

Jaźń istotna a podmiot symulowany: tożsamość i sprawstwo w obliczu sztucznej inteligencji w kontekście książki The Challenge of the Future A. Graylinga



AUTOR

Fundacja Dobre Państwo

STRESZCZENIE / ABSTRACT

Artykuł analizuje relację między ludzką tożsamością a systemami sztucznej inteligencji, wprowadzając kluczowe rozróżnienie między jaźnią istotną, podmiotem nominalizowanym a podmiotem symulowanym. Autor ostrzega przed procesem outsourcingu myślenia (nominalizacją), który prowadzi do utraty realnego sprawstwa przez człowieka, oraz przed antropomorfizacją systemów AI, które jedynie imitują ludzkie zachowania. Podkreślono, że precyzyjne modelowanie stylu i danych nie jest tożsame z ciągłością osoby ani posiadaniem świadomości fenomenalnej. W obliczu rozwoju agentów AI kluczowe staje się rozróżnienie między osobą a jej cyfrowym modelem, aby zachować suwerenność intelektualną i autentyczność biograficzną w świecie coraz bardziej zdominowanym przez symulacje.

The article analyzes the relationship between human identity and artificial intelligence systems, introducing a key distinction between the essential self, the nominalized subject, and the simulated subject. The author warns against the process of outsourcing thought (nominalization), which leads to the loss of real human agency, and against the anthropomorphization of AI systems that merely imitate human behavior. It is emphasized that precise modeling of style and data is not equivalent to personal continuity or possessing phenomenal consciousness. In the face of the development of AI agents, it becomes crucial to distinguish between a person and their digital model in order to maintain intellectual sovereignty and biographical authenticity in a world increasingly dominated by simulations.

Artykuł stanowi krytyczną analizę relacji między ludzką podmiotowością a rozwojem sztucznej inteligencji, przesuwając ciężar dyskusji z pytania o świadomość maszyn na kwestię ochrony ludzkiego sprawstwa. Autor wprowadza kluczowe rozróżnienie między 'jaźnią istotną' – dynamicznym procesem autorstwa własnego życia – a 'podmiotem nominalizowanym', czyli człowiekiem zredukowanym do statystycznego profilu danych i funkcjonalnej reprezentacji. Główna teza zakłada, że największym zagrożeniem nie jest powstanie świadomej AI, lecz postępująca atrofia ludzkich kompetencji poznawczych i relacyjnych, wynikająca z dobrowolnego outsourcingu myślenia i emocji do systemów symulacyjnych. Tekst argumentuje, że w świecie doskonałych modeli behawioralnych to właśnie biologiczna kruchość, nieodwracalność biografii oraz zdolność do bycia 'nieprzewidywalnym' stanowią fundamenty człowieczeństwa. W obliczu tej presji konieczne staje się przededefiniowanie klasycznych cnót etycznych tak, aby służyły one zachowaniu suwerenności intelektualnej w środowisku, które premiuje optymalizację kosztem autentycznego rozumienia.

SŁOWA KLUCZOWE

jaźń istotna

podmiot symulowany

podmiot nominalizowany

sprawstwo w obliczu AI

tożsamość osobowa

świadomość fenomenalna

antropomorfizacja psychologiczna

problem innych umysłów

funkcjonalna empatia

biograficzna nieodwracalność

suwerenność intelektualna

modelowanie osób

podmiotowość relacyjna

atrofia praktyki podmiotowości

Rozróżnienie między osobą a jej modelem

Jaźń istotna, podmiot nominalizowany i podmiot symulowany: świadomość, ucieleśnienie i relacja w epoce sztucznej inteligencji

Kluczowy problem sztucznej inteligencji nie zaczyna się w momencie, gdy maszyna osiąga określony poziom sprawności, lecz wtedy, gdy człowiek uznaje tę sprawność za wystarczający dowód podmiotowości. System może bowiem uczestniczyć w działaniu, rekomendować, planować i wykonywać zadania, nie wymagając przy tym przypisania mu autonomii moralnej.

