Historia*, 36(2), 106–216.

Wasilewska-Kamińska, E. (2016). *Myślenie krytyczne jako cel kształcenia. Na przykładzie systemów edukacyjnych USA i Kanady*. Warszawa: Wydawnictwa Uniwersytetu Warszawskiego. <https://doi.org/10.31338/uw.9788323525639>.

Przemysł

Związki sztucznej inteligencji i edukacji – szanse i zagrożenia dla stron procesu edukacji w kontekście miejskim

prof. dr hab. Jacek Szoltysek*
Jakub Stęchły**

Wprowadzenie

Zarówno sztuczna inteligencja (AI), jak również wirtualna i rozszerzona rzeczywistość (VR/AR) posiadają potężny potencjał do wprowadzania wielu zmian w życiu ludzi. W to wierzą powszechnie nie tylko informatycy, wierzy w to również coraz większa liczba ludzi, którzy, wsłuchując się w narrację informatyków, wspierają się wiedzą zaczerpniętą z książek lub obejrzanych filmów *science fiction* w poszukiwaniu wsparcia informacyjno-decyzyjnego. Są to pożądane działania, gdyż ci ludzie, stając przed problemem decyzyjnym, sami sobie nie radzą w zadawalającym stopniu z podejmowaniem decyzji, albo mogą sobie poradzić, ale pod warunkiem włożenia sporego nakładu pracy, co często jest zadaniem nieatrakcyjnym. Do takich zadań należy edukacja, która, mimo chwalebnych osiągnięć, ciągle obarcza ludzi obowiązkami, nudnymi procedurami zapamiętywania niepotrzebnych (jak się to często wydaje) informacji, które trudno uczącemu się powiązać w logiczne ciągi. Zarówno AI, jak też VR/AR, są przez nas w tych rozważaniach nazywane „zjawiskami”³⁵.

Mimo że wymienione zjawiska mają zasięg ponadlokalny, to jednak natężenie ich funkcjonowania³⁶ jest zintensyfikowane w obszarach miejskich. Być może mają one charakter przejściowy, związany z wyłanianiem się zarówno AI jak i VR/AR w kontekście ich implementacji i wykorzystania, niemniej wydaje się, że miasta z różnych powodów stwarzają warunki dla akceleracji rozwoju tych zjawisk.

Autorzy wyznaczyli przestrzeń – tworzoną przez nakładające się na siebie subprzestrzenie miasta – sztucznej inteligencji i VR/AR. Może ona aktywnie stymulować procesy edukacji. Nadto autorzy postanowili rozpoznać zakres oddziaływania tej przestrzeni na edukację.

Aby jednak był sens zagłębiania się w takie rozważania, należy: (1) zdefiniować wymienione pojęcia, (2) rozpoznać sensowność ich wyodrębnienia poprzez sformułowanie założeń bądź tez, (3) udowodnić (zgodnie z istotą tez) ich prawdziwość, (4) rozpoznać wzajemnie związki między tymi pojęciami i (5) rozpoznać hipotetyczne

³⁵ Użycie przez autorów pojęcia „zjawisko” jest figurą retoryczną, zaś jego uzasadnieniem jest próba objęcia tym samym pojęciem (oznaczającym to, co dane jest w poznaniu zmysłowym) większego zakresu zidentyfikowanych różnorodnych pojęć w sytuacji, gdy ta różnorodność dla narracji nie ma istotnego znaczenia z punktu widzenia oddziaływania na inne zjawiska (na edukację).

³⁶ Mówiąc o „natężeniu” zjawiska, autorzy mają na myśli charakterystyki ilościowe zjawiska, możliwe do przedstawienia w formie punktowej, powierzchniowej czy obszarowej.

* Uniwersytet Ekonomiczny w Katowicach, ORCID: 0000-0003-3266-0241

** Akademia WSB w Dąbrowie Górniczej, ORCID: 0000-0002-3595-1901

oddziaływanie tak sformułowanej przestrzeni na edukację – w tym zwrócić uwagę na szanse i zagrożenia.

Autorzy, rozważając problem zarysowany w tytule tych rozważań, sięgnęli po tezy³⁷. Teza jest zdaniem prawdziwym, a nie prawdopodobnym, co oznacza, że jest ona, w odróżnieniu od hipotezy, udowadniana³⁸. Tezy formułowane są sekwencyjnie, w miarę prowadzenia narracji.

Tabela 7. Tezy postępowania narracyjnego

Teza 1	Miasto to najpopularniejsze i najbardziej zaawansowane środowisko edukacji.
Teza 2	Miasto jako środowisko sprzyja kreowaniu innowacyjności poprzez tworzenie obiektywnych przesłanek dla różnych wymiarów bliskości międzyorganizacyjnej (w tym przede wszystkim geograficznej/przestrzennej), sprzyjając tym samym tworzeniu relacji emocjonalnych, czy szerzej – społecznych. Ponadto miasto jako środowisko wymusza na systemie oświaty bliskość organizacyjną i poznawczą.
Teza 3	Rozszerzona rzeczywistość (VR/AR) jest powiązana ze sztuczną inteligencją (AI).
Teza 4	Rozszerzona rzeczywistość (VR/AR) jest powiązana z miastem (jako zjawiskiem i podmiotem materialnym).
Teza 5	Sztuczna inteligencja (AI) jest powiązana z miastem (jako zjawiskiem i podmiotem materialnym).

Źródło: Opracowanie własne.

Uwaga: wszystkie przywoływane w tym tekście tezy pochodzą z Tabeli nr 7.

Postępowanie koncepcyjne oparto o heurystykę, rozumianą jako sztukę wykrywania nowych faktów i związków między nimi, prowadzących do poznania nowych prawd, czy może, jak uważał A. M. Turing, „zdolność do rozpoznawania danych, które następnie mogą być sprawnie i efektywnie wykorzystane do rozwiązywania problemów” (Firlej-Buzon, 2003, s. 25).

Celem niniejszego artykułu jest przeprowadzenie refleksyjnej narracji w oparciu o formułowane *ad hoc* tezy oraz prezentacja obszarów, w jakich uwarunkowania przestrzeni mogą wpływać na procesy edukacji.


³⁷ Według Słownika wyrazów obcych teza (gr. *thesis*) to twierdzenie zawierające treść podstawową dla jakiejś dziedziny, założenie, które ktoś zamierza udowodnić (Kopaliński, 1991).

³⁸ Teza jest udowadniana zawsze przy określonych założeniach, na podstawie których jest przeprowadzany dowód pozwalający tezę odrzucić bądź przyjąć, i sformułować twierdzenie, które ma istotne znaczenie dla danej dziedziny (Kuciński, 2010, s. 93). Teza jest udowadniana na drodze dedukcji.

Przestrzeń rozważań

Pod pojęciem „przestrzeni rozważań” autorzy rozumieją nakładające się na siebie zjawiska sztucznej inteligencji (AI), rozszerzonej rzeczywistości (VR/AR) oraz miasta jako struktury sieci współzależnych (patrz: Filip, 2015, s. 97–114). W tej przestrzeni autorzy sytuują edukację i identyfikują związki, jakie występują w połączeniach między tymi pojęciami/zjawiskami (Rys. 1).

Rysunek 1. Konceptyjna przestrzeń rozważań



Źródło: Opracowanie własne.

Tak zarysowana przestrzeń, zgodnie z przewidywaniami autorów, oddziałuje na kształt edukacji, rozumiany wielokontekstowo.

Rozwój procesorów graficznych (GPU) pod koniec ubiegłego wieku spowodował wzrost rynku gier komputerowych, na nowo zdefiniował nowoczesną grafikę komputerową i zrewolucjonizował przetwarzanie równoległe. W ostatnich latach wykorzystanie GPU do przetwarzania algorytmów uczenia głębokiego (*deep learning*) zapoczątkowało nowy etap w rozwoju sztucznej inteligencji z GPU pełniącym rolę mózgu komputerów, robotów i pojazdów autonomicznych, które potrafią postrzegać i rozumieć świat. Parafrazując apokryficzną³⁹ maksymę można powiedzieć, że prognozowanie przyszłości jest trudne, zwłaszcza w świecie, gdzie rozwój przełomowych metod przewidywania kształtu białek to produkt uboczny produkcji komputerowych strzelanek.

Sztuczna inteligencja to jedna z najbardziej dysrupcyjnych⁴⁰ technologii naszych czasów (King, 2018, s. 53–67). Zainteresowanie wykorzystaniem AI do innowacji miejskich stale rośnie. W szczególności rozwój inteligentnych miast – lokalizacji

³⁹ <https://quoteinvestigator.com/2013/10/20/no-predict/>. Mowa tu o szeregu rozmaitych wypowiedzi dotyczących przewidywania przyszłości, zbudowanych w oparciu o stwierdzenie: „Prognozowanie przyszłości jest trudne, zwłaszcza...”.

⁴⁰ Dysrupcyjny – charakteryzujący się nieciągłością, gwałtowny, nieliniowy, trudny do przewidzenia, a jednocześnie istotnie wpływający na codzienność/przyszłość (Głomb i in., 2019).

miejskich, które dzięki społeczności, technologii i polityce mogą zapewniać produktywność, innowacje, warunki życia, dobre samopoczucie, zrównoważony rozwój, dostępność, dobre zarządzanie i dobre planowanie – zwiększył zapotrzebowanie na innowacje wykorzystujące sztuczną inteligencję. Do najpopularniejszych technologii w kontekście inteligentnych miast należą między innymi internet rzeczy (IoT), pojazdy autonomiczne (AV), big data, 5G, robotyka, *blockchain*, przetwarzanie w chmurze, druk 3D, wirtualna rzeczywistość (VR), cyfrowe bliźniaki (*digital twins*) i sztuczna inteligencja (AI) (Kyriazopoulou, 2015, s. 14–15). Choć wszystkie te technologie mają kluczowe znaczenie w przekształcaniu naszych miast w inteligentniejsze, sztuczna inteligencja w połączeniu z tymi technologiami ma znaczny potencjał, aby sprostać wyzwaniom urbanizacyjnym naszych czasów (Rahman, 2017, s. 116).

W zdefiniowanej przestrzeni rozważań wyłania się nurt sztucznej inteligencji miejskiej – gdzie AI są ucieleśniane w miejskich przestrzeniach, infrastrukturze i technologiach, które razem przekształcają miasta w autonomiczne jednostki działające w sposób nienadzorowany (Cugurullo, 2020, s. 2–5). Inteligencja ta może manifestować się poprzez fizyczne artefakty, takie jak pojazdy autonomiczne, lub pozostawać na pierwszy rzut oka niewidoczna – choć z nie mniejszą siłą oddziaływania. Siłę algorytmów doskonale obrazuje eksperyment artysty Simona Weckerta. Polegał on na tym, że ulicą w centrum Berlina Weckert ciągnął wózek załadowany 99 telefonami komórkowymi. Wszystkie telefony miały włączone usługi lokalizacyjne. W rezultacie Mapy Google zaczęły ostrzegać kierowców o dużym korku na ulicy, którą szedł Weckert, i sugerować alternatywne trasy. Kierowcy podążali za podpowiedziami systemu sugerującymi zmianę trasy, by ominąć korki. Według Weckerta celem eksperymentu było zilustrowanie, jak poprzez zmiany w cyfrowym świecie można zmienić świat fizyczny (Mertala, 2021, s. 7).

Z takimi nieoczywistymi interakcjami pomiędzy światem rzeczywistym i cyfrowym łączy się pojęcie *urban computing*, które dotyczy badania i zastosowania technologii obliczeniowej na obszarach miejskich. Jako takie jest ściśle związane z planowaniem urbanistycznym, w szczególności z infrastrukturą, w tym z sieciami transportowymi, komunikacyjnymi i dystrybucyjnymi. Wyobrażamy sobie przyszłość, w której znacznie łatwiej jest zapewnić ludziom to, czego potrzebują i czego chcą, w tym między innymi edukację, pracę, opiekę zdrowotną i wszelkiego rodzaju usługi osobiste (dostęp do supermarketów, usług bankowych itp.). Tworzenie nowego, szerszego i łatwiejszego dostępu do usług czy miejsc może zostać utrudnione przez przeszkody w dotarciu do nich. Czas poświęcony na dojazd do szkoły lub pracy można byłoby spożytkować lepiej. Wydłużony czas przemieszczania się można traktować jako poważne ograniczenie korzystania z oferty usługowej. Nadto, gdy ludzie nie mają łatwego dostępu do profilaktycznej opieki zdrowotnej, późniejsze koszty odwrócenia niekorzystnych zmian mogą znacznie przewyższyć te, które zostałyby poniesione, gdyby zastosowano odpowiednie środki zapobiegawcze. Brak łatwego dostępu do supermarketów ze zdrową żywnością jest silnie skorelowany z otyłością (a tym samym chorobami serca, cukrzycą itp.) (Kolata, 2012, s. 12). Technologia AI może znacznie poprawić mobilność, a tym samym znacznie zmniejszyć te i inne nieefektywności na rynku, aby ułatwić codzienne życie.

Im łatwiej będzie ludziom się poruszać w przestrzeni miasta, tym bardziej żywe będą obszary miejskie i tym bardziej owocne będą interakcje społeczne i gospodarcze zachodzące w ich wnętrzu. Forma przemieszczania nie pozostaje również obojętna dla zdrowia mieszkańców miast (Stutzer and Frey, 2008, s. 339–366). Niebawem, podobnie jak w przypadku nawigacji samochodowej, decyzje o wyborze środka transportu pozostawimy aplikacji opartej o AI (Huiling and Goh 2017, s. 26–29).

Rzeczywistość wirtualna to generowana komputerowo symulacja trójwymiarowego obrazu lub środowiska, z którą w pozornie rzeczywisty lub fizyczny sposób może wejść w interakcję osoba korzystająca ze specjalnego sprzętu elektronicznego, takiego jak kask z ekranem wewnątrz i rękawiczki wyposażone w czujniki. Podobny cel zanurzenia użytkownika w środowisku wirtualnym ma rozszerzona rzeczywistość, która jest definiowana jako technologia nakładania obrazu wygenerowanego komputerowo na widok świata rzeczywistego przez użytkownika (Stevenson, 2010). Oba systemy są technologiami immersyjnymi, posiadającymi zdolność do generowania trójwymiarowego obrazu, który wydaje się otaczać użytkownika. Mają różne wspólne cechy, takie jak dostarczanie obrazu wygenerowanego komputerowo i obrazu trójwymiarowego lub tworzenie środowiska wirtualnego. Jednocześnie każdy system zakłada immersję, ale z inną intensywnością – zaczynając od semiimmersyjnego środowiska wirtualnego (w przypadku rzeczywistości rozszerzonej), a kończąc na środowisku w pełni immersyjnym (w przypadku rzeczywistości wirtualnej).

Od dłuższego czasu opinie badaczy w tej dziedzinie sugerują, że niedługo rzeczywistość wirtualna połączy się z rzeczywistością rozszerzoną (Kaufmann and Papp, 2006, s. 160–165). W związku z tym, opierając się na powyższych faktach, uważamy, że użycie w przyszłości terminu takiego jak rozszerzona rzeczywistość (XR – *extended reality*), który ujmuje cechy wspólne dla rzeczywistości rozszerzonej i wirtualnej, będzie mile widziane w literaturze specjalistycznej (Kwok i Koh, 2021, s. 1935–1940).

Kończąc rozważania w tej części, warto zdefiniować samo pojęcie miasta. Miasto jako zjawisko i podmiot materialny jest definiowane w rozmaity sposób, zależnie od kompetencji osoby definiującej oraz celu tworzenia definicji. Skoro jednak zwracamy uwagę na środowisko miasta sprzyjające kreowaniu innowacji w oparciu o wymiar bliskości przestrzennej (teza 2)⁴¹, wmontowując w ten wymiar aspekty relacji międzyludzkich (emocjonalne, społeczne), to warto zdefiniować miasto w takim właśnie kontekście przestrzenno-społecznym. Definicję tę zaproponowano w jednym z mniej znanych w Polsce dokumentów *The European Charter for the Safeguarding of Human Rights in the City adopting the stance of the European Charter of Local Autonomy*. W paragrafie 1.1. tego dokumentu czytamy: „miasto to wspólna przestrzeń, należąca do społeczności ją zamieszkującej, mającej prawo do zagwarantowania jej warunków spełnienia politycznego, społecznego i ekologicznego, przy jednoczesnym założeniu obowiązku solidarności” (UCLG Committee on Social Inclusion i in. 2012, s. 10, tłum. własne).

⁴¹ Każdorazowo odnosząc się do sformułowanych tez, autorzy kierują uwagę Czytelników do Tabeli 7 na s. 122.

W tak zarysowanej przestrzeni autorzy sytuują edukację, uznając, że odnajduje ona w niej swoje środowisko bytowania.

Edukacja w Polsce ma długą, dobrze udokumentowaną historię licznych reform. Koncepcyjnie zaczynają się one od 1551 roku⁴², zaś wdrażane są od 1773 roku⁴³. Zazwyczaj (poza trójstopniowym modelem szkolnictwa wprowadzonym przez Komisję Edukacji Narodowej) obejmowały: stronę ideologiczną (kształcenie teologiczne, kształcenie w języku polskim, germanizację i rusyfikację, założenia marksistowsko-leninowskie, kształcenie podporządkowane zmieniającej się władzy i promowaniu jej), dostosowywanie programów nauczania, podręczników oraz przejmowanie kontroli nad działalnością szkół i realizacją ustalonych programów nauczania. Można zatem stwierdzić, że na przestrzeni prawie 250 lat edukacja nie wychodzi poza krąg tych problemów. Zastanawiające jest to, że pojawiające się przełomowe technologie (tranzystor, Internet) nie wpłynęły na jej kształt. Znacznie ograniczona autonomia szkół (poza uczelniami wyższymi, posiadającymi elementy autonomii) jest utrwalana przez rozbudowywany aparat regulacyjny sprzyjający wszelkim formom kontroli i prowadzący do cementowania zachowań biurokratycznych w organizacji. Wyraża się to nadmiarem przepisów, dyrektyw, nierzadko dochodzi do paraliżu i ograniczenia jednostek wykonawczych, co w konsekwencji prowadzi do działań pozornych (Bieniok i Rokita, 1984, s. 117). Tak uwarunkowana organizacja szkolna ma niewiele swobody w zakresie kształtowania swojej identyfikacji.

Dowód dla tezy 1

Miasto to najpopularniejsze i najbardziej zaawansowane środowisko edukacji. To stwierdzenie należy rozpatrywać w dwóch perspektywach: (1) liczby placówek oraz (2) liczby uczniów pobierających naukę⁴⁴. Jeśli chodzi o pierwszą perspektywę: liczba placówek (1), to w grupie szkoły podstawowe można odnieść mylne wrażenie, że dominującym środowiskiem dla tego typu szkół jest wieś (8675 placówek wobec 5909 ulokowanych w miastach). Natomiast w zakresie drugiej perspektywy (2), w miastach do szkół podstawowych uczęszczało w roku 2019/20 1,9 mln uczniów, zaś na wsi – 1,1 mln (GUS, 2019, s. 32). Podobnie ma się rzecz z gimnazjami (które w okresie przywołanych badań GUS były w fazie wygaszania swojej działalności). W roku szkolnym 2019/20 (1) w miastach działało 1031 placówek, zaś na wsi 609. Dodatkowo gimnazjów kształcących dorosłych w miastach było 53, na wsi były 2 (GUS, 2019, s. 34). W sektorze szkół (a) ponadgimnazjalnych⁴⁵ i (b) ponadpodstawowych⁴⁶ (1) udział szkół zlokalizowanych w miastach wynosił 90,1%, na wsi natomiast 9,9% (GUS, 2019, s. 35). Pochodną tego stanu jest uczestnictwo w zajęciach rozwijających zainteresowania i uzdolnienia – wg stanu na 30 września 2018 roku w szkołach dla dzieci i młodzieży funkcjonowało 201,6 tys. szkolnych kół, klubów i zespołów prowadzących zajęcia pozalekcyjne

⁴² W 1551 roku Andrzej Frycz-Modrzewski napisał dzieło „O poprawie Rzeczypospolitej, składające się z 5 rozpraw. Jedną z nich „O szkole” dotyczyła szkolnictwa obywatelskiego i demokratycznego.

⁴³ W 1773 roku powołano do życia Komisję Edukacji Narodowej.

⁴⁴ W dowodzie dla tezy 1 zastosowano dwie perspektywy: 1 – oznaczającą liczbę placówek oraz 2 – liczbę uczniów pobierających naukę. Odnoszenie się do „1” zawsze jest kontekstem – perspektywą liczby placówek, natomiast do „2” zawsze oznacza odniesienie do liczby uczniów pobierających naukę. Dodatkowo zaprezentowano podział na szkoły ponadgimnazjalne, które oznaczono je literą „a”, oraz ponadpodstawowe, oznaczone literą „b”.

⁴⁵ (a) licea ogólnokształcące, technika oraz ogólnokształcące szkoły artystyczne;

⁴⁶ (b) specjalne szkoły przysposabiające do pracy, branżowe szkoły I stopnia oraz szkoły policealne.

i nadobowiązkowe. W zajęciach uczestniczyło 2301,9 tys. uczniów (liczonych tyle razy, w ilu zajęciach rozwijających zainteresowania i uzdolnienia uczestniczyli uczniowie) (GUS, 2019, s. 60). W proporcji będącej pochodną zarówno liczby, jak i usytuowania placówek edukacyjnych oraz uczących się można rozpatrywać kontekst przestrzenny (miasto – wieś) aktywności nauczycieli. W 2018/19 w Polsce zatrudnionych było 512 353 nauczycieli, w tym w miastach 357 811 (70%), zaś na wsi – 154 542 (30%) (GUS, 2019, s. 200). Zaprezentowane dane w wystarczającym stopniu uzasadniają **tezę 1**, sformułowaną w Tabeli 7 oraz przywołaną na początku tego akapitu – miasto jest najpopularniejszym i najbardziej zaawansowanym (w kontekście potencjału zgromadzonego w obszarach miast oraz aktywności edukacyjnej) środowiskiem edukacji.

Dowód dla tezy 2

Jeśli do argumentów zaprezentowanych w dowodzie dla tezy 1 dodać informację o lokalizacji w miastach praktycznie 100% uczelni wyższych (w których procesy nauczania też są realizowane), wówczas można założyć, że miasta również są obdarzone potencjałem kreowania nowych trendów w nauczaniu, biorąc pod uwagę masowość nauczania, jak również bliskość⁴⁷ (geograficzną, organizacyjną, poznawczą, instytucjonalną, kulturową czy społeczną), sprzyjającą w wielu wymiarach innowacjom. Boshma i Frenken w prosty sposób wyjaśniają to pojęcie – bliskość oznacza podobieństwo atrybutów organizacji (Boshma and Frenken, 2009, s. 120–135). W. Czakon bliskość odnosi do podobieństwa zarówno przestrzeni fizycznej, relacji emocjonalnych i społecznych, jak i podzielanych wartości kulturowych lub podobieństwa instytucjonalnych warunków działania (Czakon, 2010, s. 16–19). Klimas na podstawie analizy literatury przedmiotu wskazuje, że mimo pewnych niespójności na kreowanie wiedzy główny wpływ mają: bliskość geograficzna – bliskość przestrzenna może stymulować przepływy wiedzy; bliskość poznawcza – posiadanie podobnych baz wiedzy, patentów czy technologii, oraz bliskość organizacyjna. Niektórzy badacze wręcz twierdzili, że dyfuzja wiedzy i technologii wymaga bliskości organizacyjnej (Klimas, 2011, s. 19–20). Bez wątplenia wymienione trzy wymiary bliskości, niezależnie od tego, czy ich istotność współcześnie się zwiększa, czy też nie (np. waga/istotność wymiaru bliskości geograficznej może spadać w obliczu istnienia szerokiego wachlarza rozwiązań z zakresu wirtualizacji, coraz powszechniej stosowanych szczególnie od czasu lockdownów związanych z pandemią COVID-19) mają znacznie szersze znaczenie praktyczne. Bliskość przestrzenna nie jest neutralna (np. w tworzeniu relacji emocjonalnych czy społecznych), dlatego można ją traktować jako zestaw bazowych wymiarów bliskości. Spójrzmy na opisane stosunkowo szczegółowo środowisko edukacji (dodatkowo w kontekście miast) – te trzy wymiary od dawna istnieją w tle współpracy/współdziałania: placówek (jednostek szkolnych), nauczycieli i innej kadry związanej z funkcjonowaniem edukacji; stosunków z organami nadzoru pedagogicznego (kuratorzy oświaty), jak i organami prowadzącymi⁴⁸. Mamy więc w mieście nie tylko nagromadzenie instytucji edukacyjnych, tworzących według Floridy zasób nazwany „talentem”. Zwiększanie gęstości kontaktów międzyludzkich, wskutek tworzenia relacji emocjonalnych czy społecznych tworzy podstawy kolejnego zasobu, nazywanego „tolerancją”. Po uwzględnieniu poglądu

⁴⁷ Zwaną też „bliskością międzyorganizacyjną”.

⁴⁸ Zgodnie z art.10 Ustawy z 14.12.2016 r. Prawo oświatowe (t.j. Dz.U. z 2021, poz. 1082, ze zm.) – są nimi: minister, jednostka samorządu terytorialnego, osoby prawne i fizyczne, odpowiadające za ich działalność.

Florydy, że „3 T – technologia, talent i tolerancja” to kluczowe przesłanki sukcesu kreatywnego miasta, zaś dążenie do tego, by powiązać sukces miasta ze zwiększaniem jego kreatywności, owo nagromadzenie instytucji edukacyjnych wydaje się niezwykle korzystne w tym zakresie. Co prawda każdy z tych elementów oddzielnie jest konieczny, by osiągnąć sukces, ale oddzielnie nie jest wystarczający. Tylko realizacja wszystkich tych elementów jest w stanie generować nowatorstwo i stymulować wzrost ekonomiczny (Florida, 2011, s. 261). Niemniej przytoczone argumenty uzasadniają wysokie prawdopodobieństwo innowacyjności tak postrzeganego środowiska miasta.


Miasto jako środowisko sprzyja kreowaniu innowacyjności poprzez tworzenie obiektywnych przesłanek dla różnych wymiarów bliskości (w tym przede wszystkim geograficznej/przestrzennej), a tym samym tworzeniu relacji emocjonalnych czy społecznych. System oświaty zaś wymusza bliskość organizacyjną i poznawczą. Zatem **tezę 2** można uznać za uzasadnioną.

Nawiasem mówiąc – obecność w miastach uczelni wyższych może również być impulsem do kreowania innowacyjności w edukacji przy spełnieniu określonych warunków.

Związki między zjawiskami

Zdefiniowane powyżej zjawiska wypełniają z różną intensywnością przestrzeń rozważań. Mogą być one od siebie niezależne, lub w określony sposób współzależne (np. technologicznie czy regulacyjnie) i w taki też sposób wpływać na procesy edukacji. Przestrzeń rozważań w tej sytuacji jest pewnym ekosystemem, stąd naturalne jest dążenie do rozpoznania zależności, jakie wewnątrz takiego systemu są realizowane (Rys. 2).

Rysunek 2. Związki między zjawiskami



Źródło: Opracowanie własne.

Dowód dla tezy 3

Sztuczna inteligencja i rozszerzona rzeczywistość coraz częściej koegzystują, a nawet uzupełniają się w różnych sferach życia, takich jak: edukacja (Jiang, 2021), fitness (Zhao, 2021), rehabilitacja (Riva i in., 2019) sztuka (Lugrin i in., 2006) czy górnictwo (Mitra and Saydam, 2014). Wymienione różnorodne sfery wskazują na transwersalny charakter występowania tych technologii w warunkach koegzystencji, a nawet symbiozy – jednak przegląd literatury wskazuje na medycynę jako sferę, gdzie na dzień dzisiejszy rozwój jest najbardziej dynamiczny.

Za przykład niech posłużą symulatory rzeczywistości wirtualnej używane do szkolenia chirurgów (opisywane przez Winkler-Schwartz i in., 2019), śledzące wszystkie ruchy i siły symulowanych instrumentów chirurgicznych i generujące ogromne zbiory danych, które można dalej analizować za pomocą algorytmów uczenia maszynowego. Algorytmy te rozwijane są nie tylko w celu klasyfikowania uczestników szkolenia zgodnie z wiedzą chirurgiczną, ale przede wszystkim szkolenia w zakresie określonego standardu chirurgicznego. Systemy te pozwolą na prowadzenie studiów w celu dalszego wypracowania właściwego podejścia do wykorzystania tej technologii w nauczaniu umiejętności psychomotorycznych. Niezależnie od tego, co przyniesie przyszłość, jasne zrozumienie chirurgii, metodologii sztucznej inteligencji i najlepszych praktyk edukacyjnych będzie kluczowe dla ostatecznego sukcesu tych systemów, rozumianego jako osiągnięcie wyższych kompetencji przez chirurgów.

Jak wskazują Bastug i in. (2017), istnieją ograniczenia technologiczne związane z mocą obliczeniową oraz przepustowością systemów bezprzewodowej transmisji danych, ale rozwój systemów wykorzystujących AI i VR jest ograniczony również przez kwestie ochrony prywatności czy aspekty środowiskowe (energochłonność procesu przetwarzania informacji).

