

## SZTUCZNA INTELIGENCJA

Początki debaty na temat AI sięgają konferencji w Dartmouth w 1956 roku<sup>33</sup>, w której między innymi brali udział tacy badacze, jak: Claude E. Shannon z Bell Labs (teoria informacji), Marvin Minsky z Harvardu (matematyk), Mellon Herbert Simon z Carnegie (ekonomista), John McCarthy z Harvardu (psycholog), George Miller (znany z prac nad ludzką pamięcią) oraz John Nash (matematyk, laureat nagrody Nobla). Termin „sztuczna inteligencja” sformułował wówczas McCarthy, nadając oficjalnie tę nazwę nowemu projektowi inżynierii inteligentnego życia. Założenia inicjatywy były proste: zbadać naturę zdolności poznawczych (myślenia), zaprojektować program odtwarzający te zdolności, a następnie wdrożyć i przetestować jego działanie na powstających komputerach<sup>34</sup>. SI miała być nauką „o tworzeniu maszyn zdolnych do wykonywania zadań, które wymagałyby inteligencji, gdyby były wykonywane przez ludzi lub w mniejszym, słabszym sensie, przez zwierzęta”<sup>35</sup>. Obecnie pod pojęciem SI rozumie się multidyscyplinarną dziedzinę inżynierii, obejmującą robotykę, sieci neuronowe, uczenie maszynowe, A-Life oraz logikę rozmytą. Jako dziedzina badań naukowych korzysta ona z dorobku informatyki (ang. computer science), neurokognitywistyki, biologii, teorii systemów i organizacji, filozofii i neuropsychologii<sup>36</sup>. Za tymi dość skomplikowanymi terminami w praktyce kryją się pragmatyczne cele. Są to: opracowywanie modeli inteligentnych zachowań oraz budowanie programów zdolnych te zachowania symulować bądź odtwarzać<sup>37</sup>. Sztuczna inteligencja za-

---

<sup>33</sup> Por. E.L. L a r s o n, *The Myth of Artificial Intelligence: Why Computers Can't Think the Way We Do*, The Belknap Press of Harvard University Press, Cambridge, Massachusetts, London 2021, s. 50.

<sup>34</sup> Tamże T. W a l s h, *To żyje! Sztuczna inteligencja. Od logicznego fortepianu do zabójczej broni*, Wydawnictwo Naukowe PWN, Warszawa 2018, s. 32n.; M. S u c h a c k a, R. M u s t e r, M. W o j e w o d a, *Human and Machine Creativity: Social and Ethical Aspects of the Development of Artificial Intelligence*, „Creativity Studies” 14(2021) nr 2, s. 434.

<sup>35</sup> C.H. H o f f m a n, *Is AI Intelligent? An Assessment of Artificial Intelligence, 70 years after Turing*, „Technology in Society” 68(2022), s. 2.

<sup>36</sup> Por. A. P r z e g a l i Ń s k a, P. O k s a n o w i c z, *Sztuczna inteligencja. Nieludzka, arcyłudzka*, Wydawnictwo Znak, Kraków 2020, s. 43.

<sup>37</sup> Por. tamże.