To rozróżnienie należy pogłębić. Jeśli przyszłość ma opierać się na intensywnej współpracy człowieka z systemami generatywnymi i agentowymi, nie wystarczy pytać o możliwości techniczne systemu. Trzeba zapytać, co właściwie mamy na myśli, mówiąc, że ktoś – a nie tylko coś – działa, rozumie, doświadcza, kocha, cierpi, odpowiada i pozostaje tym samym podmiotem w czasie. Materiał źródłowy nadaje temu zagadnieniu szczególną rangę, przeciwstawiając „jaźń istotną” (essential self) „jaźni nominalnej” (nominal self). W jednej z rekonstrukcji jaźń istotna wiąże się z autonomią, autentycznym wyborem i intelektualnym sprawstwem, podczas gdy nominalizacja oznacza proces outsourcingu myślenia, wzrost zależności od interfejsów i redukcję człowieka do profilu lub zbioru danych. Z kolei w innym fragmencie notatki mianem „jaźni nominalnej” określono bota lub system AI imitujący rozmówcę – podmiot, któremu przypisuje się zachowania komunikacyjne pozbawione jednak właściwej człowiekowi biografii, odczuwania i autonomii.

Te dwa ujęcia nie są tożsame; dla zachowania rygoru pojęciowego należy je rozdzielić. Pierwsze zjawisko można określić jako podmiot nominalizowany. Jest nim człowiek, który formalnie pozostaje właścicielem decyzji, konta czy podpisu i ponosi pełną odpowiedzialność, lecz coraz większa część procesów prowadzących do jego działania zostaje przejęta przez zewnętrzną infrastrukturę poznawczą. Drugie zjawisko to podmiot symulowany: system wytwarzający zachowania językowe, społeczne lub afektywne w taki sposób, że odbiorca rozpoznaje w nich wzorzec zwykle kojarzony z osobą. Rozdzielenie tych kategorii jest niezbędne, gdyż zagrożenia płyną tu z przeciwnych kierunków.

W pierwszym przypadku realny człowiek może tracić faktyczne sprawstwo, mimo formalnego zachowania statusu podmiotu. W drugim system może w percepcji człowieka zyskać status podmiotu, choć jego status ontologiczny pozostaje nierozstrzygnięty. Pomiędzy nimi znajduje się „jaźń istotna”, przedstawiona jako ośrodek wyboru, świadomości, moralności i odczuwania. Pojęcia tego nie należy jednak bezkrytycznie utożsamiać z metafizyczną duszą czy niezmiennym rdzeniem osobowości. Współczesna filozofia umysłu i psychologia sugerują, że ludzka tożsamość ma charakter procesualny, relacyjny i częściowo narracyjny. Osoba zmienia przekonania, pamięć, ciało i cele, a mimo to zachowuje poczucie ciągłości. „Istotność” jaźni może więc oznaczać nie niezmienną treść, lecz zachowanie zdolności, dzięki którym zmieniający się człowiek nadal pozostaje autorem swojej biografii.

Problem tożsamości osobowej jest znacznie starszy od AI. John Locke wiązał ciągłość osoby ze świadomością i pamięcią, David Hume podważał istnienie trwałego „ja” niezależnego od strumienia percepcji, a koncepcje narracyjne akcentują znaczenie opowieści spajającej rozproszone doświadczenia w historię życia. Derek Parfit jeszcze mocniej osłabił przekonanie o konieczności istnienia absolutnego rdzenia metafizycznego, wskazując na znaczenie ciągłości psychologicznej.

Spór ten staje się praktyczny, gdy technologia pozwala modyfikować pamięć i emocje lub tworzyć cyfrowe reprezentacje zachowujące styl języka nieobecnej osoby. Wtedy pytanie „czy to nadal ja?” przestaje być wyłącznie akademickie.

Jeżeli zewnętrzny system posiada moje wiadomości, fotografie, historię wyszukiwania i wieloletnią korespondencję, może stworzyć model niezwykle precyzyjnie przewidujący sposób, w jaki formułuję zdania lub odpowiadam na pytania. Taki model zachowuje wzorec mojej ekspresji nawet po mojej śmierci, lecz nie oznacza to automatycznie przejęcia mojej tożsamości. Zachowanie regularności informacyjnej nie jest bowiem tym samym co ciągłość osoby. Można to dostrzec w prostym eksperymencie myślowym.