Zatem można trzecią tezę (**teza 3**), zgodnie z którą rozszerzona rzeczywistość (VR/AR) jest powiązana ze sztuczną inteligencją (AI), uznać za uzasadnioną.

Dowód dla tezy 4 i 5 (*smart city*)

Wymienione tezy (4 i 5) wiążą w zależności miasto i sztuczną inteligencję (AI) oraz rozszerzoną rzeczywistość (VR/AR). W tym celu należy założyć, że miasto do takiej zależności musi być odpowiednio przygotowane, innymi słowy – powinno posiadać określone atrybuty, tworzące dla wymienionych zjawisk ekosystem ich rozwoju połączony z korzyściami dla miasta. Internet rzeczy w kontekście miasta pojawia się zazwyczaj w nurcie dyskusji o mieście inteligentnym (*smart city*). Na czym polega „inteligencja” miasta? Wśród nurtów koncepcyjnych można wskazać dwa. Pierwszy jest stosunkowo jednolity, technologiczny – podkreśla możliwości internetu rzeczy (IoT) i technologii, które mamy do dyspozycji. Drugi nurt jest mniej jednolity i ma charakter kontemplacyjny. W ramach tego drugiego mieści się coraz większa liczba publikacji, które zwiększenie „inteligencji” miasta w istocie prowadzą do tego, by miasto pozyskało umiejętność „myślenia” (Szołtysek, 2017, s. 288). Mianem *smart* określa się „miasto, gdzie technologie są wzajemnie powiązane i rozwijane. Miejsce, które udostępnia zoperacjonalizowane doświadczenie życiowe, przenosząc je na zupełnie nowy poziom. To również miasto, którego

zarządzający posiadli umiejętność optymalizowania wzrostu, doskonalenia budżetu oraz proaktywnego planowania” (Export, 2016, s. 6). Miasto adaptujące się, proaktywne i zwinne, wykorzystujące szanse, odkodowujące dane, analizujące je oraz wykorzystujące to, co gromadzi się współcześnie w ramach big data. Zazwyczaj takie miasta są stosunkowo intensywnie zaopatrzone w „inteligentne przedmioty, mogące odczuwać, reagować na środowisko oraz przetwarzać i pamiętać informacje cyfrowe, a także przesyłać te informacje do innych przedmiotów (i tym samym do ich użytkowników) za pośrednictwem protokołów internetowych” (Czajkowski i Nowakowski, 2016, s. 28) – czyli w internet rzeczy.

W 2018 roku Szoltysek sformułował dwa paradygmaty *smart city*, wprowadzając tym samym swoistą „gradację inteligencji” miast. Wskazuje on na miasto „sprytne” oraz miasto „myślące” (Szoltysek, 2018, T. 3, s. 127–156). Jego zdaniem większość współczesnych polskich miast swój plan na przyszłość wiąże z dążeniem do bycia miastem „smart”. Działania podejmowane w tym zakresie zazwyczaj skoncentrowane są na stronie technicznej projektu, a efekty uzyskiwane dzięki oprzyrządowaniu pozwalają zarówno władzom miasta, wszelkiego rodzaju służbom miejskim jak i innym, dedykowanym użytkownikom, wykorzystywać informacje pozyskane z sensorów oraz wszelkich urządzeń monitorujących i rejestrujących. Dążą tym samym do zwiększenia sprawności (skuteczności, ekonomiczności czy korzystności) działania tych użytkowników oraz samego miasta. Takie działania rozpoczynają nową erę w funkcjonowaniu miasta – erę paradygmatu miasta sprytnego. Autor użył tu słowa spryt, gdyż w języku polskim oznacza on „zdolność do szybkiego, praktycznego radzenia sobie w trudnych sytuacjach” (Szymczak, 1981, s. 307). Decyzje na podstawie takich informacji podejmowane są zazwyczaj w dotychczasowym trybie, lecz bazują na szybszych i bardziej obiektywnych (mniej zniekształconych) danych źródłowych oraz większym zakresie takich danych. Stopniowe przechodzenie do kolejnych (wyższych) poziomów, w których zakres możliwości czerpania informacji i tworzenia na jej podstawie inteligentnie skrojonych na potrzeby szerokich rzesz odbiorców inteligentnych wypowiedzi – dorad, oznacza stopniową zmianę paradygmatu w kierunku miasta myślącego. Myślący to taki, „który samodzielnie myśli, analizuje i zastanawia się nad tym, co robi”, „uświadamia sobie coś i skupia na tym uwagę, usiłuje coś zrozumieć lub rozwiązać” (Szymczak, 1981, T. 2, s. 236).

Internet rzeczy (IoT) ma swoje główne miejsce w przestrzeni koncepcyjnej pomysłu *smart city*, zaś to ostatnie jest praktycznym przejawem funkcjonowania miasta w paradygmacie miasta myślącego. Miasto myślące sięga do trzech kluczowych zasobów: technologii informatycznych i komunikacyjnych, które są niezbędnym oprzyrządowaniem IoT, infrastruktury, wspierającej nie tylko mądre funkcjonowanie miasta, ale też mające istotny dodatni wpływ na rozwój IoT, wreszcie – kapitału kreatywnego, jedyne go zasobu, mogącego na bazie wcześniej wymienionych dokonywać innowacyjnego rozwoju miasta, oraz wszelkich osiągnięć koncepcyjnych i realizacyjnych, będących pożywką rozwoju dowolnej organizacji, grupy osób czy jednostek. Na styku tych wyznaczników oraz w ich głównym nurcie osadzone są współcześnie stosowane rozwiązania w mieście w nurcie *smart* – w tym bazujące zarówno na pomysłe rozszerzonej rzeczywistości (VR/AR) jak i sztucznej inteligencji (AI). Jak się okazuje, obszar zastosowania tych zjawisk w miastach jest rosnący, a powodem tego jest przede wszystkim to, że w mieście, jak w soczewce, skupiają się wszystkie problemy, z którymi ludzie, jako jednostki i grupy, realizują swoje

zadania, zaspokajają potrzeby, wreszcie korzystają z dostępnych usług. Podobnie ma się rzecz z procesami wytwarzania, zagospodarowania zasobów, kwestiami bezpieczeństwa, sportu, kultury, ochrony zdrowia czy edukacji – ten obszar wypełnia częściowo potrzeby mieszkańców, również w zakresie usług. Miasto, realizując przypisane mu funkcje, jak również poprzez tworzony ład gospodarczy, ekologiczny i społeczny, kieruje swoją ofertą do mieszkańców oraz otoczenia. W ten sposób kreuje swoje przewagi konkurencyjne, które ponadto wzmacnia w nieustannym dialogu z interesariuszami tak, by pozyskiwać nowych mieszkańców i utrzymywać dotychczasowych. Ponadto owo pozyskiwanie powinno być kierowane szczególnie do tych grup, które są w stanie „pobudzić” miasto do nowych form działania, by umożliwić mu skok cywilizacyjny w hierarchii miast. Wiele o tym pisał Florida (2011) czy McQuire (2008). Ten ostatni postrzega miasto jako różnorodne sieci cyfrowe i media elektroniczne w nim funkcjonujące, które zaczynają coraz więcej dyktować mieszkańcom, kształtować ich sposób życia oraz wyobrażenia o czasie i przestrzeni, wpływając nie tylko na życie jednostki czy grup, ale też na planowanie miejskie czy modę w architekturze. W swoich wyobrażeniach zbliża się on niebezpiecznie do Orwella, Foucalta czy Senneta (mamy tu na myśli *The fall of public man*). Przejmująco i zaskakująco trafnie opisana pół wieku temu przyszłość ludzkości przez Tofflera (w *Szoku przyszłości* i w *Trzeciej fali*) realizuje się współcześnie, a wyzwania techniczne, polegające na połączeniu biotechnologii i technologii informacyjnej stawiają przed ludźmi największe wyzwania, jakie kiedykolwiek ludzkość napotkała na swojej drodze. Tak uważa Harari (w książce *21 lekcji na XXI wiek*), zaś Taleb wieszczy niepredyktywność wizji świata (w *Antykruchości*). Nie wszystkie przewidywania poczynione przed wielu laty zrealizowały się. Potwierdzenie tych spostrzeżeń znajdujemy na pocztówce przedstawiającej wizję przyszłości miasta sprzed ok. 100 lat (Rys. 3).

Rysunek 3. Wizja przyszłości miasta Königshütte (dzisiejszy Chorzów), pocztówka z początku XX wieku



Źródło: Archiwum własne.

Ponieważ ciągle jeszcze wierzymy, że ludzkość w dominującej liczbie będzie mieszkać w miastach, oraz że brak jest alternatyw dla technologicznego, cyfrowego otoczenia, kształtującego nasze życie w każdym zakresie, należy uznać, że miasta w swoim funkcjonowaniu są współzależne i współwarunkujące dobrostan.

Uwzględniając powyższe, można stwierdzić, że uzasadnienie mają obie **tezy: 4** – rozszerzona rzeczywistość (VR/AR) jest powiązana z miastem i **5** – sztuczna inteligencja jest powiązana z miastem. W obu tezach miasto traktowane jest jako zjawisko i podmiot materialny.

Możliwości i potencjalne ograniczenia związane z potencjałem AI, VR/AR i miasta dla procesów edukacji

Możliwości

Jak wskazuje Elmquaddem (2019), wartość zastosowania wirtualnej rzeczywistości w edukacji i nauce jest częściowo związana z faktem, że ta technologia może usprawnić i ułatwić naukę, przyswajanie informacji i procesy decyzyjne podczas pracy w stymulujących warunkach. W rzeczywistości, kiedy czytamy treść tekstową (na przykład na wydrukowanym dokumencie), nasz mózg interpretuje wszystko, co czytamy, a to zwiększa nasz wysiłek poznawczy. W przypadku korzystania z wirtualnej rzeczywistości proces interpretacji jest skrócony, ponieważ jest mniej symboli do interpretacji, a rozumienie jest bardziej bezpośrednie. Na przykład łatwiej jest zrozumieć, jak działa maszyna, wizualizując jej działanie, niż czytając objaśnienie tekstowe. A gdy wizualizacja jest w 3D/VR, zrozumienie przychodzi jeszcze łatwiej. Fizyczny dostęp do wszystkiego, czego się uczymy, nie jest możliwy – VR pozwala nam uzyskać dostęp do wszystkiego, czego chcemy, wirtualnie, tak jakbyśmy naprawdę tam byli. Uczący się może na przykład zbadać Księżyc lub dno oceanu, albo zobaczyć, jak wyglądało dane miejsce w przeszłości. Pozwala to na lepsze zrozumienie rzeczy i zjawisk przy mniejszym wysiłku poznawczym ze strony uczącego się i niższych kosztach dla instytucji zajmujących się uczeniem. Uczeń jest bardziej zaangażowany, zmotywowany, otwarty, gotowy do nauki i komunikowania się z innymi.

W ciągu ostatnich dwóch dekad liczne badania wykazały mocne strony wykorzystania wirtualnej i rozszerzonej rzeczywistości w nauczaniu (Postawa, 2018). Jednym z najważniejszych ich atutów jest to, że zmieniają rolę nauczyciela z dostarczyciela wiedzy w facylitatora, który pomaga uczniom odkrywać i uczyć się (Youngblut, 1998). To silnie uzupełnia konstruktywistyczną teorię uczenia się. Uczniowie czują się wzmocnieni i zaangażowani, ponieważ mają kontrolę nad procesem uczenia się (Dede, 2005). Mogą uczyć się empirycznie i robić postępy we własnym tempie, ponieważ eksplorują środowisko wirtualne. Zapobiega to również sytuacjom, w których uczniowie pozostają w tyle podczas wykładu i spędzają resztę zajęć, próbując nadrobić zaległości (Jonassen i in., 1999).


Ponadto wirtualna rzeczywistość może pomóc uczniom w nauce abstrakcyjnych pojęć, ponieważ mogą oni doświadczać i wizualizować te pojęcia w środowisku wirtualnym. W przeciwieństwie do tradycyjnego procesu uczenia się, który zwykle opiera się na języku, koncepcyjne i abstrakcyjne środowisko uczenia się w rzeczywistości wirtualnej sprzyja aktywnemu uczeniu się i pomaga uczniom zrozumieć

wiedzę abstrakcyjną (Ray and Deb, 2018). Osoby uczące się, które mają niską orientację przestrzenną, szczególnie czerpią korzyści z wirtualnej rzeczywistości, ponieważ wizualizacje pomagają obniżyć zewnętrzne obciążenie poznawcze (Lee and Wong, 2014).

Według Kurubacaka i Altinpulluka (2017) AR zapewnia liczne korzyści edukacyjne. Dla uczących się korzyści te można podsumować jako: radość z zajęć, zmniejszenie obciążenia poznawczego, wzrost motywacji i zainteresowania zajęciami, zwiększona możliwość zadawania pytań, więcej interakcji między uczącymi się, nowe możliwości indywidualnego uczenia się, konkretyzacja abstrakcyjnych pojęć, wzrost efektywności procesu nauczania. W przypadku nauczycieli korzyści te polegają na przyczynianiu się do rozwoju kreatywności uczących się, zapewnieniu efektywnego udziału uczniów w zajęciach, możliwości prowadzenia zajęć we własnym tempie.

O ile związki między AI i VR/AR są wyraźne, gdyż należą do tych samych nurtów technologicznych, o tyle związki z miastem i edukacją są mniej oczywiste i wymagają dla ich zaistnienia podejmowania celowych działań. Obecnie procesy edukacyjne w coraz większym stopniu korzystają z szans, jakie stwarzają rozmaite technologie, w tym wymienione AI, VR/AR. Zaawansowanie w tym zakresie wzrasta wraz z dopływem nowych kadr nauczycielskich, wychowanych w środowisku cyfrowym oraz pod wpływem rosnących inwestycji w oprzyrządowanie, które gwałtownie przyspieszyły z nastaniem pandemii COVID-19. Wdrożenie edukacji z wykorzystaniem metod i technik nauczania na odległość było impulsem dla podjęcia działań, przesuujących proces edukacji z pozycji „1” do przyszłościowego prze-modelowania jej („2”) w kierunku zwiększenia w nim udziału AI oraz VR/AR (Rys. 4).

Rysunek 4. Zmiana wymiaru AI oraz VR/AR w przyszłym procesie edukacji



Źródło: Opracowanie własne.

Skuteczność takiej transformacji może być uwarunkowana wieloma czynnikami, jednak ramy tego opracowania zakładają pewne samoograniczenia. Autorzy proponują zatem przyjrzenie się uwarunkowaniom w układzie macierzy zaprezentowanej na Rys. 5. Uznając za obiektywnie istniejące elementy AI, VR/AR w różnym

stopniu zaawansowania, związku miasta i edukacji można rozpatrywać w czterech wymiarach (po 2 charakteryzujące odpowiednio edukację i miasto) i wypełnić je działaniami. Te działania powinny być aktywizowane oraz celowo formowane w środowisku miasta, by edukację umieścić w przestrzeni rozważań w miejscu lepiej wykorzystującym potencjał AI, VR/AR. Dla jasności należy wskazać, że pozycja „2” może być usytuowana w dowolnym miejscu przestrzeni, z tym, że każdorazowo zwiększanie lub zmniejszanie roli elementów składowych, wyznaczających przestrzeń rozważań, powoduje stosowną zmianę wynikową jakości⁴⁹ edukacji.

Rysunek 5. Macierz uwarunkowań zmiany jakości edukacji w układzie „edukacja – miasto”

EDUKACJA	Wymiar koncepcyjny	Kształtowanie potencjału jednostek edukacji, w tym podnoszenie kwalifikacji i kształtowanie kompetencji kadry nauczycielskiej oraz doskonalenie współpracy z interesariuszami	Wykorzystanie zasobów miasta dla zwiększenia atrakcyjności procesu edukacji w tym zarówno w aspekcie techniki i technologii, jak i historii, kultury, antropologii, tożsamość
	Wymiar formalny	Organizacja systemu edukacyjnego oraz nadzór kuratora oświaty, realizowania zadań organu założycielskiego, prowadzącego	Kształtowanie systemu edukacyjnego z punktu widzenia mnożenia korzyści pochodzących z bliskości międzyorganizacyjnej oraz innowacji
		Wymiar formalny	Wymiar koncepcyjny


MIASTO

Źródło: Opracowanie własne.

Im dalej usytuowana jest edukacja od kątów trójkąta przestrzeni rozważań, tym większe jest natężenie zjawiska, lub też istotność jego obecności w procesie edukacji (Rys. 6).

⁴⁹ Jakość, w tym jakość edukacji, to wbrew pozorom skomplikowane i niedopowiedziane zjawisko (por. Mizerek, 2012, s. 19). Uznając za wyjątkowo trafne postrzeganie jakości w kontekstach: doskonałości, wyników kształcenia, wyników audytu – przeglądu, misji, kultury czy transformacji, w naszym podejściu owa jakość jest traktowana przekrojowo jako dodatkowe szanse tworzone przez miasto, AI, VR/AR w kategoriach doskonałości.

Rysunek 6. Natężenie zjawisk w przestrzeni rozważań



Źródło: Opracowanie własne.

Autorzy w swoich rozważaniach koncentrują uwagę na II kwadrancie macierzy, tj. wymiarach koncepcyjnych zarówno edukacji, jak i funkcjonowania miasta. Odnajdują w nim postulaty intensywnego wykorzystywania w procesach edukacji zasobów miasta – technicznych i technologicznych (atrybuty *smart city*, AI, VR/AR), historii miasta jako zjawiska oraz miasta jako podmiotu materialnego, kultury (w tym miejsca miasta i jego mieszkańców w historii regionu, państwa, kontynentu etc., jak również w kontekście legend miejskich), tożsamości mieszkańców i szerzej – grup społecznych, oraz w kontekście antropologii, która wydaje się mieć szczególne znaczenie dla funkcjonowania miast. Dostęp do tych obszarów powinien być udostępniony poprzez technologie, o których tu dyskutujemy, i ten kanał powinien być „wmontowany” w procesy edukacji, odbywającej się zarówno w budynku szkoły, jak również w rozmaitych przestrzeniach miasta. Celem takich zabiegów jest zaoferowanie nowej jakości edukacji, ułatwiającej oraz porządkującej zrozumienie treści programowych, przez co owe treści powinny się stać bardziej atrakcyjne i pozyskać przymiot użyteczności, tak nieobecnej we współczesnym procesie uczenia się. Wmontowanie do procesu edukacji elementów przestrzeni rozważań pozwoli na zindywidualizowanie procesu nauczania w kontekście dostosowania do możliwości percepcyjnych uczniów, a także nadanie treściom programowym specyfiki miasta, w którym edukacja jest realizowana. Te oferty wydają się nowatorskie w kontekście ich potencjalnie masowego wykorzystania.

Ograniczenia

Podobnie jak w przypadku każdego postępu technologicznego, wirtualna rzeczywistość jest narzędziem, które musi być właściwie wykorzystywane, aby było skuteczne. Pomimo wielkiej obietnicy wirtualnej rzeczywistości i opisanych powyżej zalet, istnieją pewne ograniczenia, które należy uwzględnić podczas integracji wirtualnej rzeczywistości w środowisku edukacyjnym (Boyles, 2017).

Przez wiele lat głównymi przeszkodami w wykorzystaniu wirtualnej rzeczywistości w edukacji były koszty i moc obliczeniowa niezbędna do stworzenia realistycznych

środowisk (Merchant i in., 2014). Ponadto niektóre systemy wirtualnej rzeczywistości były trudne w użyciu (Youngblut, 1998), a sprzęt, który użytkownik musiał nosić, był nieporęczny i charakteryzował się ograniczoną immersywnością (Ray and Deb, 2016). Na szczęście postęp w technologii urządzeń mobilnych zmniejszył rozmiar urządzeń VR (Wu i in., 2013), a wprowadzenie rozwiązań takich jak Google Cardboard czy Oculus Quest sprawiło, że rzeczywistość wirtualna jest niezwykle przystępna cenowo.

Kolejną przeszkodą w wykorzystaniu wirtualnej rzeczywistości są dolegliwości zgłaszane przez jej użytkowników. Wybrani uczestnicy badań rzeczywistości wirtualnej odczuwali nudności, objawy choroby lokomocyjnej lub niewielkie bóle głowy podczas korzystania z urządzeń (Kinaterer i in., 2014). Takie dolegliwości miało nawet 10–20% użytkowników w jednym badaniu (Hussein i Nätterdal, 2015). Dzięki postępowi technicznemu w ciągu ostatniej dekady część przyczyn złego samopoczucia udało się usunąć, ale wciąż część populacji skarży się na „cybermdłości” (Caserman i in., 2021).

Kolejnym ograniczeniem jest kwestia opanowania zasad korzystania z wirtualnej rzeczywistości. Uczniowie i nauczyciele potrzebują dodatkowego czasu na naukę obsługi urządzeń wirtualnej rzeczywistości. Na przykład niewłaściwie wyregulowane wyświetlacze montowane na głowie mogą powodować rozmycie obrazów i tekstu (Hussein i Nätterdal, 2015), a dodatkowe obciążenie poznawcze związane z nauką nawigacji i eksploracji w wirtualnym świecie wymaga od nauczycieli poświęcenia czasu – swojego i uczniów – na naukę, obsługi urządzeń (Wu i in., 2013). Oprócz korzystania z narzędzi, nauczyciele lub administratorzy muszą pozyskać lub zbudować wirtualne światy lub symulacje dla swoich klas. Ponieważ większość nauczycieli nie ma czasu ani umiejętności technicznych, aby tworzyć własne aplikacje rzeczywistości wirtualnej, prawdopodobnie będą potrzebne osoby trzecie do tworzenia i utrzymywania tych programów i tworzenia treści. Mając to na uwadze, ważne jest również, aby używane programy można było łatwo modyfikować, dostosowywać lub aktualizować przez instruktorów dla określonych klas i uczniów (Kerawalla i in., 2006).

Należy pamiętać, że technologia rzeczywistości wirtualnej nie zmniejsza znaczenia planowania lekcji ani roli nauczyciela w nauczaniu w klasie. Chociaż rola nauczyciela wyposażonego w narzędzia wirtualnej rzeczywistości zwykle ogranicza się do bycia coachem i mentorem (Zhang, 2013), wskazówki nauczyciela nadal mają kluczowe znaczenie podczas korzystania z systemów wirtualnej rzeczywistości (Lee i in., 2010). Ponadto muszą istnieć jasne cele edukacyjne i oraz takie, które wspierają rzeczywistość wirtualną (Choi i in., 2016; Baker i in., 2009). W niektórych przypadkach rzeczywistość wirtualna nie jest najlepszą metodą osiągnięcia celu uczenia się (Pantelidis, 2010), dlatego konieczne jest przyjrzenie się programowi zajęć i określenie, gdzie może pomóc rzeczywistość wirtualna, a gdzie inne metody nauczania będą bardziej odpowiednie.

Warto również zaznaczyć, że nauczanie danego zagadnienia w wirtualnej rzeczywistości może zająć więcej czasu niż w przypadku tradycyjnych środków (Wu i in., 2013). Jeśli narzędzia wirtualnej rzeczywistości są trudne w użyciu, może to zniechęcić nauczycieli do korzystania z nich w swoich klasach (Choi, 2016). Ponadto, ponieważ wielu nauczycieli mogło nie mieć kontaktu z możliwościami lub

zastosowaniami wirtualnej rzeczywistości w klasie, należy znaleźć taką formę profesjonalnej edukacji, aby nauczyciele czuli się komfortowo, korzystając z technologii w swojej klasie i odkrywali nowe możliwości, jakie otwiera VR.

Podsumowanie

Rozważane kwestie przyszłości edukacji, realizowanej w środowisku miejskim w obliczu nowych wyzwań oraz szans, jakie stwarza rozwój AI i VR/AR, pozwalają na szereg refleksji oraz na sformułowanie wniosków, które uwzględniają również negatywnie zaskakującą odporność systemu edukacji na zmiany. I tak:

1. Technologie AI i VR/AR posiadają dysruptywny potencjał i będą istotnie wpływały na otaczającą nas rzeczywistość, również w kontekście miejskim i w kontekście edukacji.
2. Uwzględniając, że technologie AI i VR/AR oraz miasto są wzajemnie powiązane oraz że miasto jest najpopularniejszym i najbardziej zaawansowanym środowiskiem edukacji, można założyć, że innowacyjny klimat miasta oraz bliskość międzyorganizacyjna jednostek edukacyjnych stwarzają szansę na jakościową zmianę systemu edukacji przyszłości.
3. Twórcze połączenie zidentyfikowanych charakterystyk (w kontekście użyteczności) technologii AI i VR/AR oraz miasta ma na celu zaoferowanie nowej jakości edukacji, ułatwiającej oraz porządkującej zrozumienie treści programowych. Dzięki temu owe treści powinny stać się bardziej atrakcyjne, pozyskać przymiot użyteczności oraz stanowić uzupełnienie procesu edukacji o elementy przestrzeni rozważań. To pozwoli na zindywidualizowanie procesu nauczania w kontekście dostosowania do możliwości percepcyjnych uczniów, jak również na nadanie treściom programowym specyfiki miasta. Taki rozwój wydarzeń jest częścią pozytywnego scenariusza rozwoju rozważanej przestrzeni.
4. Jeśli nie dojdzie do materializacji czarnych scenariuszy silnej sztucznej inteligencji (AGI), trajektoria rozwoju zależeć będzie w dużej mierze od świadomości i współpracy interesariuszy w celu kontrolowanego przejścia od koncepcyjnych do formalnych wymiarów miasta i edukacji. Gdy tego zabraknie, grozi nam zdominowanie przestrzeni miejskich czy procesu edukacji przez niezrównoważone (w rozumieniu celów zrównoważonego rozwoju – SDG) rozwiązania, takie jak samochody osobowe w przypadku mobilności miejskiej.
5. Tak jak nie doczekaliśmy się latających rowerów, które jednak materializują się w innej formie (np. dronów), niektóre z rozważań dotyczących przyszłej edukacji nigdy nie zmaterializują się lub też pojawią się rozwiązania, których dzisiaj nie jesteśmy w stanie przewidzieć.
6. Autorzy wyrażają nadzieję, iż nadchodzącej zmianie technologicznej towarzyszyć będzie fundamentalna transformacja polskiego systemu edukacji w kierunku rozwoju ciekawości, otwartości na świat i ludzi oraz współpracy.

Niezależnie od trajektorii wspólnego rozwoju miast, edukacji i technologii, wszelkie formy wykorzystywania technologii jako narzędzia ograniczania swobód ekspresji i dostępu do wiedzy i propagowania dezinformacji stanowią siłę istotnie hamującą rozwój rozważanej przestrzeni.

Bibliografia

- Ab-Rahman, A., Hamid, U. Z. and Chin, T.A. (2017). Emerging technologies with disruptive effects: A review. *Perintise-J.*, 7, 111–128.
- Baker, S. C., Wentz, R. K. and Woods, M. M. (2009). Using virtual worlds in education: Second Life® as an educational tool. *Teaching of Psychology*, 36(1), 59–64.
- Bastug, E., Bennis, M., Médard, M. and Debbah, M. (2017). Toward interconnected virtual reality: Opportunities, challenges, and enablers. *IEEE Communications Magazine*, 55(6), 110–117.
- Bieniok, H. i Rokita J. (1984). *Struktura organizacji przedsiębiorstwa*. Warszawa: Państwowe Wydawnictwo Ekonomiczne.
- Boschma, R. A. and Frenken K. (2009). The Spatial Evolution of Innovation Networks: a Proximity Perspective. W: R.A. Boschma, R. Martin (eds). *The handbook of evolutionary economic geography*. Cheltenham: Edward Elgar.
- Boyles, B. (2017). *Virtual reality and augmented reality in education*. Center For Teaching Excellence, United States Military Academy. NY: West Point.
- Caserman, P., Garcia-Agundez, A., Zerban, A. G. and Göbel, S. (2021). Cybersickness in current-generation virtual reality head-mounted displays: systematic review and outlook. *Virtual Reality*, 25, 1–18.
- Choi, D. H., Dailey-Hebert, A. and Estes, J. S. (Eds.). (2016). *Emerging tools and applications of virtual reality in education*. Hershey, PA: Information Science Reference.
- Cugurullo, F. (2020). Urban artificial intelligence: From automation to autonomy in the smart city. *Frontiers in Sustainable Cities*, 2, 38.
- Czajkowski, R. i Nowakowski, W. (2016). IoT jako naturalna ewolucja Internetu, *Elektronika 4*, 28–32.
- Czakon, W. (2010). Hipoteza bliskości. *Przegląd Organizacji* 9, 16–20.
- Dede, C. (2005). Planning for neomillennial learning styles. *Educause Quarterly*, 28(1), 7–12.
- Elmqaddem, N. (2019). Augmented reality and virtual reality in education. Myth or reality? *International journal of emerging technologies in learning*, 14(3), 234–242.

Export opportunities (2016). *Smart Cities, Regions & Communities Vol.1*, 276. Department of Commerce USA.

Filip, A. J. (2015). Miasto jako struktura sieci współzależnych, *Studia Ekonomiczne. Zeszyty Naukowe Uniwersytetu Ekonomicznego w Katowicach* 217, 97–114.

Firlej-Buzon, A. (2003) Heurystyka – geneza oraz współczesne zastosowania. *Zagadnienia informacji naukowej*, 1, 23–37.