tem to „określenie programu komputerowego, który zamiast wykonywać listę dokładnych instrukcji, wykorzystuje zaawansowane modele statystyczne do tego, żeby rozwiązać zadanie. Inteligencja w tym przypadku oznacza, że program na podstawie zbioru danych zawierającego przykłady zadań i poprawne odpowiedzi – sam znajduje występujące między nimi zależności (wzorce)”<sup>38</sup>. Od samego początku było oczywiste, że prace nad SI nie będą miały charakteru jednorodnego, wyróżniano sztuczną inteligencję tak zwaną słabą (ang. weak artificial intelligence) lub inaczej wąską (ang. narrow artificial intelligence, ANI) i silną (ang. strong artificial intelligence), określaną także mianem pełnej (ang. full) albo uniwersalnej (ang. general artificial intelligence, AGI)<sup>39</sup> oraz superinteligencję (osobliwość, ang. singularity)<sup>40</sup>. W słabej (wąskiej) AI chodzi o doskonalenie wykonania danej czynności; do niej zalicza się aplikacje specjalizujące się w jednym obszarze. Klasycznym przykładem jest Deep Blue IBM (ANI). Silny (uniwersalny, pełny) jest to stopień skomplikowania oprogramowania, przy którym aplikacje mają osiągać poziom ludzkiej inteligencji, czyli móc myśleć abstrakcyjnie i logicznie, szybko uczyć się, a także zdobywać wiedzę na podstawie doświadczenia (AGI). Natomiast w przypadku superinteligencji (osobliwości) komputery mają stać się autonomiczne i sprawniejsze intelektualnie od człowieka. Obecnie jesteśmy na poziomie pierwszym, używamy wyspecjalizowanych aplikacji, które stanowią wsparcie w wąskich obszarach działania. Nie jest to jednak równoznaczne z tym, że dysponujemy fundamentem pod silną sztuczną inteligencję. Sytuację tę trafnie diagnozuje Erick J. Larson w *Myth of Artificial Intelligence: Why Computers Can't Think the Way We Do*. Jego zdaniem z powodzeniem stosujemy aplikacje wyposażone w wąską inteligencję, które korzystają z mocy obliczeniowej cyfrowej technologii i dużej ilości danych, ale nie znaczy to, że dokonujemy stopniowego postępu, lecz raczej zbieramy nisko wiszące owoce. I na tym etapie prac nie ma przejścia od jednego do drugiego, nie istnieje żaden algorytm dla inteligencji uniwersalnej. Mamy także obiektywne powody, by sceptycznie podchodzić do tego, że taki algorytm powstanie w wyniku dalszych wysiłków nad systemami głębokiego uczenia<sup>41</sup>, chociaż wciąż jest nadzieja na wypracowanie takiego algorytmu<sup>42</sup>.

<sup>38</sup> *Sztuczna inteligencja non-fiction*, red. A. Obem, K. Szymielewicz, Fundacja Panoptykon, Warszawa 2020, s. 7.

<sup>39</sup> Por. J.R. S e a r l e, *Mind, Brains, and Program*, „The Behavioral and Brain Sciences” 3(1980) nr 3, s. 417; A.C. N e u b a u e r, *The Future of Intelligence Research in Age of Artificial Intelligence – With a Special Consideration of the Philosophical Movements of Trans- and Posthumanism*, „Intelligence” 87(2021), s. 5; L a r s o n, dz. cyt., s. 2.

<sup>40</sup> Zob. R. K u r z w e i l, *The Singularity is Near: When Humans Transcend Biology*, Viking Penguin, London, New York 2005.

<sup>41</sup> Por. L a r s o n, dz. cyt., s. 2.

<sup>42</sup> Zob. P. D o m i n g o s, *Master Algorithm: How the Quest for the Ultimate Learning Machine Will Remake Our World*, Basic Books, New York 2015.

Co można uznać za obiektywnie istniejącą trudność? Wydaje się, że problem tkwi w technicznym odtworzeniu jednego z kluczowych sposobów ludzkiego wnioskowania, które Charles S. Peirce określał mianem abdukcji<sup>43</sup>. Ze względu na wagę tego zagadnienia w kontekście niniejszych rozważań jego opis zostanie nieco rozszerzony. Ten rodzaj rozumowania „polega na tym, by w obliczu zaskakującego zjawiska szukać hipotezy, z której można dedukcyjnie wyprowadzić to, że takie zjawisko zajdzie”<sup>44</sup>. Jest to zatem testowanie hipotez poprzez próbkowanie możliwych przewidywań, które mogą być na nich oparte. Abdukcja jest potrzebna, gdy pojawiają się fakty sprzeczne z tym, czego powinniśmy się spodziewać. Wyjaśnienie musi być taką propozycją, która prowadziłaby do przewidywania zaobserwowanych faktów. Na przykład dzięki abdukcji możemy odpowiadać na pytania typu: czy woda przestała się lać, bo ktoś zakręcił kran, czy zbiornik się wyczerpał, a może chwilowo doszło do jakiegoś niekontrolowanego wycieku i woda cieknie, ale gdzie indziej? lub czy gdybym wtedy zachowała się inaczej, dzisiaj łatwiej byłoby mi zmierzyć się z tą sytuacją? Z technicznego punktu widzenia wnioskowanie próbujące przewidywać zdarzenia, w takim sensie „niezgodne z faktami”, bo ich zaistnienie jest jedynie rozważane, wymaga rozwijania równań algorytmicznych o dodatkowe składniki, które uwzględniałyby informacje o zmiennych pojawiających się w efekcie zmiany innych zmiennych. A to dotyczy przewidywania skutków działania i wyobraźni przeczącej faktom<sup>45</sup>. Żadna maszyna obecnie nie dysponuje takim potencjałem<sup>46</sup>.