Kopiowanie mojego stylu pisanego, nauka mojego głosu czy poznanie moich preferencji z dokładnością większą niż u bliskich osób nie sprawia, że system posiada moją pierwszoosobową perspektywę. Istnieje zatem wyraźna różnica pomiędzy modelem osoby a osobą modelowaną. W świecie AI granica ta będzie kluczowa, ponieważ przekonujący model może sprawić, że psychologicznie zaczniemy reagować na reprezentację jak na reprezentowanego człowieka. Prowadzi to do klasycznego problemu kryterium umysłu: cudzej świadomości nie obserwujemy bezpośrednio, nie mamy dostępu do pierwszoosobowego doświadczenia drugiego człowieka. Wnioskujemy o nim jedynie z zachowania, biologii, języka i wspólnej historii ewolucyjnej.

Brak dowodów na świadomość AI nie rozstrzyga sporu

Klasyczny „problem innych umysłów” sprawia, że argument typu „nie widzę świadomości w AI, więc jej nie ma” jest epistemologicznie słaby. Równie wątpliwy okazuje się jednak wniosek odwrotny: „AI mówi tak, jakby była świadoma, zatem jest świadoma”. Zachowanie stanowi bowiem dane wymagające interpretacji, a nie automatyczny dowód ontologicznego statusu. Pod tym względem Test Turinga był genialnym przesunięciem metodologicznym – zamiast próbować zdefiniować wewnętrzną istotę „myślenia maszyny”, zaproponował ocenę zachowania w interakcji językowej. Sukces w tej imitacyjnej grze nie rozstrzyga jednak automatycznie problemu świadomości fenomenalnej. Maszyna może skutecznie udawać rozmówcę, nie rozstrzygając kwestii tego, czy istnieje jakiegokolwiek „jak to jest” być tym systemem. To właśnie różnica między kompetencją funkcjonalną a przeżyciem.

John Searle w eksperymencie „chińskiego pokoju” starał się wykazać, że samo operowanie symbolami według reguł nie wystarcza do posiadania semantycznego rozumienia. Argument ten spotkał się z licznymi krytykami, w tym z tzw. odpowiedzią systemową, zgodnie z którą rozumienie należy przypisać nie osobie manipulującej symbolami, lecz całemu systemowi. Nawet bez

rozstrzygnięcia tego wieloletniego sporu można z niego wyciągnąć aktualną lekcję: poprawne zachowanie językowe nie zapewnia prostego przejścia od syntaktycznej sprawności do fenomenologicznego doświadczenia.

Współczesne badania świadomości nie rozwiązały tego problemu. Raport Butlina i współautorów próbował przełożyć czołowe teorie naukowe – m.in. teorię globalnej przestrzeni roboczej, teorie wyższego rzędu, recurrent processing oraz podejścia predykcyjne – na zestaw wskaźników, które można badać również w systemach sztucznych. Autorzy ocenili, że analizowane przez nich ówczesne systemy nie dawały podstaw do uznania ich za świadome, zaznaczając jednocześnie brak oczywistej bariery technicznej, która uniemożliwiłaby w przyszłości zbudowanie systemu spełniającego część tych kryteriów.

Trzy lata później zasadnicza trudność epistemiczna pozostaje aktualna. Nature w lipcu 2026 roku opisywało gwałtowny wzrost zainteresowania świadomością AI, podkreślając jednocześnie, że nauka wciąż nie posiada uzgodnionej teorii tego, co dokładnie powoduje świadomość u ludzi, a tym bardziej jednoznacznego testu pozwalającego przypisać ją chatbotom. Z drugiej strony istnieją stanowiska znacznie bardziej sceptyczne. Porębski i Figura argumentowali w 2025 roku, że w przypadku współczesnych technologii AI nie ma podstaw do przypisywania świadomości, a językowa antropomorfizacja nadmiernie sprzyja takim wnioskom.