Florida, R. (2011). *The rise of creative class and how it's transforming work, leisure, community and everyday life*. Toronto: Basic Books.

Głomb, K., Jakubowski, M., Krawczyk, A., Kulisiewicz, T., Nowakowski, Z., Złotnicki, A. and Gajderowicz, T. (2019). *Kompetencje przyszłości w czasach cyfrowej dysrupcji. Studium wyzwań dla Polski w perspektywie roku 2030*. Warszawa: Instytut Badań Rynku, Konsumpcji i Koniunktur.

Główny Urząd Statystyczny (2019). *Oświata i wychowanie w roku szkolnym 2018/19*. Warszawa, Gdańsk: Główny Urząd Statystyczny, Urząd Statystyczny w Gdańsku.

Huiling, E. and Goh, B. (2017). AI, Robotics and Mobility as a Service: the Case of Singapore. *Field Actions Science Reports. The Journal of Field Actions* (Special Issue 17), 26–29.

Jiang, L. (2021). *Virtual Reality Action Interactive Teaching Artificial Intelligence Education System*. Complexity. Special Issue: Complexity Problems Handled by Advanced Computer Simulation Technology in Smart City. Hindawi.

Jonassen, D. H., Peck, K. L. and Wilson, B. G. (1999). *Learning with technology: a constructivist perspective*. Upper Saddle River, NJ: Merrill.

Kaufmann, H. and Papp, M. (2006). *Learning objects for education with augmented reality*. Proceedings of EDEN, International Media Systems. Wiedeń: Vienna University of Technology.

Kerawalla, L., Luckin, R., Seljeflot, S. and Woolard, A. (2006). Making it real: exploring the potential of augmented reality for teaching primary school science. *Virtual reality*, 10(3), 163–174.

Kinatereder, M., Ronchi, E., Nilsson, D., Kobes, M., Müller, M., Pauli, P. and Mühlberger, A. (2014). *Virtual reality for fire evacuation research*. 2014 Federated Conference on Computer Science and Information Systems (s. 313–321). Warszawa: FedCSIS.

King, B.A., Hammond and T., Harrington, J. (2017). Disruptive technology: Economic consequences of artificial intelligence and the robotics revolution. *J. Strateg. Innov. Sustain* 12, 53–67.

Klimas, P. (2011). Wymiary bliskości w sieciach innowacji. *Przegląd Organizacji* 4, 16–20.

- Kolata, G. (2012). Studies question the pairing of food deserts and obesity. *New York Times*, 17.
- Kopaliński, W. (1991). *Słownik wyrazów obcych i zwrotów obcojęzycznych*. Warszawa: Wiedza Powszechna.
- Kuciński, K. (2010). *Metodologia nauk ekonomicznych: dylematy i wyzwania*. Warszawa: Difin.
- Kurubacak, G. and Altinpulluk, H. (Eds.). (2017). *Mobile technologies and augmented reality in open education*. Hershey, Pennsylvania: IGI Global.
- Kwok, A. O. and Koh, S. G. (2021). COVID-19 and extended reality (XR). *Current Issues in Tourism*, 24(14), 1935–1940.
- Kyriazopoulou, C. (2015). Smart city technologies and architectures: A literature review. In Proceedings of the 2015 International Conference on Smart Cities and Green ICT Systems, Lisbon, Portugal, 20–22 May 2015 (1–12).
- Lee, E. A. L. and Wong, K. W. (2014). Learning with desktop virtual reality: Low spatial ability learners are more positively affected. *Computers & Education*, 79, 49–58.
- Lugrin, J., Cavazza, M., Palmer, M. and Crooks, S. (2006). Artificial intelligence-mediated interaction in virtual reality art. *IEEE intelligent systems* 21(5), 54–62.
- McQuire, S. (2008). *The Media City. Media, architecture and urban space*. London: Sage Publications Ltd.
- Merchant, Z., Goetz, E. T., Cifuentes, L., Keeney-Kennicutt and W., Davis, T. J. (2014). Effectiveness of virtual reality-based instruction on students' learning outcomes in K-12 and higher education: A meta-analysis. *Computers & Education*, 70, 29–40.
- Mertala, P. (2021). The pedagogy of multiliteracies as a code breaker: A suggestion for a transversal approach to computing education in basic education. *British Journal of Educational Technology* 52(6), 2227–2241.
- Mitra, R. and Saydam, S. (2014). Can artificial intelligence and fuzzy logic be integrated into virtual reality applications in mining? *Journal of the Southern African Institute of Mining and Metallurgy*, 114(12), 1009–1016.
- Mizerek, H. (2012). Jakość edukacji. Dyskursy, które wybrzmiały, milcząc. W: G. Mazurkiewicz (red). *Jakość edukacji. Różnorodne perspektywy*. Kraków: Wydawnictwo Uniwersytetu Jagiellońskiego.
- Pantelidis, V. S. (2010). Reasons to use virtual reality in education and training courses and a model to determine when to use virtual reality. *Themes in Science and Technology Education*, 2(1–2), 59–70.
- Postawa, A. (2018). *Rzeczywistość rozszerzona w nauczaniu i uczeniu się. Komunikacja a zmiana społeczna*. Wrocław: Instytut Pedagogiki Uniwersytetu Wrocławskiego.

Puryear, J. S. and Lamb, K. N. (2020) Defining Creativity: How Far Have We Come Since Plucker, Beghetto, and Dow?, *Creativity Research Journal*, 32(3), 206–214, DOI: 10.1080/10400419.2020.1821552

Ray, A. B. and Deb, S. (2016). Smartphone based virtual reality Systems in Classroom Teaching—a Study on the effects of learning outcome. In 2016 IEEE eighth international conference on technology for education (T4E) (pp. 68–71). IEEE.

Riva, G., Wiederhold, B. K., Di Lernia, D., Chirico, A., Riva, E. F. M., Mantovani, F. and Gaggioli, A. (2019). Virtual reality meets artificial intelligence: The emergence of advanced digital therapeutics and digital biomarkers. *Annual Review of CyberTherapy and Telemedicine* 17, 3–7.

Stevenson, A. (Ed.). (2010). *Oxford dictionary of English*. USA: Oxford University Press.

Szołtysek, J. (2017). Logistyka miasta wobec postulatów zwiększania „inteligencji” smart city W: R. Matwiejczuk i I. Pisz (red). *Logistyka w naukach o zarządzaniu*. Część I. Warszawa, Łódź: Wydawnictwo Społecznej Akademii Nauk.

Szołtysek, J. (2018). Miasto w dobie Internet of Things W: Ł. Sułkowski i D. Kaczorowska-Spychalska (red.). *Internet of Things. Nowy paradygmat rynku*. Warszawa: Difin.

Szymczak, M. (1981). *Słownik języka polskiego*. Warszawa: PWN.

UCLG Committee on Social Inclusion, Participatory Democracy and Human Rights (2012). *The European Charter for the Safeguarding of Humans Rights in the City*. Barcelona: United Cities and Local Governments.

Winkler-Schwartz, A., Bissonnette, V., Mirchi, N., Ponnudurai, N., Yilmaz, R., Ledwos, N. and Del Maestro, R. F. (2019). Artificial intelligence in medical education: best practices using machine learning to assess surgical expertise in virtual reality simulation. *Journal of surgical education*, 76(6), 1681–1690.

Wu, H. K., Lee, S. W. Y., Chang, H. Y. and Liang, J. C. (2013). Current status, opportunities and challenges of augmented reality in education. *Computers & education*, 62, 41–49.

Youngblut, C. (1998). *Educational uses of virtual reality technology*. Alexandria, Virginia: Institut for Defence Analysis.

Zhang, H. (2013). Pedagogical challenges of spoken English learning in the Second Life virtual world: A case study. *British Journal of Educational Technology*, 44(2), 243–254.

Zhang, L-F and Sternberg R. J. (2011). Revisiting the Investment Theory of Creativity, *Creativity Research Journal*, 23 (3), 229–238, DOI: 10.1080/10400419.2011.595974

Zhao, C. (2021). Application of Virtual Reality and Artificial Intelligence Technology in Fitness Clubs. *Mathematical Problems in Engineering*. Special Issue: AI Powered Service Optimization for Edge/Fog Computing, Hindawi, 1–10.

Usługi

Rola edukacji – potrzeba rozwoju kompetencji cyfrowych.

Perspektywa cyberbezpieczeństwa

dr hab. Jakub Brdulak*
Cezary Piekarski**

Wstęp

Dopasowanie edukacji do zapotrzebowania rynku jest szczególnie istotne w przypadku umiejętności, które są niszowe – dobrym przykładem są tutaj kompetencje w zakresie cyberbezpieczeństwa, gdzie rynek, zarówno polski, jak i globalny, mierzy się z brakiem pracowników.

Jak wskazują badania przeprowadzone przez portal HRK (polską firmę specjalizującą się w doradztwie personalnym) wraz z HackerU (izraelskim dostawcą szkoleń i usług z zakresu bezpieczeństwa IT):

zapotrzebowanie na kandydatów z branży cyberbezpieczeństwa jest obecnie bardzo wysokie (...). W Polsce na jednego kandydata przypada około 7 nieobsadzonych wakatów (...). Szacuje się, że w Polsce mamy około 17 500 nieobsadzonych stanowisk. Jeżeli obecny trend się utrzyma, liczba ta z roku na rok będzie się zwiększać. Oznacza to, że nawet osoby bez doświadczenia będą miały szansę na wejście na ten atrakcyjny rynek

(Gajewski i Zbudniewek, 2021, s. 4).

W związku z powyższym „popyt” na usługi edukacyjne w zakresie zarządzania bezpieczeństwem jest bardzo wysoki. Stąd kluczowe jest zaproponowanie rozwiązań, których efekty będą osiągalne w krótkim okresie, a nie dłuższym, charakterystycznym dla edukacji formalnej, np. 3 lat dla studiów licencjackich, czy w sumie 5 lat, doliczając studia magisterskie. Dynamika rynku cyberbezpieczeństwa jest tak duża, że około 50% treści dezaktualizuje się w ciągu 2 lat, stąd też edukacja w tym zakresie musi zostać zaprojektowana w krótkich pętlach procesu uczenia się, które umożliwiają zarówno szybkie przyswajanie przez uczących się nowych kompetencji, jak również szybkie „oduczanie” się tego, co się dany uczący nauczył.

Rozwiązaniem, które obecnie jest dyskutowane i wprowadzane do Europejskiego Obszaru Szkolnictwa Wyższego (ang. *European Higher Education Area – EHEA*) mogą być tak zwane „mikrokwalifikacje” lub „mikropoświadczenia” (ang. *micro-credentials*). Dla celów niniejszej publikacji będzie stosowane pojęcie w języku polskim „mikrokwalifikacje”. W Polsce dyskusja na temat mikrokwalifikacji również się rozpoczęła, w szczególności warto sięgnąć do publikacji ekspertów Stęchłego i Nowakowskiego (2021).

* Szkoła Główna Handlowa w Warszawie, ORCID: 0000-0002-7772-7721

** Standard Chartered

Celem niniejszego rozdziału będzie przedstawienie mikrokwalifikacji jako rozwiązania rozpoznawanego w edukacji formalnej dla skuteczniejszego kształcenia osób w zakresie kompetencji cyfrowych, a w szczególności kompetencji w obszarze cyberbezpieczeństwa.

Niniejszy rozdział dzieli się na następujące podrozdziały:

1. Mikrokwalifikacje – obecny status prac w Polsce oraz w EHEA
2. Charakterystyka kompetencji cyfrowych ze szczególnym wskazaniem kompetencji w zakresie cyberbezpieczeństwa
3. Mikrokwalifikacje jako odpowiedź na potrzeby edukacyjne w zakresie cyberbezpieczeństwa
4. Zintegrowany System Kwalifikacji (ZSK) a mikrokwalifikacje.

Ze względu na doświadczenia Cezarego Piekarskiego wynikające z pracy w sektorze finansowym, w dużym stopniu obserwacje przedstawione w rozdziale zostaną oparte na doświadczeniach autora w tym sektorze. Jednak zjawiska opisywane w niniejszym rozdziale nie dotyczą tylko sektora finansowego – mają charakter uniwersalny, stąd dane będą ogólniejsze i będą dotyczyć generalnie rynku pracy.

Rozdział zostanie oparty w głównej mierze na raportach eksperckich i danych dostępnych w Internecie. Cyberbezpieczeństwo i ogólnie kompetencje IT podlegają ciągłemu i dynamicznemu rozwojowi, dlatego można stwierdzić, że aktualna literatura naukowa przedmiotu nie nadąża za tą dynamiką. Mikrokwalifikacje, które będą szeroko prezentowane w niniejszym rozdziale, również są nowym zjawiskiem, nieopisanym jeszcze w szerokim zakresie w naukowej literaturze dotyczącej edukacji.

Niniejszy rozdział nie będzie koncentrować się nadmiernie na sztucznej inteligencji, jednakże ona także jest niezwykle dynamicznym zjawiskiem, które zostało szczegółowo opisane w pozostałych rozdziałach publikacji. Niewątpliwie sztuczna inteligencja jest ściśle związana z kompetencjami w obszarze cyberbezpieczeństwa, ponieważ staje się fundamentem zarządzania w tym obszarze, gdzie algorytmy „atakujące” mierzą się z algorytmami „broniącymi” organizacji, a człowiek staje się ekspertem nadzorującym działanie algorytmów. Jednocześnie coraz szersze wykorzystanie sztucznej inteligencji w edukacji umożliwi lepsze dopasowanie procesów kształcenia do indywidualnych cech osób uczących się, stąd pomimo nieskoncentrowania się na samym pojęciu „sztucznej inteligencji” w niniejszym rozdziale, będzie ona uwzględniana przy formułowaniu rekomendacji i wniosków.

Mikrokwalifikacje – obecny status prac w Polsce oraz w EHEA

Obecnie trwają intensywne prace w Europejskim Obszarze Szkolnictwa Wyższego nad włączeniem mikrokwalifikacji do formalnego kształcenia, a więc kształcenia, które jest powszechnie rozpoznawane i wpisuje się w europejskie ramy kwalifikacji.

Zaproponowana przez Komisję Europejską definicja mikrokwalifikacji lub mikropoświadczeń (micro-credentials) prezentuje Tab. 8.

Tabela 8. Definicja mikrokwalifikacji

Oryginalna definicja w języku angielskim:	tłumaczenie na język polski (własne):
A micro-credential is a proof of the learning out-comes that a learner has acquired following a short learning experience. These learning outcomes have been assessed against transparent standards. The proof is contained in a certified document that lists the name of the holder, the achieved learning outcomes, the assessment method, the awarding body and, where applicable, the qualifications framework level and the credits gained. Micro-credentials are owned by the learner, can be shared, are portable and may be combined into larger credentials or qualifications. They are underpinned by quality assurance following agreed standards.	Mikrokwalifikacja jest dowodem uzyskania efektów uczenia się przez ucznia po krótkiej nauce. Te efekty uczenia się zostały zweryfikowane na podstawie przejrzystych standardów. Jest to poświadczony dokument, który zawiera nazwisko posiadacza, osiągnięte efekty uczenia się, metody oceniania, dane instytucji przyznającej mikrokwalifikację oraz, jeśli jest to potrzebne, poziom ram kwalifikacji i zdobyte punkty. Osoba, która zdobyła mikrokwalifikację, może je okazywać, przenosić i łączyć w większe pakiety lub kwalifikacje. Ich jakość zapewniają określone standardy.

Źródło: Komisja Europejska (2020). A European approach to micro-credentials output of the Micro-credentials Higher Education Consultation Group, s. 10.

Analizując powyższą definicję, warto zwrócić uwagę na następujące kluczowe cechy mikrokwalifikacji:

- mikrokwalifikacje są zawarte w konkretnym poświadczeniu/dowodzie – może to być np. certyfikat osiągnięcia przez uczącego się określonych efektów uczenia się,
- mikrokwalifikacje obejmują krótki okres, a więc osiągnięcie efektów uczenia się następuje w krótszym czasie niż np. w przypadku studiów licencjackich lub magisterskich,
- certyfikat (dowód) zawiera wskazane w definicji elementy opisane językiem umożliwiającym jego przyporządkowanie do konkretnego poziomu ramy kwalifikacji,
- certyfikat (dowód) jest powszechnie rozpoznawalny, co oznacza, że może m.in. stanowić element formalnych programów studiów,
- wskazane w certyfikacie (dowodzie) efekty uczenia się są poświadczane przez zewnętrzną instytucję zapewniającą jakość.

W praktyce do mikrokwalifikacji mogą być zaliczone wszelkie kursy czy szkolenia oferowane nie tylko przez uczelnie, ale też przez różnego typu podmioty prywatne. Aby nie doprowadzić do chaosu w tym obszarze, projekty europejskie dyskutują nad zapewnianiem jakości zarówno samych mikrokwalifikacji, jak również „certyfikowaniu” podmiotów, które oferują mikrokwalifikacje.

Charakterystyka kompetencji cyfrowych ze szczególnym wskazaniem kompetencji w zakresie cyberbezpieczeństwa

Najistotniejszym dokumentem w Europie wskazującym kompetencje w procesie uczenia się są Zalecenia Rady z dnia 22 maja 2018 r. w sprawie kompetencji kluczowych w procesie uczenia się przez całe życie. Dokument wyróżnia 8 kompetencji:

1. kompetencje w zakresie rozumienia i tworzenia informacji,
2. kompetencje w zakresie wielojęzyczności,
3. kompetencje matematyczne oraz kompetencje w zakresie nauk przyrodniczych, technologii i inżynierii,
4. kompetencje cyfrowe,
5. kompetencje osobiste, społeczne i w zakresie umiejętności uczenia się,
6. kompetencje obywatelskie,
7. kompetencje w zakresie przedsiębiorczości,
8. kompetencje w zakresie świadomości i ekspresji kulturalnej.⁵⁰

Cyberbezpieczeństwo wchodzi w skład kompetencji cyfrowych. Poniższa tabela prezentuje szczegółowe zapisy zawarte w wyżej przytoczonym dokumencie dotyczące kompetencji cyfrowych.

Tabela 9. Kompetencje cyfrowe jako kompetencje kluczowe w procesie uczenia się przez całe życie

<p>Kompetencje cyfrowe obejmują pewne, krytyczne i odpowiedzialne korzystanie z technologii cyfrowych i interesowanie się nimi do celów uczenia się, pracy i udziału w społeczeństwie. Obejmują one umiejętność korzystania z informacji i danych, komunikowanie się i współpracę, umiejętność korzystania z mediów, tworzenie treści cyfrowych (w tym programowanie), bezpieczeństwo (w tym komfort cyfrowy i kompetencje związane z cyberbezpieczeństwem), kwestie dotyczące własności intelektualnej, rozwiązywanie problemów i krytyczne myślenie.</p> <p>Niezbędna wiedza, umiejętności i postawy powiązane z tymi kompetencjami:</p> <p>Niezbędne są rozumienie, w jaki sposób technologie cyfrowe mogą pomagać w komunikowaniu się, kreatywności i innowacjach oraz świadomość związanych z nimi możliwości, ograniczeń, skutków i zagrożeń. Niezbędne jest rozumienie ogólnych zasad, mechanizmów i logiki leżących u podstaw ewoluujących technologii cyfrowych oraz znajomość podstawowych funkcji i korzystanie z różnych rodzajów urządzeń, oprogramowania i sieci. Niezbędne są przyjmowanie krytycznego podejścia do trafności, wiarygodności i wpływu informacji i danych udostępnianych drogą cyfrową oraz świadomość prawnych i etycznych zasad związanych z korzystaniem z technologii cyfrowych. Niezbędna jest zdolność do korzystania z technologii cyfrowych w celu wsparcia aktywnej postawy obywatelskiej i włączenia społecznego, współpracy z innymi osobami oraz kreatywności w realizacji celów osobistych, społecznych i biznesowych. Umiejętności obejmują zdolność do korzystania z treści cyfrowych, uzyskiwania do nich dostępu, ich filtrowania, oceny, tworzenia, programowania i udostępniania. Niezbędna jest zdolność do</p>

⁵⁰ (2018/C 189/01)

cd. Tabeli 9. Kompetencje cyfrowe jako kompetencje kluczowe w procesie uczenia się przez całe życie

zarządzania informacjami, treściami, danymi i tożsamościami cyfrowymi oraz do ich ochrony, a także do rozpoznawania i skutecznego wykorzystywania oprogramowania, urządzeń, sztucznej inteligencji lub robotów. Korzystanie z technologii i treści cyfrowych wymaga refleksyjnego i krytycznego, a zarazem pełnego ciekawości, otwartego i perspektywicznego nastawienia do ich rozwoju. Wymaga również etycznego, bezpiecznego i odpowiedzialnego podejścia do stosowania tych narzędzi.

Źródło: Zalecenie Rady z dnia 22 maja 2018 r. w sprawie kompetencji kluczowych w procesie uczenia się przez całe życie (2018/C 189/01), s. 9–10.

Warto też zwrócić uwagę na opracowanie europejskie dotyczące wpływu sztucznej inteligencji na kształcenie. Publikacja ta prezentuje przyszłe kompetencje związane ze sztuczną inteligencją wraz z szacunkiem prawdopodobieństwa ich trwałości.

Tabela 10. Obszary kompetencji i prawdopodobieństwo ich zakłócenia w przyszłości

Obszar kompetencji	Opis	Prawdopodobieństwo zakłócenia
Technicy	wysoki poziom kompetencji technicznych	umiarkowane
Rzemieślnicy	średni poziom kompetencji technicznych, niski poziom kompetencji zarządczych	bardzo wysokie
Czyniący	podstawowe umiejętności	wysokie
Rozwiązujący	umiejętności zarządcze i krytyczne myślenie	minimalne
Facylitatorzy	umiejętności emocjonalne	umiarkowane
Dostawcy	wysoki poziom umiejętności analitycznych	niskie

Źródło: Tuomi, I. (2018). The Impact of Artificial Intelligence on Learning, Teaching, and Education. Policies for the future, Eds. Cabrera, M., Vuorikari, R., Punie, Y., EUR 29442 EN, Publications Office of the European Union, Luxembourg, s. 24.

Kwestie związane z kompetencjami w zakresie cyberbezpieczeństwa są jednym z kluczowych obszarów analiz i działalności Agencji Unii Europejskiej ds. Cyberbezpieczeństwa (ang. European Union Agency for Cybersecurity – ENISA). Jest to organizacja, której celem jest osiągnięcie wysokiego wspólnego poziomu cyberbezpieczeństwa w całej Unii Europejskiej poprzez aktywne wspieranie państw członkowskich, instytucji, organów, urzędów i agencji Unii w poprawie cyberbezpieczeństwa (De Zan and Di Franco, 2019, s. 1). Jednym z działań ENISA jest stworzenie bazy danych o formalnych programach studiów w zakresie cyberbezpieczeństwa w krajach Europejskiego Obszaru Gospodarczego oraz Szwajcarii. Baza danych ma stać się głównym punktem odniesienia dla wszystkich obywateli Europy, którzy chcą podnieść swoją wiedzę i umiejętności w zakresie cyberbezpieczeństwa poprzez ukończenie studiów wyższych (De Zan and Di Franco, 2019, s. 3).

ENISA sformułowała szereg rekomendacji mających na celu wsparcie kształcenia w zakresie cyberbezpieczeństwa. Prezentuje je Tab. 11.

Tabela 11. Rekomendacje ENISA odnośnie kształcenia w zakresie cyberbezpieczeństwa


<p>1. Wpływ certyfikacji stopni cyberbezpieczeństwa* na niedobór umiejętności w zakresie cyberbezpieczeństwa (ang. <i>The cybersecurity skills shortage – CSSS</i>). Rozwiązania krajowe dotyczące certyfikacji z zakresu cyberbezpieczeństwa powinny być poddawane systematycznej i pogłębionej analizie pod kątem wdrożenia i wyników już stosowanych certyfikacji krajowych. Powinno się rozpoznawać stosowane najlepsze praktyki w poszczególnych krajach, możliwe do wdrożenia w innych krajach po dopasowaniu ich do lokalnych systemów edukacji i rynków pracy. Na przykład w wyniku analizy mogą być porównywane stopnie certyfikowane z niecertyfikowanymi z zakresu cyberbezpieczeństwa w następujących obszarach:</p> <ul style="list-style-type: none"> ▪ w jakim stopniu studenci doskonalą swoją wiedzę i umiejętności z zakresu cyberbezpieczeństwa; ▪ w jakim stopniu certyfikowane stopnie naukowe przyciągają studentów, którzy przed podjęciem studiów są jedynie marginalnie zainteresowani cyberbezpieczeństwem jako szansą na karierę; ▪ odsetek studentów podejmujących pracę w zakresie cyberbezpieczeństwa oraz rola, sektor, staż pracy i poziom wynagrodzenia na tym stanowisku; ▪ czas potrzebny studentom na znalezienie pracy po ukończeniu studiów; ▪ poziom zadowolenia pracodawców z absolwentów certyfikowanych programów cyberbezpieczeństwa; ▪ poziom zadowolenia edukatorów z partnerstwa z branżą; ▪ poziom zadowolenia studentów z dyplomu; ▪ inne konkretne wyniki, które mogą przynieść certyfikowane programy, na przykład poziom włączenia mniej reprezentowanych segmentów populacji lub zwiększona współpraca z krajowymi ekosystemami cybernetycznymi.
<p>2. Przyjmowanie i promowanie bazy danych ENISA o cyberbezpieczeństwie szkolnictwa wyższego. Baza danych będzie użytecznym instrumentem dla obywateli tylko wtedy, gdy będzie zawierała większość odpowiednich stopni bezpieczeństwa cybernetycznego w Europie, albo nawet wszystkie. Jeżeli baza danych osiągnie ten cel, umożliwi również dalszą analizę ewoluującego stanu edukacji cyberbezpieczeństwa w UE. W najlepszym interesie instytucji szkolnictwa wyższego będzie aktywne dodawanie stopni cyberbezpieczeństwa do bazy danych, ponieważ będzie to kolejny sposób na dalszą promocję i publikację ich oferty edukacyjnej.</p>
<p>3. Charakter i cechy CSSS w UE. Raport ten zagregował dostępne dane, aby lepiej zrozumieć CSSS, ale również zwrócił uwagę na brak szczegółowych i istotnych informacji na temat niedoborów w UE, zwłaszcza w porównaniu z informacjami dostępnymi w innych krajach. Ponieważ opracowanie polityki mającej na celu złagodzenie niedoboru powinno być poprzedzone szczegółową analizą problemu, nadal istnieje zbyt wiele luk w naszej wiedzy na temat CSSS UE, które należy wypełnić.</p>
<p>4. Działania systemowe są najskuteczniejsze w zwiększaniu liczby specjalistów. Aby upewnić się, że niedobór został rozwiązany w taki sposób, jaki jest (kwestia ilościowa i jakościowa), decydenci odpowiedzialni za gospodarkę powinni zapewnić, że na rynek pracy wejdzie więcej specjalistów. Polityki takie jak certyfikacja stopni najprawdopodobniej przyczyniają się do podniesienia jakości wiedzy i umiejętności, ale nie jest jasne, w jakim stopniu skłaniają one więcej osób do przyłączenia się do sektora. Istnieją inne polityki, które zostały wdrożone w celu zwiększenia zainteresowania karierą w zakresie cyberbezpieczeństwa, takie jak konkursy, wyzwania, kampanie uświadamiające o możliwościach kariery i programy przekwalifikowania dla profesjonalistów już zatrudnionych.</p>
<p>5. Zaprojektowanie kompleksowej strategii rozwoju kadr z zakresu cyberbezpieczeństwa. Zaprojektowanie kompleksowej strategii rozwoju siły roboczej w zakresie cyberbezpieczeństwa, która wykracza poza politykę ukierunkowaną wyłącznie na system kształcenia i szkolenia. Zamiast tego powinna promować aktywną rolę pracodawców w rozwoju krajowej siły roboczej ds. cyberbezpieczeństwa.</p>
<p><i>*„certyfikowane stopnie cyberbezpieczeństwa” oznaczają wg ENISA kształcenie formalne rozpoznawane np. dyplomem ukończenia studiów I lub II stopnia (komentarz: Jakub Brdulak)</i></p>

Źródło: De Zan, T. and Di Franco F. (2019). Cybersecurity skills development in the EU. *The certification of cybersecurity degrees and ENISA's Higher Education Database, ENISA*, s. 30–32.

Dość prostą i dobrze obrazującą logikę kształcenia w zakresie cyberbezpieczeństwa zaproponowała ENISA w raporcie dotyczącym identyfikacji kluczowych czynników sukcesu przy organizacji krajowych konkursów w dziedzinie cyberbezpieczeństwa oraz przedstawienie obrazu aktualnej sytuacji w krajach partnerskich UE – Rys. 7.

Grafika oparta jest na metaforze drzewa symbolizującego kształcenie w zakresie cyberbezpieczeństwa planowane w horyzoncie długo-, średnio- i krótkookresowym. Aby osiągnąć rezultaty w tym obszarze (owoce), konieczne jest w pierwszym kroku kształtowanie świadomości dzieci w zakresie bezpieczeństwa. Następnym krokiem jest dostarczenie możliwości nabycia umiejętności (kompetencji) nastolatkom i studentom, w szczególności I stopnia studiów. Trzeci krok to ciągłe rozwijanie kwalifikacji osób dorosłych w tym obszarze. Mikrokwalifikacje dedykowane są przede wszystkim osobom dorosłym, dlatego bardzo dobrze wpisują się w tę logikę. Umożliwiają realizację krótkookresowych strategii zorientowanych na wąskie i precyzyjne dostarczanie brakujących kwalifikacji. Tutaj w szczególności istotną rolę mogą odegrać mikrokwalifikacje.