Generalnie SI bazuje na stosowaniu znanych od starożytności metod pozyskiwania wiedzy, dedukcji (odgórna) oraz indukcji (oddolna). „Odgórne podejście odgrywało znaczącą rolę w pierwszych sztucznych inteligencjach, a w pierwszej dekadzie XXI wieku przeżyło nawrót w formie probabilistycznych (bayesowskich) modeli generatywnych. [...] Bayesowskie techniki ułatwiają określenie, która z dwóch hipotez jest bardziej prawdopodobna [...], ale żaden system nie potrafi efektywnie rozważyć wszystkich”<sup>47</sup>. Oddolna metoda natomiast opiera się na technikach wykrywania statystycznych schematów w dużych zbiorach danych. Polega ona na zapewnieniu programowi dostępu do danych, z których wyłuskuje znaczące wzory. Rozwój SI bazujący na tej metodzie stał się możliwy

<sup>43</sup> Por. Ch.S. Peirce, *The Essential Peirce. Selected Philosophical Writings*, t. 2, (1993-1913), red. Nathan Houser, Indiana University Press, Bloomington, Indianapolis 1998, s. 95.

<sup>44</sup> A. Grobler, *Metodologia nauk*, Wydawnictwo Aureus, Wydawnictwo Znak, Kraków 2006, s. 102.

<sup>45</sup> Por. J. Pearl, *Ograniczenia nieprzejrzyście uczących się maszyn*, w: *Człowiek na rozdrożu. Sztuczna inteligencja – 25 punktów widzenia*, red. J. Brockman, tłum. M. Machnik, Helion, Gliwice 2020, s. 37n.

<sup>46</sup> Zob. Larson, dz. cyt.

<sup>47</sup> A. Gopnik, *AI kontra czterolatki*, w: *Człowiek na rozdrożu*, s. 246n.

dzięki technologicznemu dostępowi do danych, czyli zjawisku tak zwanego Big Data, a w tym przypadku kluczowe są korelacje.

Każde z tych dwóch podejść ma wady i zalety, które wzajemnie się uzupełniają. W metodzie oddolnej program nie wymaga wiedzy początkowej. Konieczny jest jedynie dostęp do danych. Z kolei podejście odgórne wymaga zaimplementowania dużej ilości „wiedzy początkowej”, która w przypadku każdego z programów okazywała się niewystarczająca. Stąd obecnie prace wielu badaczy z zakresu SI skupiają się na połączeniu obu metod. Jednak tym, co wydaje się najbardziej problematyczne, jest odkrywanie przez algorytmy głębokiego uczenia jedynie powierzchownych regularności statystycznych, a nie wysokopoziomowych pojęć abstrakcyjnych. Sztuczne sieci neuronowe nie osiągnęły jeszcze tego, co stanowi ważny aspekt ludzkiego uczenia się i rozumowania, a mianowicie możliwości tworzenia abstrakcyjnego modelu świata. Na razie SI jest wyposażona w filtry do rozpoznawania wzorów i ich specjalistycznego stosowania.