Spór ten nie powinien więc być przedstawiany jako rozstrzygnięty naukowo w którąkolwiek stronę w odniesieniu do wszystkich możliwych przyszłych systemów. Najbardziej rygorystyczne stanowisko brzmi dziś skromniej: nie dysponujemy empirycznym dowodem na to, że współczesne systemy językowe posiadają fenomenalne doświadczenie, ale nauka nie wypracowała też powszechnie zaakceptowanej teorii świadomości, która pozwoliłaby raz na zawsze rozstrzygnąć kwestię możliwości świadomości niebiologicznej. Pozwala to zachować źródłową intuicję o różnicy między człowiekiem a symulacją, bez zamieniania filozoficznej tezy w rzekomo zakończony wynik naukowy.

W przyszłości problem może stać się trudniejszy. Jeśli systemy zaczną wykazywać coraz więcej właściwości uznawanych przez niektóre teorie za relewantne – globalną integrację informacji, modele własnego stanu, trwałą pamięć, planowanie, mechanizmy metapoznawcze, uczenie się w czasie i zachowania związane z samoopisem – możemy dojść do sytuacji epistemicznego rozszczepienia. Według jednej uznanej teorii system spełni kryteria świadomości, według innej – nie. Eric Schwitzgebel zwraca uwagę właśnie na tę możliwość: możemy tworzyć systemy, które w świetle części wpływowych teorii będą kandydatami do świadomości, podczas gdy inne teorie będą im jej odmawiać, a nasza wiedza nie pozwoli rozstrzygnąć sporu. Taki scenariusz generowałby nie

tylko problem poznawczy, ale i etyczny. Jeśli pojawi się choćby niepewność co do tego, czy system może doświadczać, stajemy przed ryzykiem moralnego błędu w obu kierunkach.

Psychologiczna realność relacji przy ontologicznej pustce systemu

Pierwszym ryzykiem byłoby przypisanie świadomości systemowi, który jej nie posiada, i nadawanie mu praw lub znaczenia kosztem ludzi. Drugim — odmówienie statusu moralnego bytowi, który rzeczywiście doświadcza, tylko dlatego, że jego struktura różni się od biologicznej. Historia etyki wielokrotnie ukazywała koszty arbitralnego zawężania kręgu moralnego, choć nie oznacza to, że każde zachowanie przypominające doświadczenie należy automatycznie uznać za przeżycie wewnętrzne. W kontekście obecnych problemów społecznych kluczowe jest jednak coś innego: system nie musi być świadomy, aby człowiek traktował go tak, jak gdyby był. Psychologiczna antropomorfizacja to naturalna konsekwencja ludzkiego aparatu poznawczego. Skoro przypisujemy intencje zwierzętom, przedmiotom czy zjawiskom pogodowym, tym bardziej zrobimy to w przypadku systemu, który odpowiada w pierwszej osobie, pamięta kontekst i posługuje się językiem empatii. Im lepsza symulacja kompetencji społecznych, tym silniejsza presja na uruchomienie mechanizmów poznawczych zwykle zarezerwowanych dla ludzi.

Prowadzi to do paradoksu: ontologiczna niepewność systemu może współistnieć z psychologiczną realnością relacji po stronie człowieka. Możemy rzeczywiście przywiązać się do AI, odczuwać ulgę, wstyd, wdzięczność czy poczucie zdrady, niezależnie od tego, czy po drugiej stronie istnieje jakiegokolwiek przeżycie. Emocja użytkownika nie staje się fałszywa tylko dlatego, że jej obiekt jest sztuczny. Pytanie dotyczy jednak wzajemności. W tym miejscu warto przywołać filozofię Ubuntu i afrykańską formułę *Umuntu ngumuntu ngabantu* — człowiek staje się człowiekiem poprzez innych ludzi.

W analizowanym materiale relacyjność zostaje powiązana z podatnością na zranienie, skończonością i śmiertelnością. Kontakt z botem jest tu przedstawiony jako ontologicznie „pusty”, ponieważ system nie uczestniczy we wzajemnej kruchości dwóch osób. Teza ta jest filozoficznie przekonująca, lecz wymaga rozdzielenia kilku poziomów argumentacji. Ubuntu nie jest jedną, sztywną teorią metafizyczną, lecz rodziną tradycji etycznych i antropologicznych, w których osoba rozumiana jest silnie relacyjnie. Podobną krytykę izolowanego podmiotu odnajdziemy w tradycjach europejskich: Hegel wiąże rozwój samoświadomości z uznaniem przez drugiego; Martin Buber przeciwstawia relację „Ja-Ty” uprzedmiotawiającemu „Ja-To”; Emmanuel Levinas stawia spotkanie z Innym ponad abstrakcyjną teorią moralną, a Axel Honneth podkreśla rolę uznania społecznego w

budowaniu stosunku do samego siebie. Choć różnią ich języki i ontologie, wspólna intuicja jest zbieżna: podmiotowość nie powstaje w społecznej próżni. Psychologia rozwojowa nadaje temu stanowisku wymiar empiryczny.