Rysunek 7. Model organizacji kształcenia w zakresie cyberbezpieczeństwa



Źródło: De Zan, T., Mudassar Yamin, M. (2021). *Towards a common ECSC Roadmap. Success factors for the implementation of national cyber security competitions*. ENISA, s. 44.

Mikrokwalifikacje jako odpowiedź na potrzeby edukacyjne w zakresie cyberbezpieczeństwa

Mikrokwalifikacje są rozpoznawane również przez pracodawców i traktowane jako pewna szansa w redukowaniu luk kompetencyjnych w kształceniu nie tylko akademickim, ale też zawodowym.

Stowarzyszenie Europejskich Izb Przemysłowo-Handlowych (Association of European Chambers of Commerce and Industry Association) prowadzi analizę inicjatywy mikrokwalifikacji i formułuje następujące oczekiwania, które powinny zostać spełnione przy ich wprowadzaniu (Eurochambres, 2021, s. 8):

Oczekujemy, że inicjatywa mikrokwalifikacji stworzy dobrowolne ramy, które mają na celu wspieranie, a nie nadmierne regulowanie rosnącej oferty krótkich kursów. Aby odnieść sukces, ramy muszą opierać się na czterech zasadach przewodnich, które sprawiają, że będą przydatne zarówno dla przedsiębiorstw, jak i osób uczących się, oraz przyczynią się do funkcjonowania rynków pracy:

1. Ramy muszą przede wszystkim promować kursy odpowiadające potrzebom rynku pracy.
2. Mikrokwalifikacje nie mogą podważać obecnych kwalifikacji formalnych w kształceniu zawodowym.
3. Wpisanie się w Europejską Ramę Mikrokwalifikacji musi być dobrowolnym wyborem dostawcy danej kwalifikacji (instytucji uczącej).
4. Celem ram powinno być wzmocnienie zaufania i przejrzystości możliwości szkoleniowych.

Jednocześnie Stowarzyszenie Europejskich Izb Przemysłowo-Handlowych jasno wskazuje, że mikrokwalifikacje mogą być odpowiedzią na szybkie uzupełnianie kwalifikacji przez pracowników w takich sektorach, w których niedobory kwalifikacji występują, a więc m.in. w cyberbezpieczeństwie.

Problem z niedoborem kadry w zakresie cyberbezpieczeństwa nie leży tylko po stronie kształcenia. Problemem są również nadmierne oczekiwania ze strony pracodawców, w szczególności w zakresie doświadczenia kandydatów. Jak pisze Fortinet – międzynarodowa amerykańska korporacja zajmująca się rozwojem i sprzedażą oprogramowania, urządzeń oraz usług z dziedziny bezpieczeństwa teleinformatycznego – na portalu internetowym aleBank.pl (Fortinet, 2020):

Jednym z największych problemów podczas rekrutacji specjalisty ds. bezpieczeństwa są oczekiwania zarządów firm co do kompetencji i doświadczenia kandydata. Z reguły znacznie przekraczają one to, co można osiągnąć w ciągu 5, 7 a nawet 10 lat kariery zawodowej. Co więcej, zawężanie możliwości zatrudnienia do tylko tych, którzy spełnialiby określone wymagania dotyczące doświadczenia i stażu pracy, często wyklucza najzdolniejszych i utalentowanych absolwentów. Tymczasem to oni zazwyczaj są chętni do nauki i ciekawi możliwości, jakie daje praca w obszarze cyberbezpieczeństwa.

Zdaniem autorów, wydłużanie doświadczenia jest odpowiedzią na brak narzędzi i informacji, która dałaby pewność zatrudniającemu o posiadaniu przez kandydata określonych efektów uczenia się, a więc wiedzy, umiejętności i kompetencji społecznych w zakresie cyberbezpieczeństwa.

ZSK a mikrokwalfikacje

Zintegrowany System Kwalifikacji (ZSK) został wprowadzony w Polsce Ustawą z dnia 22 grudnia 2015 r. o Zintegrowanym Systemie Kwalifikacji. Zgodnie z ustawą (art. 2.25):

ZSK to wyodrębniona część Krajowego Systemu Kwalifikacji, w której obowiązują określone w ustawie standardy opisywania kwalifikacji oraz przypisywania poziomu Polskiej Ramy Kwalifikacji do kwalifikacji, zasady włączania kwalifikacji do Zintegrowanego Systemu Kwalifikacji i ich ewidencjonowania w Zintegrowanym Rejestrze Kwalifikacji, a także zasady i standardy certyfikowania kwalifikacji oraz zapewniania jakości nadawania kwalifikacji.

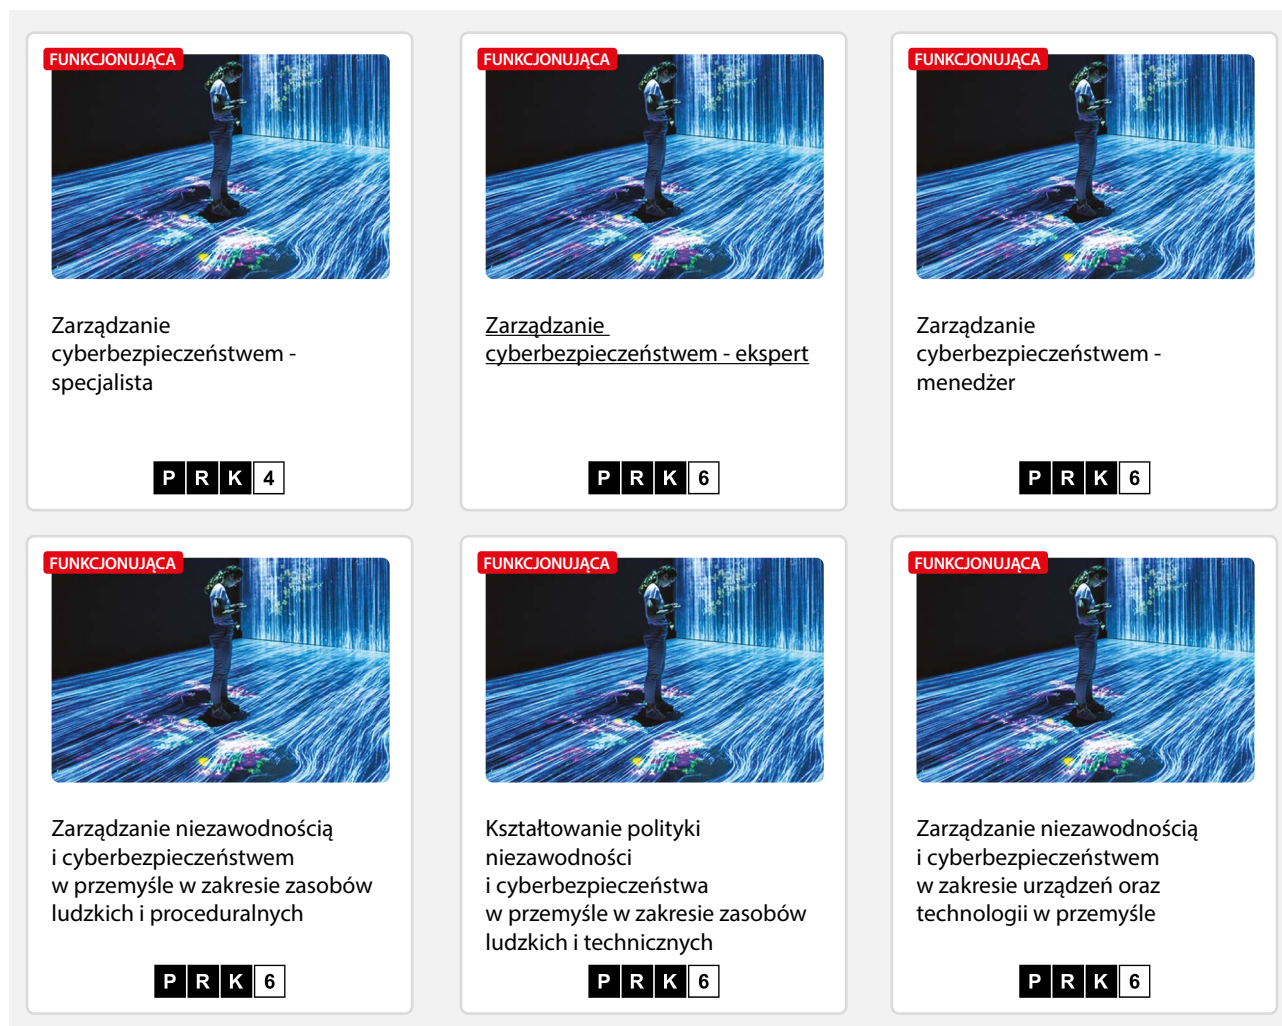
Powyższa ustawa wprowadziła też Polską Ramę Kwalifikacji, na której oparte jest kształcenie formalne. Wszelkie szczegółowe informacje w tym zakresie są dostępne zarówno w ww. ustawie, jak również na portalu prowadzonym przez Instytut Badań Edukacyjnych, dedykowanym kwalifikacjom oraz ZSK: kwalifikacje.edu.pl.

Zgodnie z intencjami, ZSK powinien wspierać pracodawców w *łatwiejszym rozpoznaniu wartości potencjalnego pracownika, a pracownikom prezentować swoje kompetencje w wiarygodny sposób* (IBE, 2021). ZSK porządkuje kwalifikacje dzięki stworzeniu jednego rejestru, gdzie są one umieszczane i prezentowane.

Warto zauważyć, że idea „wspólnych” rejestrów jest bliska zarówno przedstawionej w podrozdziale (*Charakterystyka kompetencji cyfrowych ze szczególnym wskazaniem kompetencji w zakresie cyberbezpieczeństwa*) bazie danych o formalnych programach studiów w zakresie cyberbezpieczeństwa w krajach Europejskiego Obszaru Gospodarczego oraz Szwajcarii zaproponowanej przez ENISA, jak też idei mikrokwalfikacji, które mają być również katalogowane w centralnym rejestrze. Tym samym warto się zastanowić, czy te wszystkie działania nie powinny być synergiczne. A więc czy ZSK, mikrokwalfikacje oraz baza np. ENISA nie powinny być jednym bytem albo być oparte na tych samych mechanizmach?

Obecnie (marzec 2022) w Zintegrowanym Rejestrze Kwalifikacji (ZRK), który jest elementem ZSK, można znaleźć 6 kwalifikacji związanych z cyberbezpieczeństwem. Przedstawia je poniższy zrzut z ekranu.

Fot. 2. Kwalifikacje związane z cyberbezpieczeństwem znajdujące w się w ZRK



Źródło: Zintegrowany Rejestr Kwalifikacji (ZRK), <https://kwalifikacje.gov.pl/k#undefined> (dostęp: 2022.03.30).

Liczba kwalifikacji w rejestrze dynamicznie rośnie. Każda kwalifikacja znajdująca się w rejestrze posiada elementy, które powinna w przyszłości zawierać europejska baza mikrokwalifikacji np. poziom europejskiej ramy kwalifikacji (tutaj mamy poziom Polskiej Ramy Kwalifikacji, która jest związana z europejską), czy efekty uczenia się. Tym samym wydaje się, że powinno być możliwe powiązanie kwalifikacji znajdujących się w ZRK z odpowiednimi mikrokwalifikacjami, np. aby osiągnąć „zarządzanie niezawodnością i cyberbezpieczeństwem w przemyśle w zakresie zasobów ludzkich i proceduralnych” konieczne jest osiągnięcie mikrokwalifikacji poprzez skończenie odpowiednich studiów podyplomowych czy kursów oferowanych przez znajdujące się w rejestrze firmy (dostawców).

Podsumowanie

Celem rozdziału było przedstawienie mikrokwalifikacji jako rozwiązania rozpoznawanego w edukacji formalnej dla skuteczniejszego kształcenia osób w zakresie kompetencji cyfrowych, a w szczególności kompetencji w zakresie cyberbezpieczeństwa.

Zdaniem autorów, mikrokwalifikacje są rozwiązaniem, które może zredukować luki na rynku związane z brakiem pracowników posiadających kwalifikacje w zakresie kompetencji cyfrowych, w tym cyberbezpieczeństwa. Mikrokwalifikacje wprowadzone do programów studiów, w szczególności do programów formalnych – na studiach licencjackich i magisterskich – mogą zwiększać elastyczność studiów. Kwalifikacje w zakresie kompetencji cyfrowych są warunkiem koniecznym do szerszego i bardziej świadomego wykorzystywania sztucznej inteligencji. Tym samym uelastycznienie edukacji realizowane za pomocą mikrokwalifikacji może sprzyjać lepszemu, bardziej dopasowanemu do oczekiwań rynku pracy kształceniu.

Dużym wyzwaniem dla przedstawionych w powyższych podrozdziałach rozwiązań systemowych jest kwestia zapewniania jakości zarówno na poziomie kwalifikacji znajdujących się ZRK, jak również mikrokwalifikacji/mikropoświadczeń (patrz np.: Szostakowska i Szczurek 2020). Ilość danych, które mają obejmować te rejestry oraz ich różnorodność praktycznie wykluczają zastosowanie jakichkolwiek bardzo scentralizowanych mechanizmów. Obecnie w Europie trwa dyskusja, w jaki sposób doprowadzić do tego, aby te dane były wiarygodne. Jak wynika z doświadczeń opartych na zapewnianiu jakości w sektorze szkolnictwa wyższego, rozwiązania administracyjne automatycznie nie prowadzą do braku tzw. „drapieżnych” uczelni, których model biznesowy opiera się na drukowaniu dyplomów (Brdulak, 2021). Stąd być może będą poszukiwane rozwiązania oparte na oddolnym generowaniu treści, trochę w logice rozwiązań crowdfundingowych, czy też modeli zarządzania treścią typu Wiki.

Jednocześnie niedobór pracowników posiadających kompetencje w zakresie cyberbezpieczeństwa generuje pytanie, w jaki sposób kształtować te kompetencje. Na ile rozwiązania systemowe pomagają w tym procesie, a na ile są one działaniami biurokratycznymi, które nie generują wartości dla otoczenia? Odpowiedź na to pytanie wymaga pogłębionych badań.

Niewątpliwie obecnie dużym strumieniem płyną europejskie fundusze na tworzenie wspólnych rejestrów kwalifikacji. Zapewne w niedługim czasie zostaną uruchomione środki na wdrażanie mikrokwalifikacji w krajach europejskich – w pierwszej kolejności należących do Unii Europejskiej, a być może szerzej, do Europejskiego Obszaru Szkolnictwa Wyższego. Istotne, zdaniem autorów, jest to, aby podmioty (stowarzyszenia zawodowe, izby gospodarcze i firmy), które reprezentują np. obszar cyberbezpieczeństwa, rozpoznawały te inicjatywy, tak aby w maksymalnym stopniu ich rezultaty faktycznie przekładały się na rozwiązywanie problemów gospodarczych. Na ten moment problemem gospodarczym całej Europy, nie tylko Polski, jest brak pracowników posiadających kwalifikacje z zakresu cyberbezpieczeństwa. Być może mikrokwalifikacje mogą być pewnym rozwiązaniem, ale tylko pod warunkiem, że cały proces związany z ZSK i mikrokwalifikacjami będzie realizowany w ścisłym dialogu z jego interesariuszami, więc w szczególności z pracodawcami oraz instytucjami uczącymi. Rezultatem tych wszystkich procesów i inicjatyw systemowych takich jak mikrokwalifikacje czy ZSK, ma być pracownik posiadający potrzebne dla danego rynku kompetencje. Występujące niedobory świadczą o tym, że skuteczność tych procesów nie jest na razie na odpowiednim poziomie.

Bibliografia

A European Approach To Micro-Credentials Output of the Micro-Credentials Higher Education Consultation Group, Komisja Europejska, grudzień 2020, <https://education.ec.europa.eu/sites/default/files/document-library-docs/european-approach-micro-credentials-higher-education-consultation-group-output-final-report.pdf>

Brdulak, J., (2021). *Jakość w szkolnictwie wyższym. Zapewnianie czy iluzja?* Warszawa: Oficyna Wydawnicza SGH (w druku).

De Zan, T. and Di Franco, F. (2019). *Cybersecurity Skills Development in the EU. The certification of cybersecurity degrees and ENISA's Higher Education Database*. ENISA.

Fortinet (2020). *Aż 68% firm ma problemy z zatrudnianiem ekspertów ds. cyberbezpieczeństwa*. Pobrano z <https://alebank.pl/az-68-firm-ma-problemy-z-zatrudnianiem-ekspertow-ds-cyberbezpieczenstwa/?id=347307&catid=28090>

Gajewski, M. i Zbudniewek, M. (2021). *Cybersecurity. Raport o rynku pracy w Polsce*, HRK, HackerU.

Instytut Badań Edukacyjnych (bdw.) *Czym jest ZSK?* Pobrano 27.08.2021 z <https://kwalifikacje.edu.pl/czym-jest-zsk/>

Stęchły, W. i Nowakowski, M. (2021). *Szanse i zagrożenia związane z nowymi rodzajami poświadczania umiejętności. Microcredentials, open badges, ECVET oraz osiągnięcia w ZSK*. Materiał opracowany dla FRSE, Warszawa.

Stowarzyszenie Europejskich Izb Przemysłowo-Handlowych (2021). *EUROCHAMBRES input for public consultations on the micro-credentials framework and the initiative for individual learning accounts*. Pobrano z <https://www.eurochambres.eu/wp-content/uploads/2021/07/210719-Position-paper-on-micro-credentials-and-ILAs.pdf>

Szostakowska, M. i Szczurek, A. (2020). *Ewaluacja procesu wsparcia Podmiotów Zewnętrznych Zapewniania Jakości w systemie ZSK*. Warszawa: Ośrodek Ewaluacji Sp. z o.o.

Ustawa z dnia 22 grudnia 2015 r. o Zintegrowanym Systemie Kwalifikacji (Dz. U. 2016 poz. 64).

Zalecenie Rady z dnia 22 maja 2018 r. w sprawie kompetencji kluczowych w procesie uczenia się przez całe życie (2018/C 189/01).

Zintegrowany Rejestr Kwalifikacji, <https://kwalifikacje.gov.pl/>

Rewolucja sztucznej inteligencji (AI) w ochronie zdrowia

Ilek. Ligia Kornowska*

Wprowadzenie

Termin „sztuczna inteligencja (AI) w ochronie zdrowia” u przeciętnego pacjenta wywoła następującą wizję: robot, zamiast człowieka, rozmawia, diagnozuje i leczy pacjenta. Ma kompetencje do przeprowadzenia wywiadu, badania przedmiotowego i podmiotowego. Jeśli mamy do czynienia z komputerem, a nie robotem, to po dodaniu w systemie informacji o stanie zdrowia pacjenta AI jest w stanie zaproponować holistyczne⁵¹ podejście do pacjenta i całościowy proces diagnostyczno-terapeutyczny. Potocznie uważa się również, że wykorzystaniu sztucznej inteligencji wiele czynności i procesów wcześniej wykonywanych przez lekarza, w tym także związanych z udzielaniem informacji zwrotnej pacjentowi na temat stanu jego zdrowia, będzie wykonywanych przez AI. Są to jednak błędne przekonania.

Osobom, które mają podstawowe kompetencje cyfrowe i określony poziom wiedzy na temat cyfryzacji ochrony zdrowia, ale nie są specjalistami od innowacji, hasło „AI w zdrowiu” przywołuje na myśl przede wszystkim zaawansowane algorytmy, które są powszechnie wykorzystywane w medycynie. Każdy lekarz, pielęgniarka i ratownik medyczny wiedzą, że – szczególnie w ostrych sytuacjach zdrowotnych, jak np. nagłe zatrzymanie krążenia – powinno się stosować nie tylko najnowsze standardy medyczne, ale właśnie algorytmy postępowania. Osoby te zapytane na konferencjach branżowych o sztuczną inteligencję w polskich szpitalach odpowiadają, że „przecież jest ona stosowana od lat”. Również powyższe założenia nie są zgodne z prawdą. Wiedza o sztucznej inteligencji w systemie opieki zdrowotnej stoi na przeciętnym – jeżeli nie minimalnym – poziomie.

Chcąc opisać, czym jest AI w systemie opieki zdrowotnej, najpierw musimy wiedzieć, czym jest AI. Spośród kilku definicji zaproponowanych przez KE, jedna z nich brzmi: „Termin sztuczna inteligencja odnosi się do systemów, które wykazują inteligentne zachowanie dzięki analizie otoczenia i podejmowaniu działań – do pewnego stopnia autonomicznie – dla osiągnięcia konkretnych celów” (Komisja Europejska, 2018, s. 1). Definicja ta jest wg autorki jedną z najbardziej elastycznych definicji, choć zawiera w sobie błąd *ignotum per ignotum*, ponieważ definiujemy *inteligencję* jako wykazującą *inteligentne* zachowania.

⁵¹ Mówiąc o holistycznym podejściu do pacjenta, należy traktować je jako podejście „całościowe”, obejmujące spojrzenie nie tylko pod kątem głównego objawu czy dolegliwości, ale z uwzględnieniem także czynników zewnętrznych, takich jak styl i warunki życia, oraz czynników wewnętrznych uwzględniających emocje, myśli i przeżycia. Podejście holistyczne sprawdza się chociażby w przypadku osób przewlekle chorych, bowiem leczone wówczas są nie tylko objawy, ale również ich głębsza przyczyna. A zatem w holistycznym podejściu do pacjenta ważne są wszystkie aspekty związane z pojawieniem się choroby.

* Polska Federacja Szpitali

Słownik języka polskiego PWN termin *sztuczna inteligencja* definiuje za to jako „dział informatyki badający reguły rządzące zachowaniami umysłowymi człowieka i tworzący programy lub systemy komputerowe symulujące ludzkie myślenie” (Słownik języka polskiego, bdw.). Definicja ta jest najbardziej zbliżona do sposobu rozumienia AI prezentowanego przez jednego z pierwszych twórców sztucznej inteligencji, Alana Turinga (Homer, Selman, 2001). Jednakże pojmowanie sztucznej inteligencji jako „udawanie człowieka” było wielokrotnie kwestionowane, m.in. przez Johna Seare’a w znanym eksperymencie myślowym zwanym „chińskim pokojem” (Searle, 1980) i obecnie odchodzi się od takiego definiowania.

Dodatkowo należy wspomnieć o rosnącej popularności rozwijania skrótu *AI* jako *augmented intelligence* (rozszerzonej inteligencji), zamiast *artificial intelligence* (sztucznej inteligencji). Pojęcie rozszerzonej inteligencji pomaga nam zrozumieć, że rzeczywista AI nie jest przeciwstawna „naturalnej” inteligencji, a jedynie pomaga ją wzbogacić o sposób procesowania („myślenia”), który nie jest dla ludzi naturalny.

To wszystko pokazuje, jak trudno jest znaleźć odpowiednią definicję dla AI. W dodatku ze względu na nieustanny rozwój sztucznej inteligencji, nadanie jej sztywnej definicji grozi szybką dezaktualizacją.

Na potrzeby dyskusji o AI w zdrowiu, autorka sugeruje przyjąć, że AI to skomplikowane algorytmy matematyczne, które mają zdolność ciągłego samodoskonalenia poprzez uczenie się.

Pojęcie „AI w zdrowiu” nie obejmuje jednak jednego, wszechwiedzącego algorytmu AI, który może odpowiedzieć na każde pytanie medyczne, w każdej specjalizacji lekarskiej. Nie istnieje jeden szeroki algorytm AI, który mógłby być stosowany przy wszystkich problemach diagnostyczno-leczniczych. Zamiast tego mamy kilkadziesiąt algorytmów, a każdy z nich jest przystosowany do jednej, konkretnej czynności diagnostycznej lub leczniczej. Dodatkowo, pojedynczy algorytm może nie być w stanie w całości ocenić nawet jednego badania diagnostycznego – znamy na przykład algorytmy do oceny badań MRI (rezonans magnetyczny) lub TK (tomografia komputerowa) głowy, które wykrywają jedynie kilka stanów chorobowych. To oznacza, że kontrola lekarza nadal pozostaje niezbędna.

Certyfikacja algorytmów AI

Poprzednie akapity dają oczywistą odpowiedź na bardzo często zadawane pytanie: „Czy sztuczna inteligencja zastąpi lekarzy?”. AI, tak jak każde z innych osiągnięć medycyny, nie zastąpi lekarzy, może jednak znacząco wpłynąć na podniesienie skuteczności, jakości i bezpieczeństwa leczenia pacjenta. Stoimy u progu rewolucji AI – nie tylko w medycynie, ale w każdym sektorze gospodarki.

W roku 2020 na świecie działało ponad 450 certyfikowanych, medycznych algorytmów AI, przy czym od 2015 roku obserwuje się stały, wykładniczy wzrost rozwiązań dostępnych na rynku (Muehlematter, 2021).

Klasyfikując algorytmy AI poprzez specjalizacje lekarskie, należy przyjąć, że niekwestionowanym liderem jest radiologia. Rozpoznawanie odcieni szarości na zdjęciach diagnostycznych oraz określanie, które zmiany są patologiczne, a które fizjologiczne, okazało się najlepszym obecnie obszarem do wykorzystania potencjału sztucznej inteligencji. Oprócz radiologii, algorytmy AI są stosowane szeroko w kardiologii, neurologii, ale również w genetyce molekularnej, anestezjologii czy stomatologii (Muehlematter, 2021).

Wszystkie wyroby medyczne stosowane u pacjentów, od rękawiczek i pieluch, przez defibrylatory i urządzenia wszczepialne, po algorytmy sztucznej inteligencji muszą uzyskać certyfikację, aby mogły być dopuszczone do obrotu w ochronie zdrowia. Europejski system certyfikacji opiera się na Certyfikacie Zgodności CE, w Stanach Zjednoczonych mamy system akceptacji wyrobów medycznych przez FDA (Food and Drug Administration). Każdy wyrób medyczny musi przejść proces certyfikacyjny, którego poziom skomplikowania jest zależny od wielu różnych czynników. Takie elementy jak inwazyjność wyrobu medycznego, jego wpływ na życie lub zdrowie pacjenta czy ryzyko związane z jego użytkowaniem mają wpływ m.in. na klasę wyrobu medycznego i wymogi, które wyrób medyczny musi spełnić.

Sztuczna inteligencja, aby uzyskać certyfikację potrzebną do wdrożenia na rynek medyczny, musi wykazywać skuteczność równą bądź wyższą niż dotychczas stosowane technologie, rozumiane również jako skuteczność oceny dedykowanego personelu medycznego. W wielu przypadkach dowiedziono, że algorytmy AI są skuteczniejsze w ocenie badań niż lekarze. Przykładowo, jeden z algorytmów do oceny badań mammograficznych, rozwijany przez jedną z największych firm technologicznych, wykazał redukcję o 5,7% i 1,2% (USA i Wielka Brytania) w przypadku wyników fałszywie pozytywnych oraz 9,4% i 2,7% w przypadku wyników fałszywie negatywnych. W badaniu system AI przewyższał wszystkich sześciu radiologów biorących udział w badaniu. W niektórych przypadkach badanie mammograficzne musi zostać ocenione przez dwóch niezależnych radiologów. Zostało dowiedzione, że korzystanie z powyższego algorytmu redukuje obciążenie pracą drugiego radiologa o 88% bez zmniejszenia trafności diagnozy (McKinney i in., 2020).

AI nie tylko diagnozuje, ale także leczy w sposób, który jest nieosiągalny dla człowieka. W lipcu 2021 roku opublikowano badanie, które polegało na wszczepieniu podtwardówkowego implantu osobie z anartią (zaburzenie mowy polegające na niemożności tworzenia artykułowanych dźwięków) i dekodowaniu myśli badanej osoby za pomocą sztucznej inteligencji. Użyto do tego modeli obliczeniowych stworzonych na podstawie algorytmów uczenia głębokiego i przetwarzania języka naturalnego (*NLP, natural language processing*). Udało się odkodować aktywność korową uczestnika badania w czasie rzeczywistym z szybkością 15 słów na minutę i trafnością ok. 75% (Moses i in., 2021).

W innym badaniu dowiedziono, że algorytm AI potrafi diagnozować na podstawie nieinwazyjnego badania, jakim jest badanie elektrokardiograficzne (EKG, służące do oceny aktywności serca) stan zwany anemią (niedokrwistość). Do dzisiaj nie było możliwe zdiagnozowanie tej systemowej jednostki chorobowej na podstawie badania EKG – do wystawienia takiej diagnozy lekarze potrzebują wyników badania krwi (Kwon i in., 2020).

Algorytmy sztucznej inteligencji nie tylko wspierają decyzje diagnostyczno-lecznicze podejmowane ostatecznie przez profesjonalistę medycznego. Na świecie są już zarejestrowane algorytmy, które samodzielnie, bez pieczętki lekarza, wystawiają diagnozę. Takim przykładem jest algorytm do oceny retinopatii cukrzycowej na podstawie badania dna oka (retinopatia cukrzycowa jest schorzeniem, które często występuje u osób chorych na cukrzycę i może prowadzić do ślepoty). Algorytm ten został zarejestrowany w Stanach Zjednoczonych już w 2018 roku. Działa na rynku do dzisiaj, a w ciągu trzech lat powstało w wiele innych, podobnych algorytmów do badania dna oka.