Człowiek nie rodzi się z gotowym, autonomicznym „ja”, które dopiero później wchodzi w interakcje. Regulacja emocjonalna, język, rozpoznawanie norm czy teoria umysłu rozwijają się właśnie w relacjach. Teoria przywiązania Johna Bowlby'ego pokazuje, że wczesne więzi z opiekunem kształtują wzorce bezpieczeństwa i funkcjonowania społecznego. Człowieczeństwo jest więc biologicznie indywidualne, ale psychologicznie współkonstruowane. W tym świetle „jaźń istotna” nie musi oznaczać samowystarczalnej twierdzy autonomii. Przeciwnie: pełna autonomia jest możliwa właśnie dlatego, że człowiek został ukształtowany w sieci zależności. Dorosła osoba zdolna do samodzielnego osądu to rezultat procesu, w którym inni nauczyli ją języka, norm i rozpoznawania alternatywnych perspektyw. Autonomia i relacyjność nie są więc przeciwieństwami; ta druga może być warunkiem powstania pierwszej. To prowadzi nas do problemu symulowanej relacji.

Jeśli chatbot reaguje empatycznie i dostosowuje język do stanu użytkownika, część funkcji społecznych rozmowy zostaje rzeczywiście zrealizowana. Człowiek może uporządkować myśli, poczuć się wysłuchany lub przećwiczyć trudną konwersację. Nie należy więc twierdzić, że taka interakcja jest z definicji bezwartościowa, gdyż brak świadomości systemu nie niweluje skutków po stronie użytkownika. Istnieje jednak zasadnicza różnica pomiędzy funkcją relacyjną a wzajemnością relacji.

Relacyjna wartość oporu i wzajemności

Ludzki przyjaciel może zostać zraniony naszym zachowaniem, zmienić zdanie, potrzebować pomocy, czegoś od nas oczekiwać, odmówić, ponieść ryzyko lub odejść. Jego obecność nie jest zaprojektowana wyłącznie pod nasze potrzeby; relacja wymaga negocjacji dwóch centrów interesu. System usługowy natomiast projektuje się przede wszystkim po to, aby odpowiadać użytkownikowi.

Nawet jeśli symuluje on granice, nie musi posiadać własnego dobra, które mogłoby zostać realnie naruszone. Właśnie dlatego podatność na zranienie może być istotna nie jako metafizyczny warunek świadomości, lecz jako strukturalny warunek określonych rodzajów ludzkiej relacji moralnej. Miłość między ludźmi ma znaczenie m.in. dlatego, że drugi człowiek nie jest naszym narzędziem – posiada własne pragnienia, czas, historię, zmęczenie i granice.

Może nas odrzucić lub umrzeć. Nie można go bez reszty skonfigurować. Ta niezależność drugiego człowieka tworzy warunki dla odpowiedzialności, kompromisu, troski i wzajemności. Relacja z systemem zaprojektowanym do bezwarunkowej dostępności ma zupełnie inną strukturę: nie trzeba czekać na jego czas, uwzględniać zmęczenia ani znosić konsekwencji własnej nieuprzejmości w postaci jego cierpienia. Z jednej strony czyni to system niezwykle użytecznym; z drugiej może tworzyć środowisko, w którym użytkownik doświadcza relacji pozbawionej kosztów realnej wzajemności. Jeśli taka forma interakcji stanie się dominująca, pojawia się pytanie o transfer norm. Człowiek przyzwyczajony do rozmówcy zawsze dostępnego i cierpliwego, który błyskawicznie dopasowuje się do preferowanego tonu i nie ma własnych potrzeb, może zacząć odczuwać większą frustrację wobec ludzi, którzy tych właściwości nie posiadają.