Aktualny stan wykorzystania AI w polskim systemie opieki zdrowotnej

W trakcie największej polskiej konferencji „AI w zdrowiu” w czerwcu 2021 roku przeprowadzono ankietę, w której 93% respondentów stwierdziło, że algorytmy AI powinny być szeroko stosowane w polskiej ochronie zdrowia (Konferencja „AI w zdrowiu”, 2021). Uznani profesorowie medycyny zaczynają powtarzać frazę, że wkrótce „nieskorzystanie z technologii takich jak AI będzie błędem medycznym” (Kawecki, 2021). AI rewolucjonizuje polską medycynę – i robi to już teraz.

Raport „Top Disruptors in Healthcare 2021”, jedyny raport inwentaryzujący polski sektor *medtech*, sklasyfikował ok. 380 innowacyjnych start-upów medycznych, z czego 115 zostało opisanych w raporcie. Prawie 50% z nich dotyczy sztucznej inteligencji w zdrowiu (Kornowska i in., 2021), co obrazuje popularność AI wśród tworzonych w Polsce innowacji w sektorze ochrony zdrowia. Wg raportu aż 62% twórców start-upów medycznych deklaruje ich finansowanie przez środki własne założycieli. Była to najczęściej wybierana odpowiedź w pytaniu o źródła finansowania. Jeśli weźmiemy pod uwagę globalne wydatki na rzecz sztucznej inteligencji, okaże się, że nie tylko w Polsce brakuje inwestycji w rozwiązania oparte na sztucznej inteligencji – Europa pozostaje niestety daleko w tyle za Azją i Stanami Zjednoczonymi. W 2016 roku Europa przeznaczyła 3,2 miliarda euro na rozwój sztucznej inteligencji (w późniejszych latach kwota ta wzrosła o 1,5 miliarda euro), Azja wydała na ten cel 6,5 miliarda euro, a Stany Zjednoczone – 12 miliardów euro (Zubaścu, 2020).

Jednocześnie autorka zauważa rosnące zainteresowanie AI ze strony sektora prywatnego i publicznego w polskim ekosystemie zdrowotnym. Narodowe Centrum Badań i Rozwoju (NCBiR) stworzyło specjalny program mający na celu dofinansowanie projektów m.in. opartych na sztucznej inteligencji w zdrowiu (Narodowe Centrum Badań i Rozwoju, 2021a). Na początku pandemii COVID-19, NCBiR, w rundzie finansowania przeznaczony dla szpitali jednoimiennych rozwijających innowacyjne rozwiązania w zakresie walki z COVID-19, dofinansował co najmniej kilka projektów zakładających wykorzystanie sztucznej inteligencji (Narodowe Centrum Badań i Rozwoju, 2021b).

Ministerstwo Zdrowia współpracowało z polskim start-upem Infermedica oferującym rozwiązania AI w zdrowiu przy stworzeniu ankiety dla pacjenta, oceniającej ryzyko zakażenia koronawirusem (Narodowe Centrum Badań i Rozwoju (2021b). Natomiast Ministerstwo Cyfryzacji i Narodowy Fundusz Zdrowia (NFZ) razem ze start-upem Yosh.AI rozwinęło algorytmy AI w postaci chatbota „koronawirus info”,

który odpowiadał na najczęściej zadawane pytania związane z COVID-19 podczas oczekiwania na połączenie z konsultantem NFZ (Szafrńska, 2020).

Na początku 2021 roku Rada Ministrów przyjęła dokument „Polityka dla rozwoju sztucznej inteligencji w Polsce od roku 2020” zwany w skrócie Polityką AI, która ustala strategiczne cele dla rozwoju sztucznej inteligencji. Jednym z zaleceń Polityki AI było stworzenie roboczych grup sektorowych przy Kancelarii Prezesa Rady Ministrów. Grupa działająca na rzecz ochrony zdrowia powstała już w drugim kwartale 2021 roku i działa pod nazwą GRAI ds. zdrowia – Grupa Robocza ds. Sztucznej Inteligencji, sekcja ds. zdrowia (Serwis Rzeczypospolitej Polskiej, bdw.). Również w Strategii e-Zdrowia na lata 2021–2026, będącej dokumentem strategicznym określającym kierunki cyfryzacji polskiej ochrony zdrowia tworzonej przez Centrum e-Zdrowia w 2020 roku, jeden z pięciu głównych rozdziałów dotyczy sztucznej inteligencji i big data. Strategia ta oczekuje na oficjalne przyjęcie przez Ministerstwo Zdrowia.

Jednocześnie sektor prywatny zauważa rewolucję, jaka zachodzi w medycynie dzięki sztucznej inteligencji i podejmuje działania na rzecz samoregulacji. Trzy lata temu powstała „Koalicja AI w zdrowiu” – pierwsza w Polsce organizacja, która zrzesza najważniejszych interesariuszy ochrony zdrowia zainteresowanych rozwojem AI w medycynie. Koalicja liczy obecnie ponad 30 członków, skupiając najważniejsze firmy technologiczne i farmaceutyczne, uniwersytety, organizacje pacjenckie i start-upy, które poprzez szereg projektów działają na rzecz skutecznego i bezpiecznego wdrażania AI w zdrowiu w Polsce⁵².

Znaczenie kształcenia personelu medycznego w zakresie AI

Wszystkie wymienione wyżej informacje wskazują bardzo wyraźnie, że rewolucja AI w zdrowiu dzieje się właśnie teraz. Ze względu na ogromną wagę tej rewolucji, absolutnie kluczowe jest, żeby personel medyczny był wyedukowany i świadomy tego, czym jest sztuczna inteligencja – jakie korzyści, ale także jakie zagrożenia może nieść jej wykorzystanie w procesie diagnostyczno-leczniczym. Każdy rok zwłoki w zakresie rozwijania kompetencji cyfrowych i wiedzy o nowych technologiach w medycynie wśród specjalistów medycznych niesie zagrożenie w postaci niedostatecznego wykorzystania AI w przypadkach, w których algorytmy znacząco poprawiają skuteczność diagnozy i leczenia, ale także wykorzystania niesprawdzonych algorytmów AI w sposób niekontrolowany lub niezgodny z przeznaczeniem.

Certyfikowane algorytmy AI powinny gwarantować określoną czułość i swoistość. Jednakże z wielu powodów proces certyfikacji AI jako wyrobu medycznego może być niedostosowany do nowych technologii. Warto zaznaczyć, że np. ze wspomnianych wcześniej algorytmów AI służących do oceny występowania retinopatii cukrzycowej na podstawie badania dna oka, tylko nieliczne prezentują skuteczność oceny równą i wyższą ocenom personelu medycznego (Lee i in., 2020). To jednoznacznie wskazuje, że powinniśmy ze szczególną ostrożnością podchodzić do nowych technologii wdrażanych w sektorze ochrony zdrowia. Kluczowe jest

⁵² Więcej informacji: <https://aiwzdroziu.pl/>

przygotowanie specjalistów medycznych do krytycznej ewaluacji algorytmów sztucznej inteligencji.

Każdy algorytm AI, nawet jeśli ostateczną decyzję podejmuje lekarz, musi mieć udowodnioną wartość kliniczną. Jest to szczególnie istotne w świetle ostatniego badania, w którym radiolodzy przy ocenie badania obrazowego otrzymywali sugestie diagnozy. Część z radiologów była poinformowana, że sugestia pochodzi od innego radiologa, część – że to diagnoza postawiona przez AI, choć w rzeczywistości wszystkie diagnozy pochodziły od lekarzy. Z badania wynikają dwa istotne wnioski: po pierwsze, bardziej doświadczeni radiolodzy gorzej oceniali trafność sugestii diagnozy, jeśli otrzymali informację, że pochodzi ona od AI. Mniej doświadczeni lekarze nie byli uprzedzeni do AI. Po drugie, sugestie diagnozy miały bardzo duży wpływ na ostateczną diagnozę, nawet jeśli sugestia była błędna, a wpływ ten był znaczący również u lekarzy, którzy nisko oceniali trafność sugestii. Badanie było oparte tylko na 8 przypadkach, za to do ich oceny zaangażowano prawie 300 lekarzy. To pokazuje, że nawet jeśli algorytm AI nie podejmuje samodzielnie ostatecznej decyzji diagnostyczno-leczniczej, ma znaczący wpływ na decyzję podejmowaną przez lekarza.

Korzystanie z algorytmów AI do wspomaganie decyzji medycznych jest zupełnie nowym rodzajem „konsultacji”. Zazwyczaj, gdy lekarz ma wątpliwość przy ocenie konkretnego badania, najpierw próbuje je ocenić samodzielnie, później je konsultuje z innymi specjalistami medycznymi. Ma też możliwość omówienia rad pochodzących od innych specjalistów. Przy AI, lekarz otrzyma sugestie najpewniej przed samodzielną analizą przypadku i nie będzie miał pełnej informacji, dlaczego algorytm AI ocenił dane badanie w taki właśnie sposób. Wdrażając sztuczną inteligencję w ochronie zdrowia, musimy być pewni, że personel medyczny jest świadomy wpływu, jaki płynie z sugestii diagnozy przedstawionej przez algorytm AI, a także że umie krytycznie podchodzić do prezentowanych wyników.

Rola kompetencji cyfrowych w aktualnej edukacji medycznej

W świecie, w którym postęp cyfrowy zachodzi z miesiąca na miesiąc, a nowe technologie informatyczne nieustannie zmieniają kolejne gałęzie medycyny, student uniwersytetu medycznego powinien być uczony, jak odnaleźć się w medycynie 2.0. W rzeczywistości system edukacji nie nadąża za potrzebami cyfrowymi młodych adeptów sztuki medycznej. Według raportu „Future Health Index 2020” (Future Health Index, 2020) stworzonego na podstawie odpowiedzi niemal 3000 przedstawicieli personelu medycznego poniżej 40. roku życia, aż jedna trzecia respondentów nie potrafi wykorzystywać cyfrowych danych medycznych do podejmowania decyzji dotyczących opieki nad pacjentem, a 31% ankietowanych czuje się przytłoczonych ilością cyfrowych danych medycznych. Jednocześnie 72% respondentów uważa, że wdrażanie nowych technologii jest istotne dla ich pracy, a 88% przy wyborze miejsca pracy kieruje się dostępem do najnowocześniejszego sprzętu i technologii stosowanych w podmiocie leczniczym. Prawie 60% z nich wskazuje na przydatność szkoleń z zakresu wykorzystania nowych technologii. Z pewnością jest to odpowiedź na niedostateczną edukację w zakresie kompetencji cyfrowych podczas studiów medycznych.

W programach nauczania na kierunkach lekarskich trudno znaleźć zajęcia z zakresu wykorzystania nowych technologii w ochronie zdrowia (Uniwersytet Medyczny w Poznaniu, 2020; Uniwersytet Mikołaja Kopernika w Toruniu, b.d.). W ramowym programie zajęć praktycznych dla kierunku lekarskiego i lekarsko-dentystycznego z dnia 28 sierpnia 2017 również nie znajdziemy takich zajęć (Ministerstwo Zdrowia, 2017). W praktyce studenci kierunku lekarskiego, przyszli lekarze, są rzadko edukowani w tak podstawowych kwestiach jak korzystanie z informatycznych systemów szpitalnych czy innych rozwiązań z zakresu e-zdrowia, nie mówiąc już o tak zaawansowanych technologiach jak wykorzystanie sztucznej inteligencji dla celów diagnostyczno-leczniczych, czy np. korzystanie z okularów wirtualnej i rozszerzonej rzeczywistości podczas procesu terapeutycznego.

Rzeczywistość wygląda następująco: młodzi adepci sztuki lekarskiej, po ukończeniu formalnej edukacji, nie są odpowiednio przygotowani w zakresie kompetencji cyfrowych. Osoby zainteresowane innowacjami doksztalają się samodzielnie, a w przypadku podstawowych umiejętności potrzebnych do praktykowania zawodu – jak prowadzenie elektronicznej dokumentacji medycznej czy wystawianie e-recept lub e-skierowań – uczą się na bieżąco w pracy. To może sprawiać, że pierwszy kontakt z technologiami takimi jak sztuczna inteligencja budzi wśród personelu nieufność, opór i niechęć do wprowadzania zmian. Z drugiej strony może powodować również entuzjazm i chęć bezkrytycznego wdrażania nowych rozwiązań bez ich odpowiedniej walidacji. Oba scenariusze są wysoce niekorzystne – jeden blokuje rozwój medycyny, drugi naraża życie i zdrowie pacjenta.

Lukę w edukacji zauważają również izby zawodowe. Między innymi już trzy lata temu Okręgowa Izba Lekarska w Warszawie na szkoleniu dla młodych absolwentów kierunku lekarskiego zaplanowała kilka godzin warsztatów w zakresie wykorzystania sztucznej inteligencji w zdrowiu. Lekarze byli uczeni przez informatyków prezentujących rozwiązanie IBM Watson, jak wykorzystać AI w praktyce klinicznej, ale także na co uważać. To tylko jeden przykład spośród wielu edukacyjnych aktywności izb zawodowych – jednak nie są one w stanie wypełnić całkowicie luki w edukacji przeddyplomowej.

Proponowane kierunki zmian dla polskiej służby zdrowia w obszarze AI

Każda zmiana, szczególnie w ochronie zdrowia, musi być przeprowadzana z odpowiednią dozą ostrożności i bezpieczeństwa. Wszyscy interesariusze, na których dana zmiana ma wpływ, powinni być odpowiednio wyedukowani i rozumieć zarówno szanse, jak i zagrożenia płynące z konkretnych przemian. Tak też powinno być w zdrowiu – personel medyczny, kadra menedżerska oraz pacjenci – wszyscy powinni posiadać odpowiedni poziom kompetencji cyfrowych dla zwiększenia bezpieczeństwa rewolucji, która ma miejsce w dzisiejszej medycynie.

Zarówno strona publiczna, jak i prywatna wykazują zainteresowanie tematyką sztucznej inteligencji w ochronie zdrowia. Ministerstwo Zdrowia, Ministerstwo Cyfryzacji oraz Narodowy Fundusz Zdrowia współpracują ze start-upami działającymi w dziedzinie AI, natomiast Narodowe Centrum Badań i Rozwoju rozwinęło projekt dofinansowujący projekty oparte na sztucznej inteligencji. O tym, jak istotne dla strony publicznej jest inwestowanie w przyszłość, jaką jest sztuczna

inteligencja, świadczą także działania Rady Ministrów, która na początku 2021 r. przyjęła dokument „Polityka dla rozwoju sztucznej inteligencji w Polsce od roku 2020”, ustalający strategiczne cele dla rozwoju tej dziedziny. Innym dokumentem dotyczącym AI i big data jest Strategia e-Zdrowia, oczekująca na oficjalne przyjęcie przez Ministerstwo Zdrowia. W sektorze prywatnym jedną z głównych organizacji zajmujących się sztuczną inteligencją oraz zrzeszającą najważniejszych interesariuszy ochrony zdrowia zainteresowanych jej rozwojem w medycynie jest Koalicja AI w zdrowiu, która już teraz aktywnie włącza się w kreowanie przyszłości AI w Polsce.

Głównym problemem oscylującym wokół sztucznej inteligencji w sektorze zdrowia jest niewystarczająca wiedza o jej możliwościach i zastosowaniu, bądź błędne przekonania o tym, jak AI wpłynie na ten sektor. Zadaniem sztucznej inteligencji nie jest zastąpienie personelu medycznego i samodzielne podejmowanie decyzji co do leczenia pacjentów, lecz wspomaganie lekarzy w ich codziennej pracy. Udowodnione jest, iż wykorzystywanie sztucznej inteligencji może znacząco przyczynić się do podniesienia skuteczności, jakości i bezpieczeństwa pacjenta, jako że AI diagnozuje i leczy w sposób, który nierzadko nie jest dostępny dla człowieka – bądź też jest dostępny, ale z wykorzystaniem znacznie większych nakładów pracy i czasu. Już teraz algorytmy AI są stosowane szeroko w radiologii, kardiologii, neurologii, genetyce molekularnej, anestezjologii czy stomatologii. Zdolność do ciągłego samodoskonalenia sztucznej inteligencji poprzez uczenie się daje nieograniczoną ilość możliwości, w jakich będzie mogła ona być wykorzystywana. Potencjał ten dostrzegają również polskie start-upy medyczne.

Sztuczna inteligencja stoi przed wieloma wyzwaniami, które niewątpliwie stanowią barierę ograniczającą możliwości jej wykorzystywania w sektorze ochrony zdrowia. Chociaż lekarze dostrzegają zmiany w zakresie wykorzystywania nowych technologii, znaczna część z nich jest wciąż uprzedzona, co potwierdza badanie, w którym doświadczeni radiolodzy gorzej oceniali trafność sugestii diagnozy, jeśli otrzymali informację, że pochodzi ona od AI – mimo że w rzeczywistości diagnoza ta pochodziła od innego radiologa. Tymczasem w świecie, w którym codziennie zachodzi postęp cyfrowy, zrozumienie i wykorzystywanie nowych technologii jest kluczowe dla rozwoju medycyny. Ważnym przełomem byłoby pojawienie się w programie nauczania na studiach medycznych przedmiotów z zakresu wykorzystywania nowych technologii w ochronie zdrowia – chociażby jako fakultety. Aby przygotować się do przyjęcia i stosowania AI w zdrowiu, w praktyce należy nie tylko posiadać obiektywną wiedzę na jej temat, ale także rozumieć, jakie wiążą się z tym zalety i szanse oraz zagrożenia. Sztuczna inteligencja zaczyna funkcjonować w sektorze ochrony zdrowia już teraz, ale to od nas zależy, czy i jak będziemy z niej korzystać.

W Polsce byliśmy świadkami gwałtownych przemian, jakie towarzyszyły nam przy pandemii COVID-19. Z miesiąca na miesiąc docelowo model udzielania świadczeń medycznych zmienił się z wizyt stacjonarnych na wizyty telemedyczne. Podmioty lecznicze często nie miały odpowiedniego sprzętu, który pozwoliłby korzystać ze wszystkich dobrodziejstw telemedycyny, a pod hasłem „telemedycyna” często kryła się po prostu „teleporada”. Personel medyczny z pewnością byłby wdzięczny za jednoznaczne wytyczne, jak odnaleźć się w nowej, cyfrowej medycynie. Pacjenci zaś powinni być poinstruowani, czym w ogóle jest „telemedycyna”.

Kawecki, M. (2021). Informatyk i lekarz wspólnie na sali? Nieskorzystanie z technologii będzie błędem medycznym [Podcast]. *Komputer Świat*.

Pobrano z <https://www.komputerswiat.pl/artykuly/redakcyjne/informatyk-i-lekarz-wspolnie-na-sali-nieskorzystanie-z-technologii-bedzie-bledem/ed6ndq8>

Komisja Europejska (2018). Communication from the commission to the European Parliament, The European Council, The Council, The European Economic And Social Committee and The Committee of The Regions Artificial Intelligence for Europe.

Kornowska, L. (2021). Podsumowanie Konferencji „AI w zdrowiu”. Polska Federacja Szpitali. Pobrano z <http://www.pfsz.org/2021/07/09/podsumowanie-konferencji-ai-w-zdrowiu/>

Kornowska, L. i in. (2021). *Top Disruptors in Healthcare* (Raport). Warszawa: Medexpert Ligia Kornowska.

Kwon, J. M. i in. (2020). A deep learning algorithm to detect anaemia with ECGs: a retrospective, multicentre study. *The Lancet*. Pobrano z [https://www.thelancet.com/journals/landig/article/PIIS2589-7500\(20\)30108-4/fulltext](https://www.thelancet.com/journals/landig/article/PIIS2589-7500(20)30108-4/fulltext)

Lee, A., Y. i in. (2020). Multicenter, Head-to-Head, Real-World Validation Study of Seven Automated Artificial Intelligence Diabetic Retinopathy Screening Systems. *American Diabetes Association*. Pobrano z <https://care.diabetesjournals.org/content/early/2021/01/01/dc20-1877>

McKinney, S. M., Sieniek, M. and Shetty, S. (2020). *International evaluation of an AI system for breast cancer screening*. *Nature*. Pobrano z <https://www.nature.com/articles/s41586-019-1799-6>

Ministerstwo Zdrowia (2017). Rozporządzenie Ministra Zdrowia z dnia 28 sierpnia 2017 r. w sprawie ramowego programu zajęć praktycznych dla kierunku lekarskiego i lekarsko-dentystycznego. Pobrano z <https://sip.lex.pl/akty-prawne/dzu-dziennik-ustaw/ramowy-program-zajec-praktycznych-dla-kierunku-lekarskiego-i-lekarsko-18630453>

Moses, D. A. i in. (2021). Neuroprosthesis for Decoding Speech in a Paralyzed Person with Anarthria. *The New England Journal of Medicine*. Pobrano z <https://www.nejm.org/doi/full/10.1056/NEJMoa2027540>

Muehlematter, U. J. i in. (2021). Approval of artificial intelligence and machine learning-based medical devices in the USA and Europe (2015–20): a comparative analysis. *Health Policy*. Pobrano z <https://www.thelancet.com/pdfs/journals/landig/PIIS2589-7500>

Narodowe Centrum Badań i Rozwoju (2021a). Infostrateg (II Konkurs). Pobrano z <https://www.gov.pl/web/ncbr/infostrateg-ii-konkurs>

Narodowe Centrum Badań i Rozwoju (2021b). *Wyniki oceny pozytywnej naboru wniosków złożonych w ramach przedsięwzięcia Wsparcie Szpitali Jednoimiennych z 2020 r.* Pobrano z <https://archiwum.ncbr.gov.pl/programy/programy-krajowe/>

wsparcieszpitalijednoimiennych/aktualnosci/aktualnosci-szczegoly/news/wyniki-oceny-pozytywnej-naboru-wnioskow-zlozonych-w-ramach-przedsiwzięcia-w-sparcie-szpitali-jednoim/

Searle, J. (1980). *Minds, Brains and Programs*. Cambridge University Press.

Serwis Rzeczypospolitej Polskiej (bdw.). *Grupa Robocza ds. Sztucznej Inteligencji (GRAI)*. Pobrano 26 sierpnia 2021 r. z <https://www.gov.pl/web/cyfryzacja/grupa-robocza-ds-sztucznej-inteligencji-grai>

Słownik języka polskiego (bdw.), termin „sztuczna inteligencja”. Pobrano 26 lipca 2021 r. z <https://sjp.pwn.pl/szukaj/sztuczna-inteligencja.html>

Szafrańska, M. (2020). *Sztuczna inteligencja wspiera walkę z koronawirusem. Polski start-up dostarczył rozwiązanie dla NFZ i rusza w świat. Forbes*. Pobrano z <https://www.forbes.pl/biznes/yoshai-automatyczny-asystent-dla-nfz-sztuczna-inteligencja-w-walce-z-koronawirusem/8pzp1ps>

Uniwersytet Medyczny w Łodzi (bdw.). Rekrutacja (Zbiór danych i program nauczania). Pobrano z <https://rekrutacja.umed.lodz.pl/pliki/Lekarski.pdf>

Uniwersytet Medyczny w Poznaniu (2020). Harmonogram roku akademickiego 2020/2021 (Zbiór danych i program nauczania). Pobrano z <https://wl.ump.edu.pl/informacje-wydzialowe/dla-jednostek-dydaktycznych>

Uniwersytet Mikołaja Kopernika w Toruniu (bdw.). Wykaz umiejętności absolwenta kierunku lekarskiego (Zbiór danych i program nauczania). Pobrano z <https://www.wl.cm.umk.pl/student/lekarski-studia-jednolite-magisterskie/wykaz-umiejetnosci-absolwenta-kierunku-lekarskiego/>

Zubaścu, F. (2020). Commission adds AI research 'lighthouse' to innovation priorities amid budget wrangle. *Science Business*. Pobrano z <https://sciencebusiness.net/news/commission-adds-ai-research-lighthouse-innovation-priorities-amid-budget-wrangle>

Wykorzystanie sztucznej inteligencji w opiece nad osobami starszymi. Nowe kompetencje cyfrowe w geriatricy

lek. Michał Janiszewski*

Wprowadzenie

Doświadczany przez nas w ostatnim dwudziestoleciu nagły rozwój sztucznej inteligencji, której początki datuje się na lata 40. XX w., jest bezpośrednim wynikiem postępu w dziedzinie informatyki i jej dyscyplinach, a także powiązanego z nim dostępu do dużych ilości danych, które można uzyskiwać w czasie rzeczywistym i w szybki sposób przesyłać na dowolne odległości. Ułatwienie dostępu do dużych zbiorów danych następuje praktycznie w każdej dziedzinie nauki, ale ma kluczowe znaczenie w rozwoju medycyny, w której informacje na temat bazowego stanu pacjenta i zmian, które w nim zachodzą, są podstawą do podejmowania decyzji o podjęciu, kontynuacji lub zmiany terapii. Postęp, jaki się na tym polu dokonał, obrazują dane wskazujące na to, że odsetek szpitali w USA dysponujących systemem elektronicznej dokumentacji medycznej wzrósł z niecałych 10% w 2008 r. do ponad 75% w 2015 (Adler-Milstein, 2015). Na potencjał, jaki ma zbieranie i analiza danych medycznych zwrócił uwagę brytyjski NHS (National Health Service), ogłaszając długoterminowy plan na lata 2019–2024, którego celem jest przekazywanie danych medycznych za pomocą systemów elektronicznych przez wszystkich usługodawców w ochronie zdrowia (NHS, 2019). W Polsce od 1 kwietnia 2021 r. istnieje obowiązek prawny, zgodnie z którym dostawcy oprogramowania zobowiązani są do zapewnienia możliwości dokonywania wymiany danych zawartych w elektronicznej dokumentacji medycznej za pośrednictwem Systemu Informacji Medycznej w ramach Systemu P1 (Ustawa z dnia 28 kwietnia 2011 r. o systemie informacji w ochronie zdrowia).

Ważną rolę w dostępności do danych medycznych odgrywa także zwiększający się rynek urządzeń prywatnego zastosowania, które zbierają dane medyczne, umożliwiając ich analizę i wykorzystanie w zdalnej ocenie stanu zdrowia. Dotyczy to zarówno tak powszechnie stosowanych narzędzi jak smartfony, jak również zdobywających coraz większą popularność urządzeń ubieralnych i innych.

W 2018 r. Apple udostępnił platformę PHR (*personal health record space*) – technologiczny standard przesyłania danych medycznych trafiających na urządzenia firmy, dzięki któremu aplikacje tworzone na system iOS mogą w prosty sposób przesyłać dane dotyczące zdrowia do systemów elektronicznych dokumentacji medycznej. Oznacza to, że aplikacje zbierające dane medyczne będą mogły za zgodą użytkownika udostępniać dane zbierane przez narzędzia prywatnego zastosowania bezpośrednio do systemów obsługiwanych przez personel medyczny.

*AIDA Diagnostics

Opisane zmiany dają możliwość tworzenia nowoczesnych technologii opartych na sztucznej inteligencji, które docelowo mogą poprawić efektywność opieki zdrowotnej, być wsparciem w podejmowaniu decyzji przez personel medyczny na podstawie danych, zwiększyć świadomość i zaangażowanie pacjentów w terapię, a także doprowadzić do automatyzacji wielu procesów wykonywanych dzisiaj przez ludzi. Równocześnie systemy ochrony zdrowia państw rozwiniętych stoją u progu wyzwań związanych z pogłębiającym się niedoborem kadr medycznych, wzrostem zapotrzebowania na specjalistyczne usługi w ochronie zdrowia i ich rosnących kosztów, zapewnieniem równego dostępu do leczenia dla osób mieszkających poza obszarami zurbanizowanymi, wymagających długoterminowej i szczególnej opieki czy o niskim statusie materialnym.

Ważnym czynnikiem wpływającym na powyższe wyzwania jest proces zmian demograficznych, który w państwach EU-28 będzie skutkował wzrostem udziału osób powyżej 65. roku życia z 19,7% w 2018 r. do 28,5% w 2050 r., co przekłada się na 48,1 mln więcej mieszkańców będących w tej grupie wiekowej (Eurostat, 2020). Skutkiem tych zmian będzie pojawienie się zwiększonego zapotrzebowania na usługi opieki zdrowotnej dla osób starszych, które wymuszają rozwój technologii umożliwiających ich skuteczną realizację.

Fakty te skłaniają do pogłębionej refleksji na temat możliwości i skutków zastosowania sztucznej inteligencji w nieuniknionej transformacji systemu opieki nad osobami starszymi. Jakie wyzwania zdrowotne stoją za szybko postępującymi zmianami demograficznymi? Czy rozwiązania wykorzystujące sztuczną inteligencję pomogą nam na nie odpowiedzieć? Jeśli tak, to w jakich obszarach będą najbardziej efektywne? Czy oprócz spodziewanych korzyści możemy zidentyfikować ryzyka, jakie niesie za sobą ich upowszechnienie? Jak będzie wyglądał proces adaptacji do zmian technologicznych w życiu osób starszych i jakie działania powinny zostać podjęte, aby umożliwić wykorzystanie ich pełnego potencjału?

Celem rozdziału jest przegląd wykorzystania sztucznej inteligencji w opiece nad osobami starszymi na podstawie dotychczasowych doświadczeń, a także identyfikacja szans i zagrożeń z tym związanych. Opisane zostaną wyzwania, na które musi odpowiedzieć rozwój sztucznej inteligencji i zidentyfikowane obszary technologiczne, w których jej rola jest kluczowa, aby sprostać wymaganiom stawianym przez zmieniający się świat. Następnie przeprowadzony zostanie przegląd obecnie funkcjonujących na rynku technologii z uwzględnieniem przyszłych kierunków rozwoju, a także wskazaniem ryzyk, jakie wiążą się z ich wykorzystaniem. Szczególna uwaga zostanie poświęcona ryzyku braku kompetencji personelu medycznego i pacjentów w wykorzystaniu nowoczesnych technologii z użyciem sztucznej inteligencji, a także proponowane sposoby na ograniczenie go.

Wyzwania w transformacji systemów opieki nad osobami starszymi

Spośród pięćdziesięciu krajów świata z największym udziałem osób 65+ w populacji, aż połowa należy do Unii Europejskiej, a przewidywana liczba osób wymagających opieki długoterminowej w krajach UE-27 będzie rosła z poziomu 19,5 milionów w 2016 r. do 23,6 milionów w 2030 i 30,5 milionów w 2050 (Komisja Europejska, 2021). Należy przy tym zwrócić uwagę, że opieka długoterminowa,

definiowana jako długookresowa profesjonalna pielęgnacja i rehabilitacja oraz kontynuacja leczenia farmakologicznego i postępowania dietetycznego w warunkach domowych, nie wyczerpuje potrzeb związanych z dostępnością do świadczeń zdrowotnych osób starszych. Dostępne opracowania wskazują na istotnie większy udział pacjentów z grupy wiekowej 65+ w usługach opieki doraźnej skorelowanej z wyższym wskaźnikiem hospitalizacji i ryzykiem zdarzeń niepożądanych w stosunku do pacjentów z młodszych grup wiekowych (Aminzadeh, 2002; Fayyaz, 2013; Fuchs, 2019).

W raporcie Ageing Europe, przygotowanym przez Eurostat (2020), dane statystyczne obrazują wyzwania, które będą wiązać się ze starzeniem populacji. Najistotniejsze z nich w kontekście kierunków zastosowania sztucznej inteligencji w opiece nad osobami starszymi to:

Życie w zdrowiu osób starszych

Zwiększenie średniej długości życia oznacza większe narażenie na doświadczenie poważnych chorób i niepełnosprawności. W UE-27 w 2018 r. kobiety w wieku 65 lat żyły w zdrowiu średnio przez 10 lat pozostałego okresu życia, a wartość ta byłaby porównywalna dla mężczyzn, u których wyniosła 9,8 roku. Niestety wśród państw UE widać duże dysproporcje w ramach tego wskaźnika na niekorzyść państw byłego bloku wschodniego (w Polsce 8,8 roku dla kobiet oraz 8,2 roku dla mężczyzn), a starzejące się społeczeństwa będą wymagały szczególnych działań, aby utrzymać go na dotychczasowym poziomie.

Samodzielność osób starszych

Wraz ze starzeniem się zmniejsza się zdolność do samodzielnego funkcjonowania osób starszych. Spośród osób powyżej 75. roku życia aż 23,2% miało trudności z robieniem codziennych zakupów, 14,3% z kąpielą i prysznicem, a 13,8% zgłaszało problemy z przygotowaniem posiłków.

Dostęp do opieki zdrowotnej

Osoby starsze (powyżej 65. r.ż.) w UE-27 napotkają większe trudności w dostępie do usług medycznych niż populacja osób dorosłych (zdefiniowanych jako osoby powyżej 16 r.ż.). W 2018 r. koszt usług medycznych i czas oczekiwania na ich realizację były dwoma głównymi problemami, które prowadziły do niezaspokojenia potrzeb medycznych.

Dane te rodzą szereg pytań o kształt przyszłej opieki zdrowotnej osób starszych i właściwych kierunków rozwoju technologicznego, które pozwolą odpowiedzieć na opisane wyzwania.

Czy możliwe jest, aby zredukować obciążenie ochrony zdrowia przez predykcję osób narażonych na pogorszenie stanu zdrowia i wdrożenie działań profilaktycznych? W jaki sposób uzyskiwać dane na potrzeby takich działań i jak efektywnie komunikować konieczność podjęcia działań przez personel medyczny, opiekunów i pacjentów?

Jakie rozwiązania telemedyczne i jak efektywnie stosować, aby utrzymać kontakt z pacjentami mającymi trudności z dostępnością usług medycznych i zapewnić im spersonalizowane wsparcie w procesie leczenia?

Jak wesprzeć rodziny i profesjonalnych opiekunów w opiece nad osobami wymagającymi stałej pomocy w radzeniu sobie z niepełnosprawnością? Czy cyfrowa opieka w XXI w. może wyeliminować z tego procesu ludzi? Jeśli tak, to jaki będzie jej cel? Kontrola przestrzegania zaleceń lekarskich czy wsparcie mentalne?

Odpowiedzi na te pytania będą częścią procesu tworzenia rozwiązań technologicznych w obszarze opieki osób starszych i będą zapewne wiązać się z pasmem sukcesów i porażek, zarówno na polu naukowym jak i biznesowym, które będziemy obserwować w najbliższych latach. Kierunek tych zmian odzwierciedlają dotychczasowe innowacje wprowadzane do powszechnego użytku, które coraz wyraźniej wpływają na życie osób starszych i pracę pracowników ochrony zdrowia.

Obszary zastosowania AI w opiece nad osobami starszymi

Przygotowany przez Komisję Europejską raport *The Silver Economy* nie pozostawia złudzeń co do wpływu starzejącej się populacji państw członkowskich na ich funkcjonowanie w najbliższej dekadzie. Srebrna Gospodarka jest definiowana jako suma całej działalności gospodarczej, która służy potrzebom osób w wieku 50 lat i starszych. Dotyczy to również produktów i usług, kupowanych przez nich bezpośrednio, a także aktywności gospodarczej generującej te wydatki. Warto zauważyć, że już w 2015 r. rynek Srebrnej Gospodarki wygenerował wydatki na poziomie 4,2 trylionów euro PKB (28,8% PKB UE) i utrzymywał 78 milionów miejsc pracy (35,3% zatrudnienia w UE). Do 2025 r. przewiduje się wzrost konsumpcji Srebrnej Gospodarki o ok. 5 % rocznie, do poziomu 5,7 bln euro; wydatków do 6,4 trylionów euro w PKB (31,5%) i miejsc pracy do 88 milionów (37,7%). W strukturze wydatków osób powyżej 50. r. życia, w porównaniu do osób młodszych, większy udział stanowią usługi opieki zdrowotnej, a także wydatki na rekreację, kulturę i artykuły gospodarstwa domowego (Komisja Europejska, 2018).

Mimo że raport przedstawia szeroką perspektywę wyzwań i szans związanych z obserwowanymi zmianami demograficznymi w kontekście wpływu na gospodarkę, praktycznie każda jego sekcja nawiązuje do sektora ochrony zdrowia jako kluczowej sceny, na której reakcja na zachodzące procesy będzie definiowała sukces lub porażkę polityki państw UE. W podsumowujących zaleceniach dla interesariuszy (w tym KE) autorzy raportu wskazują na:

1. Wspieranie rewolucji technologicznej i cyfrowej w sektorze ochrony zdrowia
2. Wspieranie zdrowego starzenia się na obszarze Unii Europejskiej
3. Wspieranie rozwoju rozwiązań poprawiających mobilność osób starszych
4. Wspieranie aktywnego udziału osób starszych na rynku pracy

5. Wspieranie innowacyjnych produktów i usług ukierunkowanych na zwiększenie samodzielności osób starszych.

Sztuczna inteligencja może odegrać znaczącą rolę w rozwoju rozwiązań umożliwiających realizację wszystkich wymienionych rekomendacji, a jej zastosowanie w ramach zaleceń wymienionych w punktach 1., 2. oraz 5. będzie miało bezpośredni wpływ na transformację opieki geriatrycznej.

W nawiązaniu do ogólnych rekomendacji, raport The Silver Economy przedstawia także zestaw dziesięciu studiów przypadków dotyczących szczegółowych obszarów rozwiązań dla starszych osób zidentyfikowanych w wieloetapowym procesie konsultacyjnym z interesariuszami. Spośród nich co najmniej trzy są obiecującym polem przeglądu obecnych i przyszłych możliwości zastosowania sztucznej inteligencji:

Rozwój rynku narzędzi mHealth umożliwiających monitorowanie m.in. objawów neurologicznych, kardiologicznych oraz snu w celu prewencji chorób, ich szybszej diagnostyki, a także lepszego doboru leków i identyfikacji potencjalnych zdarzeń niepożądanych, które mogą wywoływać.

Rozwój rynku robotyki w kierunku tworzenia asystentów osób starszych, będących w stanie wchodzić w skomplikowane interakcje z użytkownikiem; takie rozwiązania zmniejszą problem z niedoborem opiekunów na rynku pracy.

Rozwój zintegrowanych aplikacji i rozwiązań umożliwiających zaawansowaną analizę danych w celu promocji zdrowego i aktywnego stylu życia, w tym urządzeń ubieralnych, rozwiązań spersonalizowanego żywienia i rozwiązań medycyny prewencyjnej.

Przykłady zastosowania AI w opiece nad osobami starszymi

Na rynku już dziś dostępnych jest co najmniej kilka typów rozwiązań, które pasują do opisów przedstawionych powyżej. W celu uporządkowania, przedstawione zostaną trzy kategorie rozwiązań, które wykorzystują sztuczną inteligencję: rozwiązania internetu rzeczy, roboty opiekuńcze, aplikacje mobilne stosowane w opiece zdrowotnej. Należy jednak podkreślić, że podział ten jest umowny, gdyż nowoczesne rozwiązania często opierają się na połączeniu poniższych kategorii. Oddzielnie omówiona zostanie rola sztucznej inteligencji we wsparciu decyzji klinicznych pracowników ochrony zdrowia zajmujących się opieką geriatryczną.

Aplikacje mobilne stosowane w opiece zdrowotnej (mHealth)

Wraz z upowszechnieniem smartfonów aplikacje mobilne stały się częścią naszego codziennego życia, a obszar opieki zdrowotnej wydaje się tym, w którym postęp technologiczny będzie najbardziej pożądanym.

W aplikacjach tworzonych dla osób starszych istotne stają się oczywiście ograniczenia w dostępie i kompetencjach związanych z wykorzystywaniem nowoczesnych technologii w codziennym życiu. Osoby z grupy wiekowej 65+ rzadziej stosują mobilne aplikacje zdrowotne w porównaniu do osób młodszych (Carroll,

2017), można jednak przewidywać, że wraz ze starzeniem się pokolenia wyżu demograficznego sytuacja ta ulegnie zmianie (Berenguer, 2017). Rasche i in. (2018), badając korzystanie z aplikacji zdrowotnych wśród osób starszych w Niemczech, zidentyfikowali bariery istotne dla ich zastosowania jako: brak zaufania do tej formy wsparcia opieki zdrowotnej, obawy dotyczące ochrony danych wrażliwych, a także strach przed nieprawidłową diagnozą postawioną z pomocą aplikacji. Z mobilnych aplikacji zdrowotnych korzystało 16,5% badanych w porównaniu do 37,5% korzystających z jakichkolwiek aplikacji mobilnych i 46 % niekorzystających z żadnych aplikacji.

Mimo tych wyzwań, mobilne aplikacje służące wsparciu opieki zdrowotnej osób starszych są już dziś istotnym elementem na mapie cyfrowych rozwiązań gerontechnologii.

Berauk i in. (2017) przeprowadzili przegląd publikacji naukowych opisujących zastosowanie zdrowotnych aplikacji mobilnych dla osób starszych i zidentyfikowali dwa podstawowe obszary ich funkcjonalności: aplikacje wspomagające ogólną opiekę geriatryczną oraz aplikacje skierowane dla pacjentów ze specyficznymi chorobami. W tej oraz innych pracach przeglądowych, jako konkretne przykłady zastosowań najczęściej pojawiają się aplikacje: wspierające w utrzymaniu prawidłowej diety, aktywności fizycznej, wysokiej jakości snu i przestrzegania zaleceń lekarskich, a także wspomagające w kontroli i terapii starszych pacjentów z cukrzycą, z zaburzeniami poznawczymi oraz pacjentów onkologicznych i otrzymujących opiekę paliatywną (Changizi, 2017; Joe, 2013).

W aplikacjach tego typu stosowane są rozwiązania sztucznej inteligencji w celu analizy zbieranych danych i personalizacji zaleceń dotyczących zmiany stylu życia, predykcji wystąpienia lub progresji choroby, a także wykrywania i informowania opiekunów oraz kadry medycznej o konieczności podjęcia działań w celu modyfikacji terapii (Khan, 2020).

Przykładem modelowej aplikacji mobilnej dla osób starszych jest Altoida. Rozwiązanie to oparte jest na platformie neurologii precyzyjnej, zbierającej i analizującej dane pochodzące z dedykowanej aplikacji, mającej status wyrobu medycznego. Aplikacja, za pomocą rozszerzonej rzeczywistości, pozwala na udział w wirtualnej wersji zabawy w chowanego: użytkownicy poruszają się po obiektach generowanych komputerowo w ich fizycznej przestrzeni, a sztuczna inteligencja identyfikuje popełnione błędy w celu analizy rozumowania przestrzennego, zdolności motorycznych, a także funkcji wykonawczych mózgu. Rozwiązanie umożliwia ocenę ryzyka progresji choroby Alzheimera w ciągu następnych 12 miesięcy, co może być kluczowe w kontekście decyzji terapeutycznych i opieki nad osobami będącymi w grupie ryzyka wystąpienia choroby. W 2021 r. Altoida otrzymała oznaczenie urzędnika przełomowego – programu stworzonego przez FDA w celu przyspieszenia rozwoju, oceny i przeglądu przełomowych technologii, przy jednoczesnym zachowaniu standardów regulacyjnych dotyczących zatwierdzenia przed wprowadzeniem na rynek i pozwolenia na dopuszczenie do obrotu.

Innym przykładem zastosowania sztucznej inteligencji w aplikacjach mobilnych stworzonych do wsparcia opieki nad osobami starszymi jest aplikacja FibriCheck. Umożliwia ona diagnostykę zaburzeń rytmu serca, wykorzystując sygnał optyczny

pochodzący z urządzenia niebędącego wyrobem medycznym, takiego jak smartfon. FibriCheck korzysta z kamery smartfona do wykrywania uderzeń serca, a następnie, dzięki wykorzystaniu sztucznej inteligencji, jest w stanie przeprowadzić dokładną analizę jego rytmu w celu wykrycia migotania przedsionków. Wykrycie w porę takiego zaburzenia jest szczególnie istotne ze względu na wyższe ryzyko wystąpienia udaru niedokrwiennego i daje szansę na wdrożenie skutecznej terapii. FibriCheck w 2016 r. uzyskał europejską certyfikację wyrobu medycznego klasy IIa, a w 2018 r. został zaaprobowany również przez FDA.

Przedstawione aplikacje mobilne są tylko wierzchołkiem góry lodowej, jeśli chodzi o możliwości wprowadzania tej formy nowych technologii do opieki nad osobami starszymi. Wiele aplikacji, mogących przyczynić się do utrzymania lepszego stanu zdrowia, nie będzie wymagało długoletnich i skomplikowanych badań. Przykładem są tu aplikacje monitorujące aktywność fizyczną czy wspierające zdrowe odżywianie. Można nawet uznać, że powszechnie stosowane aplikacje do komunikacji i aktywności społecznej również zaliczają się do grupy rozwiązań wspierających lub ułatwiających opiekę nad osobami starszymi. Nie ulega jednak wątpliwości, że ze względu na konieczne zaangażowanie użytkownika końcowego, największy sukces w ramach tego obszaru odniosą aplikacje dostosowane do wymagań i przystosowane do preferencji osób starszych.

Rozwiązania internetu rzeczy (Internet of Things) w opiece nad osobami starszymi

Powiązana z aplikacjami grupą są rozwiązania IoT, których założeniem jest dostarczenie starszej osobie urządzeń zbierających dane na temat jej aktualnego stanu: od opasek nadgarstkowych, przez sensory umieszczane na przedmiotach codziennego użytku, proste urządzenia do badań jak ciśnieniomierz, aż do specjalistycznych jak spirometr. Wszystkie są wyposażone w bezprzewodowe połączenie z Internetem, które umożliwia im bieżące przekazywanie danych na serwery, na których dane są analizowane – w wielu rozwiązaniach przez sztuczną inteligencję. Wyniki analizy umożliwiają zaalarmowanie o konieczności podjęcia akcji (np. przyjęcia leków, wypicia płynów), przekazują informację o niebezpiecznym zdarzeniu (np. upadku) bezpośrednio do opiekuna lub w dedykowanej dla rozwiązania aplikacji wyświetlają wnioski, które mogą być analizowane przez personel medyczny.

Łatwo przewidzieć, że zastosowanie rozwiązań IoT jest mocno uzależnione od ilości zbieranych danych o użytkowniku. Intuicyjnie byłoby założyć, że im więcej urządzeń posiada dane rozwiązanie, tym zbierane dane będą pełniejsze i umożliwią lepszy wgląd w stan zdrowia pacjenta. Do pewnego stopnia jest to prawda i faktycznie istnieją zestawy urządzeń IoT, których celem jest umożliwienie pacjentowi wykonywania zestawu podstawowych badań. Wymaga to jednak zapoznania się z obsługą wielu narzędzi, przez co może być trudne do wykorzystania przez pacjentów.

Z drugiej strony wiele informacji o stanie zdrowia potrafią dostarczyć nam z pozoru proste urządzenia ubieralne jak opaski. Tego typu rozwiązaniem jest opaska firmy CarePredict, która, zbierając codziennie dane, analizuje je za pomocą sztucznej inteligencji w celu stworzenia unikalnego profilu aktywności dnia codziennego użytkownika. Następnie monitoruje je, by wykrywać anomalie mogące świadczyć

o pojawieniu się problemu: od zwiększenia ryzyka upadku, przez infekcję układu moczowego, aż do pojawienia się epizodu depresyjnego.

Podając przykłady rozwiązań IoT wykorzystywanych w opiece nad osobami starszymi, warto także zwrócić uwagę na polskie produkty takie jak SiDLY czy AioCare. SiDLY jest opaską, która funkcjonuje na rynku w połączeniu z aplikacją mobilną i platformą teleopieki, dzięki czemu oferuje nie tylko bieżące przekazywanie informacji na temat stanu zdrowia, ale także bezpośrednią pomoc wykwalifikowanego personelu w razie wypadku. Z kolei AioCare to osobisty system do monitorowania i leczenia chorób płuc. Kluczową częścią systemu jest urządzenie IoT, które pacjent może wykorzystać w warunkach domowych do przeprowadzenia spirometrii – badania układu oddechowego, które polega na pomiarze objętości płuc oraz przepływu powietrza w różnych fazach cyklu oddechowego. Wyniki badania są przesyłane do specjalnej aplikacji mobilnej pacjenta oraz udostępnione przez platformę webową lekarzowi prowadzącemu. AioCare umożliwia kontrolę takich chorób jak: astma, choroby śródmiąższowe płuc czy przewlekła obturacyjna choroba płuc przez pacjentów z różnych grup wiekowych. W przypadku osób starszych istotna jest zwłaszcza przewlekła obturacyjna choroba płuc, która występuje u 14,2% osób powyżej 65. roku życia (Hanania, 2010). Interesujące jest, że urządzenie wykorzystuje sztuczną inteligencję m.in. do wykrywania kaszlu podczas przeprowadzania badania, umożliwiając tym samym redukcję błędów związanych z samym procesem diagnostycznym.

Powyższe przykłady nie wyczerpują w pełni obszarów zastosowania rozwiązań IoT w opiece nad osobami starszymi. Tun i in. (2021) zidentyfikowali jedenaście domen, w których, oprócz opisanych, istotne miejsce mają rozwiązania internetu rzeczy wspomagające prewencję, diagnostykę i leczenie zaburzeń zdrowia psychicznego czy pomagające w procesach rehabilitacji.

Roboty opiekuńcze

W 2014 roku około 17,4% wszystkich osób w wieku 75 lat lub więcej w UE-28 zgłosiło, że korzystało z usług opieki domowej podczas ostatnich 12 miesięcy. W przypadku kobiet sytuacja taka występowała częściej niż u mężczyzn (20% vs 13,5%) (Eurostat, 2020). Dostęp do opieki domowej będzie jednym z wyzwań stojących przed problemem starzenia się populacji – z jednej strony przez rosnącą liczbę osób potrzebujących takiej pomocy, z drugiej – z powodu niewystarczającej liczby wykwalifikowanego personelu. Wsparciem w sprośowaniu temu wyzwaniu mogą być roboty opiekuńcze, których funkcjonalności obejmują dbanie o przestrzeganie zaleceń lekarskich, wspomaganie procesów rehabilitacji czy towarzyszenie w codziennych aktywnościach. Prawdopodobnie najbardziej spektakularną ich funkcją jest system komunikacji, często oparty na rozwiązaniach konwersacyjnej sztucznej inteligencji, które zostały szczegółowo opisane przez prof. Aleksandrę Przegalińską w artykule otwierającym niniejszą publikację. Roboty, oprócz wyposażenia w system rozumienia mowy, mogą uzyskiwać dane z pomocą opisanych wcześniej narzędzi ICT. Często wyposażone są w kamery, a nawet czujniki dotyku, które umożliwiają różnorodność interakcji. Zastosowanie sztucznej inteligencji w tego typu rozwiązaniach nie tylko zakłada umożliwienie rozpoznawania i analizy ludzkiej

mowy, ale dotyczy także klasyfikowania zbieranych informacji i ich analizy w celu podjęcia spersonalizowanych akcji.

Interesującym przykładem może być obecny na rynku robot opiekuńczy ElliQ firmy Intuition Robotics, który oprócz roli asystenta ludzkiego opiekuna jest przedstawiany jako kompan osób starszych – reagujący na zmiany humoru, zapamiętujący i uczący się ich zainteresowań i dbający o dobre samopoczucie. Twórcy ElliQ opierają swój produkt na rozwiązaniach sztucznej inteligencji, która ma imitować empatię i dzięki temu zapewniać podopiecznym wrażenie indywidualnej relacji i doświadczenia. ElliQ może więc prowadzić konwersację, sesje treningu fizycznego czy medytacji, a nawet grać z użytkownikami w gry podnoszące sprawność intelektualną.

Warto także zwrócić uwagę na rozwiązania tworzone w ramach programu Horyzont 2020 – największego w historii Unii Europejskiej programu na rzecz badań i innowacji. Tworzone przez multidyscyplinarne, międzynarodowe zespoły roboty: RAMCIP (Robotic Assistant for MCI Patients at home) oraz CARESSES (Culture – Aware Robots and Environmental Sensor Systems for Elderly Support) są obiecującymi przykładami rozwoju innowacji odpowiadającej zdiagnozowanym wcześniej potrzebom.

W projekcie RAMCIP celem było zbadanie i stworzenie robota opiekuńczego pomagającego osobom starszym z łagodnymi zaburzeniami poznawczymi lub demencją. Gerłowska i in. (2018) ocenili kliniczne zastosowanie robota, który współpracował z osiemnastoma pacjentami oddziału neurologii. Zadaniem w trakcie testów było między innymi wykrycie upadków, pomoc w prostych, codziennych czynnościach oraz wsparcie w prawidłowym przyjmowaniu leków. Wyniki prototypu były obiecujące: robot uzyskał wysoką akceptację i pozytywne oddziaływanie społeczne przy zachowaniu użyteczności, a większość badanych wyraziła chęć współpracy z finalną wersją robota.

Z kolei w projekcie CARESSES wykorzystano dostępnego komercyjnie robota Pepper, aby badać możliwości zastosowania sztucznej inteligencji w zakresie komunikacji personalizowanej pod względem wzorców kulturowych i przez to dostarczać opiekę dopasowaną do odbiorcy (Bruno, 2019).

Projekty RAMCIP oraz CARESSES, mimo że nie odniosły do tej pory spektakularnego sukcesu komercyjnego, wydają się istotne z punktu widzenia rozwoju wdrażania robotów w opiece nad osobami starszymi. W obu szczególnie nacisk położono na badania naukowe, które zaowocowały wieloma wystąpieniami konferencyjnymi oraz publikacjami. Wydaje się to szczególnie istotne, jeśli weźmie się pod uwagę doniesienia Abdi i in. (2018), którzy dokonali przeglądu prac naukowych, mających na celu potwierdzić kliniczną istotność wykorzystania robotów opiekuńczych. Mimo odnotowania pozytywnych wyników badań, autorzy zwracają uwagę na błędy metodologiczne, które wpływają na wiarygodność wyników.

Sztuczna inteligencja wykorzystywana do wsparcia decyzji klinicznych

Zaprezentowany przegląd nowoczesnych technologii wykorzystujących sztuczną inteligencję, mimo że integralnie związany z podejmowaniem decyzji

terapeutycznych przez personel medyczny w opiece nad osobami starszymi, nie obejmuje szeregu rozwiązań przeznaczonych do bezpośredniego użytku pracowników ochrony zdrowia. Wraz z rozwojem sztucznej inteligencji coraz jaśniejsze staje się, że przyszła praca w ochronie zdrowia będzie wiązała się ze współpracą ludzi i maszyn dysponujących możliwościami wykraczającymi poza zdolności człowieka.

Wykorzystanie wspomnianej we wprowadzeniu możliwości analizy dużych zestawów danych stwarza nowoczesnej terapii okazję do zastosowania sztucznej inteligencji w podejmowaniu decyzji terapeutycznych, której wsparcie poprawi jakość opieki i umożliwi jej personalizację na niespotykaną do tej pory skalę.

Obecnie zastosowanie sztucznej inteligencji w analizie i diagnostyce obrazowej jest już powszechnie wykorzystywanym standardem, a ACR Data Science Institute AI Central w swojej bazie ma ponad 100 rozwiązań zaaprobowanych przez FDA do stosowania w warunkach klinicznych w diagnostyce obrazowej. Technologia wizji maszynowej umożliwia naukę na zbiorach danych z badań obrazowych, która może zostać wykorzystana zarówno do bezpośredniego wskazania na obecność patologii, jak i wsparcia w interpretacji obrazów radiologicznych. Spośród wielu firm rozwijających tego typu rozwiązania warto zwrócić uwagę na start-up Zebra Medical Vision, którego sukcesywny rozwój można było obserwować w ostatnich kilku latach. Rozwinął on kilka rozwiązań diagnostycznych opartych na głębokim uczeniu, które zostały udostępnione na platformie Philips IntelliSpace AI Workflow Suite.

Wzrost dostępności do danych z elektronicznej dokumentacji medycznej skutkuje przyspieszeniem zastosowania sztucznej inteligencji w medycynie także poza obszarem radiologii. Z pomocą uczenia maszynowego – poddziedziną sztucznej inteligencji wykorzystującą zaawansowane techniki statystyczne – można umożliwić programom komputerowym samodzielne dokonywanie prognoz dotyczących stanu pacjenta i sugerowanie decyzji terapeutycznych uwzględniających wyniki terapii u pacjentów o podobnym profilu klinicznym (Ho, 2020). Choudhury i in. (2020) przeanalizowali publikacje naukowe dotyczące zastosowania uczenia maszynowego w opiece geriatrycznej, identyfikując 35 prac badawczych, w których celem diagnostyki i wsparcia terapii były m.in. zaburzenia poznawcze, choroby oczu, astma czy miażdżyca naczyń krwionośnych. Mimo że w konkluzjach zwrócono uwagę na limitacje analizowanych badań, zwłaszcza dotyczące jakości wykorzystanych do nauki sztucznej inteligencji zbiorów danych, można spodziewać się, że w przyszłości tego typu rozwiązania staną się powszechnie stosowanym narzędziem w ochronie zdrowia.

Biorąc pod uwagę powyższe, czy możemy spodziewać się, że sztuczna inteligencja zastąpi personel medyczny w podejmowaniu decyzji terapeutycznych? Nie wydaje się, aby miało to nastąpić w najbliższej przyszłości ze względu na liczne ryzyka, które towarzyszą wykorzystaniu sztucznej inteligencji w medycynie. Sztuczna inteligencja stanie się jednak ważnym narzędziem wsparcia w procesach leczniczych. Jej rozwiązania dają możliwość rozwoju zaawansowanych systemów wsparcia decyzji klinicznych, których wykorzystanie poprawi globalny poziom opieki zdrowotnej (Sutton, 2020).

Ryzyka związane z zastosowaniem sztucznej inteligencji w opiece nad osobami starszymi

Zastosowanie sztucznej inteligencji w opiece nad osobami starszymi, oprócz korzyści, będzie wiązać się również z ryzykami, które ze względu na dynamiczny rozwój technologii mogą zmieniać swoją formę oraz poziom zagrożenia. Wraz ze zwiększeniem wpływu sztucznej inteligencji na medycynę, identyfikowane są nowe ryzyka, które grupuje się ze względu na ich specyfikę (Gerke, 2020). W Tab. 12. wskazano kategorie i przykłady ryzyk wraz z ich opisem i proponowanym sposobem mitygacji. Ryzyko związane z ograniczonymi kompetencjami cyfrowymi zostało opisane w oddzielnym podrozdziale.

Tabela 12. Przegląd ryzyk związanych z zastosowaniem sztucznej inteligencji w geriatrici

Ryzyko	Opis	Sposób ograniczenia
Ryzyka związane z transparentnością		
Ograniczona walidacja w badaniach naukowych	Brak wytycznych i ograniczone doświadczenia dotyczące metodologii badań naukowych nad zastosowaniem sztucznej inteligencji oraz identyfikacji odpowiednich punktów końcowych może wpływać na poziom dowodów naukowych i w konsekwencji zmniejszyć zaufanie pracowników ochrony zdrowia do rozwiązań lub uniemożliwić wprowadzenie ich na rynek.	Multidyscyplinarna współpraca przy projektowaniu badań naukowych, korzystanie ze standardów Good Clinical Practice i konsultacje w ramach grup roboczych dotyczących nowych technologii GCP.
Brak odtwarzalności funkcji i wyników na rzeczywistym zestawie danych	Ograniczone zestawy danych (pod względem jakościowym i ilościowym) mogą prowadzić do powstawania rozwiązań sztucznej inteligencji prezentujących zadowalające wyniki na konkretnie przekształconym i zinterpretowanym zestawie danych, które nie będą odzwierciedlać funkcjonowania narzędzia na danych rzeczywistych (Kiener, 2020).	Wypracowanie jednolitego standardu przetwarzania wstępnego danych medycznych, tworzenie wystandaryzowanych zanonimizowanych baz danych w otwartym dostępie z uwzględnieniem specyfiki.
Ryzyka etyczne		
Depersonalizacja	Ze względu na to, że sztuczna inteligencja wykorzystuje duże zestawy danych, istnieje ryzyko niewystarczającej reprezentacji potrzeb osób ze specyficznymi potrzebami zdrowotnymi; może ona wpłynąć na decyzje i sposób terapii, prowadząc do różnej skali błędów w procesie leczniczym (Safdar, 2020).	Zapewnienie nadzoru wykwalifikowanego personelu nad rozwiązaniami wykorzystującymi sztuczną inteligencję w opiece zdrowotnej. Rozwój kompetencji cyfrowych pozwalających profesjonalistom na identyfikację błędów wynikających z generalizacji wyjątkowych przypadków pacjentów.

cd. Tabeli 12. Przegląd ryzyk związanych z zastosowaniem sztucznej inteligencji w gerii

Dehumanizacja	Stosowanie sztucznej inteligencji w opiece nad osobami starszymi może doprowadzić do pogorszenia jakości relacji międzyludzkich i w konsekwencji pogorszyć jakość życia użytkowników końcowych (Sharkey, 2010).	Edukacja osób starszych i ich opiekunów na temat właściwej roli sztucznej inteligencji w opiece, przy równoczesnym rozwoju relacji międzyludzkich i informowaniu o zagrożeniach związanych z ich pogorszeniem przez technologię.
Dyscyplinowanie	Rozwiązania oparte na sztucznej inteligencji wymagają stałego dostępu do danych pacjenta, a ich zbieranie oznacza konieczność ciągłego korzystania z narzędzi monitorujących stan zdrowia. Rodzi to obawy o wywieranie nacisku i wykorzystanie władzy nad osobami starszymi, by ograniczać ich wolność w zamian za bezpieczeństwo (Manzeschke, 2016).	Tworzenie rozwiązań wykorzystujących sztuczna inteligencję we współpracy z użytkownikami końcowymi i po uwzględnieniu ich uwag dotyczących sposobu, w jaki chcą z nich korzystać. Wprowadzenie oceny zadowolenia użytkownika jako równorzędnego miernika efektywności zastosowania technologii, decydującego o kontynuacji korzystania.
Ryzyka prawne		
<p>Wykorzystanie sztucznej inteligencji w medycynie rodzi szereg ryzyk prawnych, których przedstawienie mogłoby być tematem oddzielnego opracowania. Jednym z najszerzej dyskutowanych oraz wzbudzających najwięcej emocji jest kwestia odpowiedzialności za podjętą decyzję terapeutyczną, jeśli była podejmowana przy wsparciu sztucznej inteligencji. W przypadku wykorzystania przez lekarza z odpowiednio przebadanego i zatwierdzonego do użycia narzędzia ciężko określić odpowiedzialność za błąd medyczny powstały na skutek korzystania z pomocy sztucznej inteligencji. Nawet jeśli uznamy, że sztuczna inteligencja zawsze będzie pełnić funkcję wspierającą lekarza (co wydaje się bardzo zachowawczym podejściem), a ostateczna decyzja terapeutyczna musi być podjęta autonomicznie przez człowieka, powstają wątpliwości dotyczące ostatecznej odpowiedzialności, np. w przypadku niezawinionego przez lekarza błędu w rozwiązaniu wykorzystującym AI (Raveesh, 2016; Gerke, 2020). W związku z tym powstaje potrzeba aktualizacji obowiązujących aktów prawnych, a także opracowanie strategii dotyczącej wprowadzenia regulacji, które umożliwią odpowiedź na wyzwania związane z pojawiającymi się ryzykami prawnymi.</p>		

Źródło: opracowanie własne.

Kompetencje cyfrowe w gerii

Jednym z ryzyk związanych z wykorzystaniem nowoczesnych technologii i sztucznej inteligencji w opiece geriatrycznej będzie także brak kompetencji kadr medycznych, pacjentów i ich opiekunów do korzystania z nich w sposób świadomy. Zachodzące zmiany, nie tylko w rodzaju wykorzystywanych w opiece narzędzi, ale także procesów związanych z opieką, niosą za sobą ryzyko nieprawidłowego wykorzystania nowych technologii, oporu przed aktywnym uczestnictwem w nowoczesnych formach opieki, a także – być może najgroźniejsze – uczestniczenie w systemie ochrony zdrowia z poczuciem wyobcowania i niezrozumienia zasad jego funkcjonowania. Konieczny jest więc dalszy rozwój kompetencji w zakresie korzystania z nowoczesnych technologii, zwłaszcza wśród starszych pacjentów obecnej i przyszłej generacji, ale także zbudowanie świadomości na temat podstawowych pojęć dotyczących

sztucznej inteligencji, aby wraz z upowszechnieniem terminu rosła świadomość na temat jej zalet, wad, potencjalnych korzyści i ograniczeń.

Edukacja w zakresie rodzaju podejmowanej interwencji terapeutycznej jest jednym ze sposobów lepszego przestrzegania zaleceń przez pacjenta w przypadku konwencjonalnych terapii (Roter, 1998; Taibanguay, 2019). Terapie z wykorzystaniem nowoczesnych technologii również będą wymagały zrozumienia przez pacjenta, aby były skuteczne. Tymczasem aż 44% osób w wieku 65–74 lata, mieszkających na terenach krajów UE-27 do roku 2017 nigdy nie korzystało z komputera. Ten wskaźnik znacznie się różni w poszczególnych krajach: od 5% na Islandii, w Szwecji i Norwegii, aż do 78% w Grecji (Eurostat, 2020). Rozwój kompetencji technologicznych staje się więc kluczowym aspektem transformacji opieki geriatrycznej przyszłości i będzie miał wpływ na efektywność zastosowanych rozwiązań.

W przygotowanym przez Komisję Europejską planie działania w dziedzinie edukacji cyfrowej na lata 2021–2027 wyszczególniono trzy kluczowe priorytety działania:

1. Lepsze wykorzystywanie technologii cyfrowej w nauczaniu i uczeniu się
2. Rozwijanie kompetencji i umiejętności cyfrowych właściwych w dobie transformacji cyfrowej
3. Poprawę kształcenia dzięki lepszemu analizie danych i prognozowaniu.

W ramach priorytetu 2. podkreśla się znaczenie nabywania umiejętności cyfrowych od młodego wieku i trwanie tego procesu przez całe życie (Komisja Europejska, 2020).

Zaplanowane działania z pewnością pomogą w dostosowaniu przyszłych generacji osób starszych do wykorzystania nowoczesnych technologii, ale z punktu widzenia sukcesu transformacji opieki geriatrycznej w najbliższej dekadzie szczególnie istotne jest, aby poszerzać kompetencje osób starszych obecnej generacji, które z przyczyn naturalnych nie miały okazji rozwinąć ich w stopniu równym młodszemu pokoleniom.

Z tego powodu istotne są działania podejmowane m.in. przez AGE Platform Europe – europejską sieć organizacji non profit skupionych na artykułowaniu i realizacji potrzeb osób powyżej 50 r.ż. W publicznych konsultacjach do planu działania w dziedzinie edukacji cyfrowej AGE rekomenduje szereg aktywności, które pozwolą włączyć w zaplanowane działania osoby starsze:

1. Uwzględnienie w działaniach dotyczących rozszerzenia dostępu cyfrowego dla osób napotykających bariery w tym zakresie m.in. przez organizację otwartych punktów dostępu cyfrowego w instytucjach publicznych oraz placówkach opiekuńczych.
2. Wsparcie formalnej i nieformalnej edukacji cyfrowej nie tylko przez dostarczenie dostępu do technologii, ale także budowanie potencjału i umiejętności kadry zajmującej się edukacją dorosłych.

3. Wsparcie w zapoznaniu się osób wykluczonych cyfrowo z możliwościami nauki online.
4. Zwrócenie większej uwagi na edukację w zakresie cyfrowego bezpieczeństwa osób starszych.
5. Dostosowanie formalnych możliwości edukacji do potrzeb starszych osób uczących się, z uwzględnieniem zwiększenia dostępności dla osób mieszkających na obszarach wiejskich.
6. Zapewnienie mechanizmów finansowania ze środków publicznych projektów uwzględniających wyżej wymienione rekomendacje (AGE Platform Europe, 2020).

Założenia tych rekomendacji są już dziś spełniane w ramach inicjatyw takich jak programy DIGITOL, Mobile Age, FAITH – programy edukacyjne dla osób starszych w dziedzinie umiejętności cyfrowych, które są finansowane ze środków unijnych. AGE postuluje zwiększenie dostępności tego typu inicjatyw na szczeblu unijnym i krajowym.

Można przewidywać, że zderzenie z technologią, która jest do pewnego stopnia autonomiczna w wyciąganiu wniosków i sugerowaniu odpowiednich działań, może wzbudzać podejrzenia wśród kadry medycznej co do źródła i mechanizmu, w którym tworzy ona wyniki. Zwiększenie zaufania do sztucznej inteligencji przez zapewnienie transparentności jej działania, a także solidności w procesie badania skuteczności może być istotne dla współpracy personelu medycznego z rozwiązaniami opartymi na AI (Asan, 2020).

Istotnym tematem w najbliższych latach będą metody, za pomocą których takie zaufanie będzie budowane. Szczególnie ważne jest, aby ustalić dobre praktyki w zakresie informowania i nauki korzystania z poszczególnych rozwiązań sztucznej inteligencji i określić, kto powinien być odpowiedzialny za ich wdrażanie. Wydaje się naturalne, że dostawca rozwiązań opartych na AI powinien prowadzić szkolenia z wykorzystania danego rozwiązania w praktyce dla użytkowników, a także zapewnić wsparcie w codziennym użytkowaniu technologii. Być może funkcjonujący model działów medycznych działających w strukturach firm farmaceutycznych i udostępniających zasoby związane z edukacją i wsparciem merytorycznym dla pracowników ochrony zdrowia stanie się także standardem w firmach oferujących cyfrowe rozwiązania oparte na sztucznej inteligencji.

Obecność zewnętrznych konsultantów gotowych do pomocy personelowi medycznemu w ramach poszczególnych rozwiązań AI może okazać się niewystarczająca lub zbyt obciążająca w codziennej pracy użytkowników. Można jednak wyobrazić sobie, że odpowiednim podejściem byłoby kształcenie, w ramach zespołów medycznych, użytkowników zaawansowanych (*power user*), którzy, poświęcając dodatkowy czas na zrozumienie i korzystanie z danego rozwiązania, stawaliby się ekspertami w ramach pracy zespołu i służyliby pomocą w razie wątpliwości i pojawiających się pytań. Otwartym zagadnieniem pozostaje, jak szeroki zakres wiedzy powinien przyswoić taki użytkownik. Czy powinniśmy podjąć starania o obecność zaawansowanych użytkowników w ramach konkretnych rozwiązań sztucznej

inteligencji, których kompetencje byłyby rozwijane w niezmienionej strukturze zespołu, czy też konieczne stanie się oddelegowanie pracownika lub grupy pracowników, którzy będą wspierać daną organizację w różnych obszarach zastosowania AI? Taka strategia wiązałaby się z dodatkowymi kosztami i wymagałaby rozwinięcia uwzględniających je modeli biznesowych.

Budowanie zaufania do sztucznej inteligencji wśród pracowników ochrony zdrowia, niezależnie od rodzaju podjętych działań, będzie nieskuteczne, jeśli nie pójdzie w parze z edukacją związaną z nowoczesnymi technologiami. Znaczenie kształcenia personelu medycznego w zakresie AI zostało szczegółowo opisane przez Ligię Kornowską w jednym z podrozdziałów artykułu poprzedzającego niniejszy tekst.

Podsumowanie

Postępujące zmiany demograficzne wymuszają na systemie ochrony zdrowia wprowadzenie nowoczesnych technologii, w których sztuczna inteligencja będzie odgrywać wiodącą rolę. Będzie szansą na sprostanie wyzwaniom stojącym za konsekwencjami zmiany profilu standardowego pacjenta i jego potrzeb, a także następującymi równoległe skutkami ekonomiczno-społecznymi. Celem zastosowania sztucznej inteligencji w opiece nad osobami starszymi powinno być z jednej strony wydłużenie okresu życia w zdrowiu, a z drugiej poprawa dostępności i jakości usług opieki zdrowotnej u osób wymagających leczenia. Wysokie wskaźniki zgonów z powodu chorób kardiowaskularnych i onkologicznych, choroby współistniejące i ich negatywny wpływ na jakość życia, ograniczenie dostępu do usług zdrowotnych zwłaszcza dla mieszkańców obszarów rolniczych oraz potrzeby związane z długoterminową opieką osób starszych są jednymi z wielu istotnych problemów, w których sztuczna inteligencja może okazać się kluczowym czynnikiem zmian.

Odpowiadając na te wyzwania, należy jednak zachować ostrożność w wyznaczaniu celów opartych wyłącznie na efektywności terapeutycznej i wskaźnikach ekonomicznych. We wprowadzaniu rozwiązań opartych na sztucznej inteligencji w geriatrici należy szczególnie zwracać uwagę na potrzeby pacjentów i pracowników ochrony zdrowia, którzy, będąc końcowymi użytkownikami, mają prawo do partycypowania w ustalaniu celów opieki i sposobów ich realizacji. Dzięki temu będzie można uniknąć sytuacji niedostosowania rozwiązań do potrzeb odbiorców, wziąć pod uwagę istotne aspekty medyczne oraz uzyskać akceptację i zaufanie do nowoczesnych rozwiązań ze strony personelu medycznego.

Kluczowe jest też podjęcie działań w kierunku rozwoju kompetencji technologicznych odbiorców rozwiązań opartych na sztucznej inteligencji, w tym kadry medycznej. Równie ważne jest zapewnienie standardów etycznych, bez których sztuczna inteligencja w medycynie może stać się czynnikiem wykluczającym i doprowadzić do negatywnych skutków zdrowotnych i społecznych nie tylko z perspektywy jednostki, ale całego systemu ochrony zdrowia.

Nowe technologie oparte na sztucznej inteligencji stają się coraz bardziej powszechne w naszym życiu, mimo że czasami nawet tego nie zauważamy. W najbliższej przyszłości będą też nieodzownym elementem życia osób starszych, wpływając na istotną i coraz dłuższą część życia każdego z nas. Od uważności,

determinacji i zdolności do współpracy ekspertów różnych dziedzin będzie zależało, czy z perspektywy czasu będziemy mogli uznać obszar opieki nad osobami starszymi za historię sukcesu zastosowania sztucznej inteligencji.

Bibliografia

Abdi, J., Al-Hindawi, A., Ng, T. and Vizcaychipi, M. P. (2018). Scoping review on the use of socially assistive robot technology in elderly care. *BMJ open*, 8(2), e018815.

ACR Data Science Institute AI Central. Pobrano z: <https://aicentral.acrdsi.org/>

Adler-Milstein, J., DesRoches, C. M., Kralovec, P., Foster, G., Worzala, C., Charles, D., Searcy, T., and Jha, A. K. (2015). Electronic Health Record Adoption In US Hospitals: Progress Continues, But Challenges Persist. *Health affairs (Project Hope)*, 34(12), 2174–2180.

AGE Platform Europe (2020). AGE input to the consultation: Digital Education Action Plan. Pobrano z: https://www.age-platform.eu/sites/default/files/AGE_paper_on_Digital_Education_Action_Plan_2020-V2.pdf

Aminzadeh, F. and Dalziel, W. B. (2002). Older adults in the emergency department: a systematic review of patterns of use, adverse outcomes, and effectiveness of interventions. *Annals of emergency medicine*, 39(3), 238–247.

Asan, O., Bayrak, A. E. and Choudhury, A. (2020). Artificial Intelligence and Human Trust in Healthcare: Focus on Clinicians. *Journal of medical Internet research*, 22(6), e15154.

Berauk, A., V. L., Murugiah, M. K., Soh, Y. C., Chuan Sheng, Y., Wong, T. W. and Ming, L. C. (2018). Mobile Health Applications for Caring of Older People: Review and Comparison. *Therapeutic innovation & regulatory science*, 52(3), 374–382.

Berenguer, A., Goncalves J., Hosio, S., Ferreira, D., Anagnostopoulos, T. and Kostakos, V. (2017). Are smartphones ubiquitous? An in-depth survey of smartphone adoption by seniors. *IEEE Consum Electron Mag*, 6(1):104–110.

Bruno, B., Recchiuto, C.T., Papadopoulos, I., Saffiotti, A., Koulouglioti, C., Menicatti, R., Mastrogiovanni, F., Zaccaria, R. and Sgorbissa, A. (2019). Knowledge Representation for Culturally Competent Personal Robots: Requirements, Design Principles, Implementation, and Assessment. *International Journal of Social Robotics*, 11, 515–538.

Carroll, J. K., Moorhead, A., Bond, R., LeBlanc, W. G., Petrella, R. J. and Fiscella, K. (2017). Who Uses Mobile Phone Health Apps and Does Use Matter? A Secondary Data Analytics Approach. *J Med Internet Res*, 19(4):e125.

Changizi, M. and Kaveh, M. H. (2017). Effectiveness of the mHealth technology in improvement of healthy behaviors in an elderly population-a systematic review. *mHealth*, 3, 51.

Choudhury, A., Renjilian, E. and Asan, O. (2020). Use of machine learning in geriatric clinical care for chronic diseases: a systematic literature review. *JAMIA open*, 3(3), 459–471.

Eurostat (2020). Ageing Europe.

Fayyaz, J., Khursheed, M., Umer Mir, M. and Khan, U. (2013). Pattern of emergency department visits by elderly patients: study from a tertiary care hospital, Karachi. *BMC geriatrics*, 13, 83.

Fuchs, C., Çelik, B., Brouns, S., Kaymak, U. and Haak, H. R. (2019). No age thresholds in the emergency department: A retrospective cohort study on age differences. *PloS one*, 14(1), e0210743.

Gerke, S., Minssen, T. and Cohen, G. (2020). Ethical and legal challenges of artificial intelligence-driven healthcare. *Artificial Intelligence in Healthcare*, 2020, 295–336.

Gerłowska, J., Skrobas, U., Grabowska-Aleksandrowicz, K., Korchut, A., Szklener, S., Szczeńiak-Stańczyk, D., Tzovaras, D. and Rejda, K. (2018). Assessment of Perceived Attractiveness, Usability, and Societal Impact of a Multimodal Robotic Assistant for Aging Patients With Memory Impairments. *Frontiers in neurology*, 9, 392.

Hanania, N. A., Sharma, G. and Sharafkhaneh, A. (2010). COPD in the elderly patient. *Seminars in respiratory and critical care medicine*, 31(5), 596–606.

Ho, A. (2020). Are we ready for artificial intelligence health monitoring in elder care? *BMC geriatrics*, 20(1), 358.

Joe, J. and Demiris, G. (2013). Older adults and mobile phones for health: a review. *Journal of biomedical informatics*, 46(5), 947–954.

Khan, Z. F. and Alotaibi, S. R. (2020). Applications of Artificial Intelligence and Big Data Analytics in m-Health: A Healthcare System Perspective. *Journal of healthcare engineering*, 2020, 8894694.

Kiener, M. (2020). Artificial intelligence in medicine and the disclosure of risks [published online ahead of print]. *AI Soc.* 2020;1–9.

Komisja Europejska (2018). The Silver Economy.

Komisja Europejska (2020). Digital Education action Plan 2021–2027.

Komisja Europejska (2021). Green Paper on Ageing.

Manzeschke, A., Assadi, G. and Viehöver, W. (2016). The Role of Big Data in Ambient Assisted Living. *International Review of Information Ethics*, 24.

National Health Service (2019). The NHS long term plan.

Rasche, P., Wille, M., Bröhl, C., Theis, S., Schäfer, K., Knobe, M. and Mertens, A. (2018). Prevalence of Health App Use Among Older Adults in Germany: National Survey. *JMIR mHealth and uHealth*, 6(1), e26.

Raveesh, B. N., Nayak, R. B. and Kumbar, S. F. (2016). Preventing medico-legal issues in clinical practice. *Annals of Indian Academy of Neurology*, 19(Suppl 1), S15–S20.

Roter, D. L., Hall, J. A., Merisca, R., Nordstrom, B., Cretin, D. and Svarstad, B. (1998). Effectiveness of interventions to improve patient compliance: a meta-analysis. *Medical care*, 36(8), 1138–1161.

Safdar, N. M., Banja, J. D. and Meltzer, C. C. (2020). Ethical considerations in artificial intelligence. *European journal of radiology*, 122, 108768.

Sharkey, A.J. and Sharkey, N.E. (2010). Granny and the robots: ethical issues in robot care for the elderly. *Ethics and Information Technology*, 14, 27–40.

Sutton, R. T., Pincock, D., Baumgart, D. C., Sadowski, D. C., Fedorak, R. N. and Kroeker, K. I. (2020). An overview of clinical decision support systems: benefits, risks, and strategies for success.

Taibanguay, N., Chaiamnuay, S., Asavatanabodee, P. and Narongroeknawin, P. (2019). Effect of patient education on medication adherence of patients with rheumatoid arthritis: a randomized controlled trial. *Patient preference and adherence*, 13, 119–129.

Tun, S., Madanian, S. and Mirza, F. (2021). Internet of things (IoT) applications for elderly care: a reflective review. *Aging clinical and experimental research*, 33(4), 855–867.

Ustawa z dnia 28 kwietnia 2011 r. o systemie informacji w ochronie zdrowia (Dz.U. z 2011 r., Nr 113, poz. 657 z późn. zm.).

Informacje o autorach

Dr Marcin Będkowski – adiunkt w Instytucie Języka Polskiego Uniwersytetu Warszawskiego, kierownik Zakładu Językoznawstwa Komputerowego, ekspert w Instytucie Badań Edukacyjnych. Obszary zainteresowań naukowych: metodologia nauk humanistycznych, filozofia analityczna, semiotyka logiczna, językoznawstwo komputerowe, logika praktyczna. Autor książki *Parafrazowanie – metoda – analiza*. Członek zespołu redakcyjnego „Edukacji Filozoficznej”.

Dr hab. Jakub Brdulak – profesor w Szkole Głównej Handlowej w Warszawie oraz pełnomocnik rektora ds. Uczelnianego Systemu Zarządzania Jakością SGH, polski delegat do Bologna Follow-Up Group – Quality Assurance w Europejskim Obszarze Szkolnictwa Wyższego (*European Higher Education Area*) w latach 2018–2024. Członek zarządu Fundacji na rzecz Jakości Kształcenia przy KRASP. Członek Polskiej Komisji Akredytacyjnej, ekspert MEiN w programach „Akredytacje Zagraniczne” i „Mistrzowie Dydaktyki”. Autor wielu publikacji na temat zarządzania wiedzą, innowacji i jednostek szkolnictwa wyższego.

Prof. dr hab. Jan Fazlagić – profesor na Uniwersytecie Ekonomicznym w Poznaniu. Jeden z prekursorów zarządzania wiedzą (*knowledge management*) w Polsce. Stypendysta Fulbrighta i Marii Curie Research Fellow. Uczestnik i kierownik wielu projektów krajowych i międzynarodowych, między innymi w Polskiej Agencji Rozwoju Przedsiębiorczości, Narodowym Instytucie Samorządu Terytorialnego oraz Climate-KIC. W latach 2011–2015 odpowiedzialny za rozwój i innowacje w Grupie Uczelni Vistula w Warszawie. Autor ponad dwudziestu książek oraz kilkuset artykułów naukowych i popularnonaukowych. Interesuje się możliwościami wykorzystania sztucznej inteligencji w systemie edukacji, nauczaniu oraz w obszarze (sztucznej) kreatywności. Prelegent licznych konferencji w obszarze edukacji (także klimatycznej) oraz samorządu terytorialnego. Więcej informacji na: Fazlagic.pl

Lek. Michał Janiszewski – absolwent Warszawskiego Uniwersytetu Medycznego, dyrektor ds. medycznych i współzałożyciel AIDA Diagnostics – start-upu tworzącego systemy wsparcia decyzji z wykorzystaniem sztucznej inteligencji w ochronie zdrowia. Obszary zainteresowań naukowych: sztuczna inteligencja w medycynie, projektowanie i walidacja systemów wspomagania decyzji klinicznych, rozwiązania no-code w obszarze zdrowia.

Prof. dr hab. Dariusz Jemielniak – profesor w Akademii Leona Koźmińskiego i faculty associate w Berkman-Klein Center for Internet and Society na Harvardzie, a także członek Rady Powierniczej Fundacji Wikimedia i najmłodszy w historii członek i korespondent PAN z zakresu nauk społecznych i humanistycznych. Pracował też na MIT, Cornell University i Berkeley. Autor m.in. *Common Knowledge?* (2014, Stanford University Press), *Thick Big Data* (2020, Oxford University Press) i *Collaborative Society* (2020, MIT Press, z A. Przegalińską).

Lek. Ligia Kornowska – dyrektor zarządzająca Polskiej Federacji Szpitali, organizacji zrzeszającej największą liczbę szpitali w Polsce. Propagatorka AI w medycynie, liderka Koalicji AI w zdrowiu. Wyróżniona na liście Forbesa „25 under 25” w kategorii „Biznes”, wyróżniona na liście „100 najbardziej wpływowych osób w ochronie zdrowia”. Była CEO/dyrektor kilku start-upów medycznych. Prelegentka i moderatorka licznych konferencji sektora ochrony zdrowia o zasięgu krajowym i międzynarodowym.

Dr hab. Aleksandra Przegalińska – profesorka Akademii Leona Koźmińskiego, doktorka habilitowana w dziedzinie nauk o zarządzaniu. Doktoryzowała się w zakresie filozofii sztucznej inteligencji w Instytucie Filozofii UW. Obecnie prorektorka ds. współpracy z zagranicą oraz ESR w Akademii Leona Koźmińskiego. Od 2016 do 2019 roku prowadziła badania w ramach post-doca w Massachusetts Institute of Technology w Bostonie. Absolwentka The New School for Social Research w Nowym Jorku, gdzie uczestniczyła w badaniach dotyczących tożsamości w rzeczywistości wirtualnej, ze szczególnym uwzględnieniem Second Life. Aktualnie Research Fellow w American Institute for Economic Research. W 2022 roku rozpoczęła współpracę z Labour and Worklife Program na Harvardzie. Interesuje się rozwojem sztucznej inteligencji, przetwarzaniem języka naturalnego, uczeniem maszynowym, robotami społecznymi i technologiami ubieralnymi.

Dr Joanna Rabięga-Wiśniewska – adiunkt w Instytucie Badań Edukacyjnych, ekspertka projektu Zintegrowany Rejestr Kwalifikacji oraz ekspertka i badaczka w projekcie Erasmus+ KEEP (Key engaging educational practices used by secondary school teachers to keep connected with their students following COVID-19 pandemic). Stypendystka Programu Rozwoju Organizacji Obywatelskich na lata 2018–2030 oraz Programu Empirical Linguistics and Natural Language Processing 2002–2003 (w Niemczech). Wykładowczyni Akademii Pedagogiki Specjalnej im. M. Grzegorzewskiej oraz Collegium Verum w Warszawie. Obszary zainteresowań naukowych: pedagogika medialna, metodyka wykorzystywania mediów w edukacji, nowe technologie w edukacji, projektowanie i organizacja kształcenia online, językoznawstwo komputerowe. Współautorka kilku projektów edukacyjnych realizowanych we współpracy z sektorem pozarządowym, podnoszących kompetencje cyfrowe pracowników oświaty i grup zagrożonych wykluczeniem.

Jakub Stęchły – manager ds. zrównoważonej mobilności i energetyki w grupie Veolia, doktorant w Akademii Wyższej Szkoły Bankowej (WSB) w Dąbrowie Górniczej. Obszary zainteresowań naukowych: zarządzanie zrównoważoną mobilnością miejską, ekosystemy biznesu, nowoczesna mobilność.

Wojciech Stęchły – asystent w Instytucie Badań Edukacyjnych i Szkole Głównej Handlowej w Warszawie. Obszary zainteresowań: kształcenie zawodowe, kapitalizm, polityka rozwoju umiejętności (kapitału ludzkiego), inżynieria językowa w edukacji, certyfikacja umiejętności. Ekspert ds. Zintegrowanego Systemu Kwalifikacji, członek Sektorowej Rady ds. Kompetencji MOTO.

Prof. dr hab. Jacek Szoltysek – kierownik Katedry Logistyki Społecznej Uniwersytetu Ekonomicznego w Katowicach. Od ponad 15 lat swoje zainteresowania naukowe skupia na potencjale logistyki w zarządzaniu miastem, w ochronie zdrowia, akcjach humanitarnych i innych zastosowaniach logistyki społecznej. W swoich

badaniach i rozważaniach teoretycznych sięga do doświadczeń innych dyscyplin naukowych, wdrażając interdyscyplinarne podejście w obszarze funkcjonowania miast, w tym logistyki miasta. Jest pomysłodawcą stworzenia logistyki społecznej, traktowanej na równi z logistyką militarną i gospodarczą jako trzeci obszar koncepcyjny logistyki. Jest autorem 9 podręczników akademickich i 6 monografii naukowych, ponad 60 rozdziałów w monografiach naukowych i ponad 180 artykułów naukowych, publikowanych w kraju i za granicą. Jest redaktorem naukowym 17 prac naukowych.

Prof. dr hab. Maciej M. Sysło – matematyki i informatyk. W połowie lat 60. przyglądał się, jak uczniowie z III LO we Wrocławiu uruchamiali swoje programy na maszynie Elliott 803 w ramach pierwszych w kraju zajęć z programowania i metod numerycznych w szkole. Od połowy lat 80. włączył się w przygotowanie nauczycieli na ekspansję komputerów w edukacji. Za swój największy sukces uznaje utrzymanie, wbrew tendencjom w kraju i za granicą, wydzielonych zajęć z informatyki w szkołach, a ostatnio – wprowadzenie powszechnego kształcenia informatycznego, obejmującego nauczanie informatyki i programowania wszystkich uczniów na wszystkich poziomach edukacyjnych. Teraz upowszechnia myślenie komputacyjne, jako uzupełnienie tradycyjnych kompetencji 3R – czytania, pisania i rachowania. Nagrodzony wieloma wyróżnieniami i grantami krajowymi i zagranicznymi. Więcej na mmsyslo.pl oraz pl.wikipedia.org/wiki/Maciej_Marek_Sysło

Mirosław Usidus, publicysta naukowo-techniczny, twórca i menedżer licznych projektów internetowych, redaktor naczelny „Młodego Technika”, wcześniej autor i współpracownik m.in. „Rzeczpospolitej”, „Newsweeka”, Telewizji Polskiej, Polskiego Radia, „Świata Nauki”, miesięcznika „Press”, magazynu „ThinkTank” i wielu innych tytułów. Od ok. 15 lat zaangażowany w tematykę sztucznej inteligencji jako autor publikacji, recenzent rozwiązań, a także projektant serwisów i aplikacji opartych na wykorzystaniu AI.

algorytm (ang. *algorithm*) – skończony ciąg jasno zdefiniowanych czynności koniecznych do wykonania pewnego rodzaju zadania lub osiągnięcia celu, sposób postępowania prowadzący do rozwiązania problemu. Dział informatyki zajmujący się projektowaniem i analizą algorytmów to algorytmika.

Źródło: <https://encyklopedia.pwn.pl/haslo/;3867807>

AR (ang. *virtual reality*) - patrz: rozszerzona rzeczywistość.

automatyczne (algorytmiczne, zrobotyzowane) dziennikarstwo – dziennikarstwo automatyczne opiera się na generowaniu materiałów tekstowych, informacji, artykułów, raportów przez programy komputerowe, algorytmy przetwarzające dane, generatory tekstu oparte na modelach NLP. Programy komputerowe i algorytmy interpretują, organizują i prezentują dane w sposób czytelny dla odbiorcy. Zazwyczaj proces ten polega na zastosowaniu algorytmu, który skanuje duże ilości dostarczonych danych, wybiera z katalogu zaprogramowanych struktur materiałów informacyjnych, porządkuje kluczowe zagadnienia i wstawia specyficzne dane lub organizuje strukturę narracji (ang. *automated storytelling*), takie jak np. nazwiska, miejsca, kwoty, rankingi, statystyki i inne dane liczbowe. W połączeniu z technikami syntetyzowania głosu na podstawie tekstu i kreacji obrazów postaci humanoidalnych, techniki generowania tekstu tworzą zautomatyzowane i zrobotyzowane formy dziennikarstwa audiowizualnego.

Zautomatyzowane dziennikarstwo jest czasem postrzegane jako szansa na uwolnienie dziennikarzy od rutynowych, powtarzalnych obowiązków zawodowych, dzięki czemu zyskają więcej czasu na wykonywanie złożonych zadań. Pozwala także na zwiększenie efektywności i obniżenie kosztów, zmniejszając obciążenia finansowe, z którymi boryka się wiele redakcji. Jednak zautomatyzowane dziennikarstwo jest także postrzegane jako zagrożenie dla jakości wiadomości oraz uderzenie w źródła utrzymania dziennikarzy.

Źródło: Graefe A. (2016). Guide to Automated Journalism. Columbia Journalism Review. Pobrane z https://www.cjr.org/tow_center_reports/guide_to_automated_journalism.php

big data to termin odnoszący się do dużych, zmiennych i różnorodnych zbiorów danych, których przetwarzanie i analiza jest trudna, ale jednocześnie wartościowa, ponieważ może prowadzić do zdobycia nowej wiedzy. Pojęcie dużego zbioru danych jest względne i oznacza sytuację, gdy zbioru nie da się przetwarzać przy użyciu powszechnie dostępnych metod. W zależności od branży i stopnia złożoności algorytmu może to oznaczać rozmiar terabajtów lub petabajtów, jednak w innych zastosowaniach będą to już megabajty bądź gigabajty. Big data ma zastosowanie wszędzie tam, gdzie dużej ilości danych cyfrowych towarzyszy potrzeba zdobywania nowych informacji lub wiedzy. Wykorzystanie do analiz dużych zbiorów danych oznacza jednocześnie, że nie trzeba ograniczać się do mniejszych zbiorów określanych za pomocą różnych sposobów doboru próby, co eliminuje związane z tym błędy.

Źródło: https://pl.wikipedia.org/wiki/Big_data

blended learning – mieszana (zintegrowana, hybrydowa) metoda kształcenia, łącząca tradycyjne metody nauki (bezpośredni kontakt z prowadzącym) z aktywnościami prowadzonymi zdalnie za pomocą komputera (*mobile learning*). Stosunek poszczególnych elementów dobiera się w zależności od treści kursu, potrzeb studentów i preferencji prowadzącego.

Źródło: https://pl.wikipedia.org/wiki/Blended_learning

Certyfikat zgodności CE / deklaracja zgodności to dokument wystawiany przez producenta wyrobu albo jego upoważnionego przedstawiciela, stanowiący wiążące prawnie przyrzeczenie stwierdzające zgodność wyrobu z wymaganiami zasadniczymi właściwych dyrektyw Unii Europejskiej. Przed wystawieniem przez producenta deklaracji zgodności wyroby powinny być poddane procedurze oceny zgodności i, jeśli wynika to z odrębnych przepisów, uzyskać właściwe certyfikaty. Na wyrobach posiadających deklarację zgodności producent umieszcza oznaczenie / oznakowanie CE.

Źródło: https://pl.wikipedia.org/wiki/Deklaracja_zgodności

CMI (ang. *computer-managed instruction*) – wykorzystanie technik komputerowych do organizowania i zarządzania programami nauczania dla uczniów i studentów; pozwala ono budować aplikacje testujące, śledzić wyniki testów i monitorować postępy uczniów.

Źródło: <https://pl.wikipedia.org/wiki/CMI>

data science, danologia – jest to interdyscyplinarne pole używające naukowych metod, procesów, algorytmów i systemów do wydobywania spostrzeżeń z wielu danych strukturalnych i nieustrukturyzowanych. Data science jest powiązana z eksploracją danych (ang. *data mining*), uczeniem maszynowym (ang. *machine learning*) i analizą dużych zbiorów danych (ang. *big data*). Data science wykorzystuje statystykę, analizę danych, uczenie maszynowe, wiedzę dziedzinową (ang. *domain knowledge*) i powiązane metody w celu zrozumienia i analizy danych.

Źródło: <https://pl.wikipedia.org/wiki/Danologia>

dziedzina (domena) kreatywności – koncepcja oparta na założeniu, że nikt nie jest kreatywny w sensie ogólnym i w związku z tym u większości ludzi możemy wyróżnić pewne specjalizacje, w których osiągają od lat przeciętne wyniki. Koncepcji tej nie należy utożsamiać z teorią inteligencji wielorakich, która nie ma silnych podstaw teoretycznych, aczkolwiek jest bardzo popularna w świecie praktyków.

Źródło: prof. dr hab. Jan Fazlagić.

dziennikarstwo danych – znane w literaturze anglojęzycznej jako *data journalism* lub *data-driven journalism* (DDJ) – metoda dziennikarska i reporterska, polegająca na analizowaniu i filtrowaniu dużych zbiorów danych w celu tworzenia lub wzbogacania materiałów informacyjnych, publicystycznych, edytorskich i innych form dziennikarskich. Podejście to opiera się na starszych praktykach, przede wszystkim na dziennikarstwie wspomaganym komputerowo (ang. *computer-assisted reporting, CAR*), które przez dziesięciolecia było stosowane głównie w USA. Inne określenia dla częściowo podobnych podejść to „dziennikarstwo precyzyjne” (ang. *precision journalism*), termin ukuty w książce Philippa Meyera pod tym właśnie tytułem, opublikowanej po raz pierwszy w 1972 r. Znaczenie i możliwości dziennikarstwa ukierunkowanego na dane

rośnie ze względu na wzrost zasobów informacyjnych i baz danych, które są dostępne zarówno w sposób wolny w sieci, jak też za pomocą rosnącej liczby usług i baz danych wyspecjalizowanych, komercyjnych itp.

Źródło: DataJournalism.com.

edukacja medialna – kształcenie umożliwiające ludziom zrozumienie środków masowego przekazu wykorzystywanych w społeczeństwie (w tym słowa drukowanego, grafiki, dźwięku, obrazu nieruchomego i ruchomego dostarczanego w dowolnej technologii) oraz nabywania umiejętności posługiwania się nimi w celu komunikowania się z innymi.

Źródło: Recommendations Addressed to the United Nations Educational Scientific and Cultural Organization UNESCO, UNESCO, Paris 1999, s. 273–274

e-learning lub e-nauka – nauczanie lub szkolenie przy użyciu technologii informatycznej. Oznacza wspomaganie procesu dydaktycznego za pomocą komputerów osobistych, smartfonów, tabletów (*m-learning*) i Internetu. Pozwala na ukończenie kursu, szkolenia, a nawet studiów bez konieczności fizycznej obecności w sali wykładowej. Uzupełnia również tradycyjny proces nauczania, budując *blended learning*.

Źródło: <https://pl.wikipedia.org/wiki/E-learning>

gerontechnologia (ang. *gerontechnology*) – rozwiązania technologiczne służące niezależnemu życiu oraz wzmacnianiu aktywności społecznej osób starszych w dobrym zdrowiu, komforcie i bezpieczeństwie. Definiowane jako wdrażanie idei pomysłnego starzenia się i wspieranie osób starszych w takich dziedzinach jak życie codzienne, komunikacja, zdrowie, bezpieczeństwo, mobilność i wypoczynek.

Źródło: Mendes, D., In Fonseca, C., In Lopes, M. J., In Garcia-Alonso, J. and In Murillo, J. M. (2020). *Exploring the role of ICTs in healthy aging*.

internet rzeczy, internet przedmiotów (ang. *internet of things, IoT*) – system połączonych wzajemnie komputerów, urządzeń mechanicznych i obiektów, które mają tzw. unikalne identyfikatory (UID, specjalne kody złożone z liczb, liter i znaków, przypisane każdej jednostce w systemie) oraz możliwość przesyłania danych przez sieć bez udziału człowieka. Ludzie mogą jednak wchodzić w interakcje z urządzeniami IoT, np. by je skonfigurować, przekazać instrukcje lub uzyskać dostęp do danych. Co ważne, rzeczą w internecie rzeczy nie musi być jedynie martwy przedmiot. Może nią także być człowiek z implantem do monitorowania pracy serca czy pies z wszczepionym chipem.

Źródło: <https://www.sztuczna inteligencja.org.pl/sloownik/>

kompetencje cyfrowe – kompetencje umożliwiające świadome i odpowiedzialne korzystanie z technologii cyfrowych, nabywanie umiejętności, które ich dotyczą w celu wykorzystania w pracy i w ramach funkcjonowania społecznego. Kompetencje te obejmują nie tylko umiejętność korzystania z informacji, danych, komunikowania się i korzystania z mediów, lecz również znajomość m.in. zasad bezpieczeństwa i prawa własności intelektualnej.

Źródło: Zalecenie Rady UE z dnia 22 maja 2018 r. w sprawie kompetencji kluczowych w procesie uczenia się przez całe życie (2018/C 189/01)

kompetencje kluczowe – kompetencje niezbędne do samorealizacji i rozwoju osobistego, czyniące z jednostki aktywnego obywatela, zdolnego do współdziałania w społeczeństwie i podjęcia pracy zarobkowej. Kompetencje te łączą wiedzę, umiejętności praktyczne oraz postawy społeczne odpowiednie do sytuacji.

Źródło: „Kompetencje kluczowe w uczeniu się przez całe życie – europejskie ramy odniesienia”, załącznik do zalecenia Parlamentu Europejskiego i Rady z dnia 18 grudnia 2006 r. w sprawie kompetencji kluczowych w procesie uczenia się przez całe życie, opublikowanego w Dzienniku Urzędowym Unii Europejskiej z dnia 30 grudnia 2006 r./L394.

krytyczne myślenie – postawa wyrażająca się w gotowości do rozpatrywania w przemyślany sposób problemów i spraw, które wchodzą w zakres doświadczenia jednostki, znajomość logicznych metod rozumowania i dociekania oraz pewna wprawa w stosowaniu tych metod.

Źródło: Edward M. Glaser, *An Experiment in the Development of Critical Thinking*, Teacher's College, Columbia University, 1941.

Według prof. dr hab. Jana Fazlagicia zdolność do krytycznego myślenia jest uznawana obecnie za jedną z najbardziej pożądaných kompetencji międzynarodowych. Wysoka zdolność do krytycznego myślenia jest przydatna pracownikom pracującym nad rozwiązaniami dotyczącymi AI.

mHealth (ang. mobile health) – dostarczanie i ułatwianie przekazywania informacji związanych ze zdrowiem za pośrednictwem telekomunikacji mobilnej i technologii multimedialnych, w tym telefonów komórkowych, tabletów i infrastruktury bezprzewodowej. Obejmuje szeroki zakres rozwiązań: od prostych aplikacji służących bezpośredniej komunikacji, po złożone systemy, które zdalnie koordynują i aktywnie zarządzają opieką nad pacjentem.

Źródło: Krohn, R., Metcalf, D. (2012). *mHealth From Smartphones to Smart Systems: From Smartphones to Smart Systems* (1st ed.). HIMSS Publishing. <https://doi.org/10.4324/9780367648008>

przetwarzanie języka naturalnego (ang. Natural Language Processing, NLP) – interdyscyplinarna dziedzina łącząca lingwistykę, informatykę, inżynierię informacyjną i sztuczną inteligencję. NLP zajmuje się interakcjami między komputerami a językami ludzkimi (naturalnymi), a w szczególności sposobami programowania komputerów w celu przetwarzania i analizowania dużych ilości danych w języku naturalnym.

Źródło: Jurafsky, D., Martin, J. *Natural Language Processing*: <https://web.stanford.edu/~jurafsky/slp3/>

rozszerzona rzeczywistość – AR (ang. augmented reality) – system łączący świat rzeczywisty ze światem generowanym komputerowo. Zazwyczaj wykorzystuje się obraz z kamery, na który nałożona jest, generowana w czasie rzeczywistym, grafika 3D. Istnieją także zastosowania rozszerzonej rzeczywistości wspomagające jedynie dźwięk (jak aplikacja RjDj na iPhone). Na przykład użytkownik AR może za pomocą półprzezroczystych okularów obserwować życie toczące się na ulicach miasta, jak również elementy wytworzone przez komputer i nałożone na rzeczywisty świat.

Źródło: https://pl.wikipedia.org/wiki/Rzeczywisto%C5%9B%C4%87_rozszerzona

rzeczywistość wirtualna – VR (ang. *virtual reality*), fantomatyka – obraz sztucznej rzeczywistości stworzony przy wykorzystaniu technologii informatycznej. Polega na multimedialnym kreowaniu komputerowej wizji przedmiotów, przestrzeni i zdarzeń. Może on reprezentować zarówno elementy świata realnego (symulacje komputerowe), jak i zupełnie fikcyjnego (gry komputerowe sciencefiction).

Źródło: https://pl.wikipedia.org/wiki/Rzeczywisto%C5%9B%C4%87_wirtualna

smart city – inteligentne miasto. Koncepcja inteligentnego miasta jest stosunkowo nowym spojrzeniem na funkcjonowanie współczesnych, nowoczesnych miast. Jest wynikiem postępu technologicznego i jednocześnie wzrostu świadomości ekologicznej społeczeństwa. Łączy w sobie trzy kluczowe obszary definiujące kierunek zmian – informatyzację miasta, cyfryzację oraz zrównoważony rozwój. Smart city to odpowiedź na potrzeby współczesnego społeczeństwa zamieszkującego obszary metropolitalne. Miasta tego typu pojawiły się jako efekt inteligentnego wykorzystania informacji cyfrowej, między innymi w obszarach takich jak edukacja i transfer wiedzy, mobilność, energetyka, środowisko, zdrowie czy usługi publiczne.

Źródło: Gieleciak, Z. i Szaflarski, K. *Zarządzanie inteligentnym miastem–smart city (na przykładzie miasta Tychy)*. Globalna Gospodarka, Zarządzanie, Prawo i Administracja Global Economy, Management, Law and Administration, 39.

styl uczenia się – charakterystyka procesu utrwalania, a także zmieniania stanu wiedzy i umiejętności. Ścisłe powiązany ze stylem uczenia się jest styl nauczania. Koncepcja stylów uczenia się jest bardzo popularna w środowiskach praktyków edukacji, natomiast nie istnieją żadne wyniki badań naukowych dowodzących pozytywnego związku pomiędzy stosowaniem przez nauczyciela koncepcji „stylów uczenia się” a wynikami nauczania uczniów.

Źródło: prof. dr hab. Jan Fazlagić.

synteza mowy – zbiór technik i metod przekształcenia tekstu zapisanego do postaci wypowiedzi o charakterze akustycznym, naśladującej mowę ludzką (ang. TTS – *Text-To-Speech*). Zwykle system tego typu wykorzystuje analizę tekstu NLP, analizę fonetyczną ciągu głosek z parametrami oraz układ syntezy niskiego poziomu wytwarzającej akustyczny sygnał mowy. Analiza fonetyczna polega na zamianie tekstu dostępnego w formie pisanej na ciąg fonemów z uwzględnieniem specyficznych zjawisk fonetycznych występujących w języku, takich jak intonacja, akcenty, ubezdźwięcznienie. Synteza akustycznego sygnału może odbywać się różnymi metodami, np. za pomocą odtwarzania i łączenia elementarnych dźwięków z pamięci komputera lub konkatenacyjnie, czyli przy wykorzystaniu nagranych próbek głosu lektora.

Źródło: ScienceDirect. Speech Synthesis. Pobrane z <https://www.sciencedirect.com/topics/computer-science/speech-synthesis>

system edukacji – zbiór instytucji, organizacji i innych osób prawnych oraz fizycznych zaangażowanych w kształcenie i wychowanie dzieci, młodzieży oraz osób dorosłych. W systemie edukacji funkcjonują podmioty publiczne oraz niepubliczne. System edukacji posiada struktury formalne i nieformalne, które wzajemnie się przenikają. Kluczową rolę w systemie edukacji odgrywa państwo, które realizuje przeważającą część działań związanych z funkcjonowaniem tego systemu.

systemy wsparcia decyzji klinicznych (ang. *Clinical Decision Support Systems*)

– oprogramowanie zaprojektowane w celu poprawy świadczenia opieki zdrowotnej poprzez wspieranie decyzji medycznych przez wyniki analizy: wiedzy klinicznej, informacji o pacjencie i innych danych dotyczących jego zdrowia. W zależności od typu mogą wykorzystywać w działaniu instrukcje warunkowe oparte na wiedzy eksperckiej jak i sztucznej inteligencji.

Źródła: 1. Osheroff, J.A., Teich, J.M., Levick, D., Saldana, L., Velasco, F.T., Sittig, D.F., Rogers, K.M., & Jenders, R.A. (2012). *Improving Outcomes with Clinical Decision Support: An Implementer's Guide* (2nd ed.). HIMSS Publishing. <https://doi.org/10.4324/9780367806125>
2. Deo RC. Machine Learning in Medicine. *Circulation*. 2015 Nov 17;132(20):1920-30. doi: 10.1161/CIRCULATIONAHA.115.001593. PMID: 26572668; PMCID: PMC5831252

sztuczna inteligencja oparta na współpracy (ang. *collaborative AI*)

– poddziedina sztucznej inteligencji, która zajmuje się tym, jak wielu agentów może współpracować w celu rozwiązywania problemów. Jest ona ściśle związana z teorią gier i systemami wieloagentowymi.

Źródła: 1. „Multiagent Systems: Algorithmic, Game-Theoretic, and Logical Foundations” by Yoav Shoham and Kevin Leyton-Brown.
2. „Artificial Intelligence: A Modern Approach” by Stuart Russell and Peter Norvig.

sztuczna kreatywność – termin pochodny od pojęcia sztucznej inteligencji. Uzasadnienie jego istnienia jest pochodną stopnia, w jakim rozróżniamy koncepcję inteligencji i kreatywności. Wiele koncepcji psychologicznych uznaje kreatywność jako autonomiczny albo półautonomiczny byt w stosunku do inteligencji. W związku z tym przyszłe badania nad sztuczną inteligencją doprowadzą do zmiany na dyscyplinę pod nazwą sztuczna kreatywność.

Źródło: prof. dr hab. Jan Fazlagić.

telemedycyna – forma świadczenia usług medycznych i opieki zdrowotnej łącząca w sobie elementy telekomunikacji, informatyki oraz medycyny. Telemedycynę odróżnia się od telezdrowia i eZdrowia, które odnoszą się do szerszego zakresu usług zdalnej opieki zdrowotnej niż telemedycyna. Telemedycyna dotyczy szczególności zdalnych usług klinicznych, podczas gdy telezdrowie i eZdrowie może odnosić się do zdalnych usług nieklinicznych. W telemedycynie brany jest pod uwagę również aspekt odpowiedzialności zawodowej podczas wykonywania świadczeń medycznych na odległość. Dzięki wykorzystaniu nowych technologii pomaga ona przełamywać bariery geograficzne, pozwalając na wymianę specjalistycznych informacji w postaci obrazów statycznych i dynamicznych (najwyższej jakości zdjęć EKG, USG, MRI). Pozwala również przeprowadzić diagnozę na odległość. Duże zastosowanie telemedycyna znajduje w środowisku chirurgicznym, które wykorzystuje ją do prowadzenia operacji na odległość. Nowoczesna technologia, wykorzystująca szybkie procesory i algorytmy do cyfrowego przetwarzania i kompresji sygnałów, umożliwia przesyłanie obrazów o wysokiej rozdzielczości, a także interaktywną transmisję audiowizualną z wyjątkową dokładnością i w czasie rzeczywistym.

Źródło: <https://pl.wikipedia.org/wiki/Telemedycyna>

test Turinga / odwrócony test Turinga

– test pozwalający ocenić, czy maszyna jest zdolna naśladować człowieka w takim stopniu, że nie można jej odróżnić od człowieka. Został opracowany w latach 50. XX w. przez genialnego angielskiego matematyka Alana Turinga. W 1950 roku Alan Turing zaproponował ten test w ramach badań nad stworzeniem sztucznej inteligencji – zamiar pełnego emocji

i w jego pojęciu bezsensownego pytania „Czy maszyny myślą?” na pytanie lepiej zdefiniowane.

Test wygląda następująco: sędzia (człowiek) prowadzi rozmowę w języku naturalnym z pozostałymi stronami. Jeśli sędzia nie jest w stanie wiarygodnie określić, czy któraś ze stron jest maszyną czy człowiekiem, wtedy mówi się, że maszyna przeszła test. Zakłada się, że zarówno człowiek, jak i maszyna próbują przejść test, zachowując się w sposób możliwie zbliżony do ludzkiego.

W odwróconym teście Turinga program komputerowy podejmuje tekstowy dialog z człowiekiem i innym komputerem. Zadaniem programu jest odróżnienie człowieka od komputera. Popularną wersją tego testu jest CAPTCHA (ang. *Completely Automated Public Turing test to tell Computers and Humans Apart*), z którą można się zetknąć w wielu serwisach internetowych. Najczęściej jest wyświetlany zniekształcony obraz losowo wybranych znaków, a człowiek ma wpisać z klawiatury znaki poprawnie odczytane z obrazu. W innej wersji należy wpisać rozwiązanie prostego równania. Oczekuje się przy tym, że komputer nie jest w stanie „odczytać” obrazka lub znaleźć rozwiązanie.

Źródło: <https://www.sztucznainteligencja.org.pl/slownik/>

transformer językowy (ang. *Language Transformer*) – rodzaj sztucznej inteligencji, której zadaniem jest przekształcanie jednego języka naturalnego na inny. Transformery są powszechnie stosowane w tłumaczeniach maszynowych i aplikacjach przetwarzania języka naturalnego.

Źródła: 1. „Natural Language Processing with Python” by Steven Bird, Ewan Klein, and Edward Loper.
2. „Foundations of Statistical Natural Language Processing” by Christopher D. Manning and Hinrich Schütze.

uczenie głębokie (ang. *deep learning*) – podkategoria uczenia maszynowego (ang. *machine learning*) polegająca na tworzeniu sieci neuronowych, które mają za zadanie udoskonalić technikę rozpoznawania głosu i przetwarzania języka naturalnego. Znajduje również zastosowanie w bioinformatyce i projektowaniu leków.

Źródło: https://pl.wikipedia.org/wiki/Deep_learning

umiejętności XXI wieku (*21st Century Skills*) – zespół postulatów wystosowanych do systemu edukacji, nakierowanych na rozwijanie specyficznych umiejętności powiązanych z potrzebami społeczeństwa i rynku pracy w XXI wieku. Termin *umiejętności XXI wieku* służy także wyraźnemu podkreśleniu konieczności reformy systemów edukacji tak, aby odeszły one od modelu edukacji wypracowanego w XIX i XX wieku.

VR (ang. *virtual reality*) – patrz: rzeczywistość wirtualna.

Prezentowana monografia koncentruje uwagę Czytelnika na szansach, zagrożeniach i wyzwaniach, jakie niesie ze sobą wykorzystanie sztucznej inteligencji w szeroko rozumianej edukacji. Autorzy umiejętnie przedstawili swoje rozważania, zamieszczając je w ramach czterech obszernych części tematycznych, które zatytułowano „Społeczeństwo i państwo”, „Edukacja”, „Przemysł” i „Usługi”. Uporządkowanie rozważań w sekcje sygnalizuje, jak wielowymiarowa i wieloaspektowa jest dyskusja nad sztuczną inteligencją, w jak wielu sferach można doszukiwać się szans i zagrożeń z nią związanych. Jednocześnie wskazuje, jak szerokie może być pole jej zastosowań, kiedy weźmie się pod uwagę potrzeby edukacyjne.

Interdyscyplinarne podejście do zagadnienia sztucznej inteligencji, które zastosowano w opracowaniu, świadczy także o tym, że sztuczna inteligencja zasługuje na miano megatrendu, który oddziałuje na społeczeństwo i gospodarkę, w tym na edukację. Wartość prezentowanej publikacji ma nie tylko aspekt poznawczy, ale także praktyczny. Przedstawione rozważania zwracają uwagę tych, którzy kształtują politykę w sektorze edukacji, nauczycieli, instytucji szkolących nauczycieli oraz reprezentantów administracji oświatowej zarówno na nowe wyzwania dla edukacji, jak i nowe możliwości.

Prof. dr hab. Barbara Jankowska

Instytut Badań Edukacyjnych

ul. Górczewska 8

01-180 Warszawa

tel. + 48 22 241 71 00

www.ibe.edu.pl

www.kwalifikacje.gov.pl

ISBN 978-83-67385-10-7

Projekt współfinansowany ze środków Unii Europejskiej w ramach Europejskiego Funduszu Społecznego.

Egzemplarz bezpłatny