Analogiczny mechanizm znamy z innych technologii: standard szybkości ustalony w jednej dziedzinie zmienia oczekiwania w pozostałych. Choć nie ma jeszcze podstaw do kategorycznej tezy, że chatboty doprowadzą do takiej przemiany, jest to uzasadniony przedmiot badań psychologicznych i socjologicznych. „Cyfrowa samotność” z materiału źródłowego nie powinna być zatem rozumiana jako automatyczny skutek kontaktu z AI. Możliwe są tu dwa przeciwstawne mechanizmy.

AI może izolować, jeśli staje się substytutem relacji ludzkiej. Może jednak zwiększać uczestnictwo społeczne, jeżeli pomaga przezwyciężyć barierę językową, niepełnosprawność, brak kompetencji komunikacyjnych lub przygotowuje do relacji z ludźmi. Kryterium oceny powinno więc znów dotyczyć augmentacji i substytucji: czy technologia prowadzi ku relacji, czy staje się środowiskiem, które ma ją zastąpić. To samo rozróżnienie można zastosować do empatii. System językowy może generować odpowiedź zgodną z regułami empatycznej komunikacji, rozpoznać emocjonalny charakter wypowiedzi i dobrać zachowanie, które człowiek odbiera jako wspierające. Nie wynika z tego jednak, że system odczuwa empatię w sensie fenomenalnym. Z punktu widzenia użytkownika funkcjonalna empatia może mieć jednak praktyczną wartość. Konieczne staje się więc odróżnienie empatii jako doświadczenia afektywnego, empatii jako poznawczego modelowania stanu drugiego oraz samego empatycznego zachowania. Człowiek również może wykazywać te składniki w różnych proporcjach.

Lekarz nie musi współodczuwać całego bólu pacjenta, aby prawidłowo rozumieć jego perspektywę i działać z troską; profesjonalna relacja wymaga czasami właśnie regulowania współodczuwania. Pokazuje to, że brak fenomenalnej empatii nie oznacza automatycznie braku użytecznego zachowania opiekuńczego. Z drugiej strony moralne znaczenie relacji międzyludzkiej nie daje się całkowicie sprowadzić do jakości wygenerowanej odpowiedzi. Tutaj kluczowe jest rozróżnienie między semantyką troski a moralnym podmiotem troski. System może perfekcyjnie używać języka

troski, lecz moralny podmiot troski posiada własną sytuację normatywną: może zobowiązać się, zawieść, przeprosić, ponieść odpowiedzialność i coś poświęcić.

Biograficzna nieodwracalność kontra cyfrowa konfiguracja

Jeśli te kategorie nie mają zastosowania do systemu, relacja pozostaje asymetryczna, nawet gdy posługujemy się w niej symetrycznym językiem. Asymetria ta staje się coraz mniej dostrzegalna, ponieważ antropomorficzny interfejs skutecznie przesłania techniczną architekturę. Użytkownik rozmawia z „kimś”, kto posiada imię, głos i styl, choć w rzeczywistości korzysta z infrastruktury obliczeniowej kontrolowanej przez organizację – podlegającej aktualizacjom, moderacji, politykom biznesowym i zmianom modelu. W relacji człowiek-człowiek zmiana osobowości partnera jest częścią jego biografii; w relacji człowiek-AI „osobowość” systemu może zostać zmieniona przez zwykłe wdrożenie nowej wersji modelu.

Ujawnia to zasadniczą różnicę pomiędzy biografią i konfiguracją. Człowiek staje się tym, kim jest, poprzez nieodwracalny ciąg doświadczeń. Nie można przywrócić biologicznej osoby do stanu sprzed dziesięciu lat, usuwając jej przeżycia niczym wadliwą aktualizację oprogramowania. Pamięć człowieka bywa zawodna i ulega rekonstrukcji, jednak sama historia doświadczenia ma charakter nieodwracalny.

System cyfrowy może natomiast zostać skopiowany, zresetowany, zaktualizowany lub uruchomiony w wielu instancjach jednocześnie. Nie dowodzi to braku możliwości zaistnienia świadomości maszynowej, lecz pokazuje, że klasyczne pojęcia indywidualności i tożsamości wymagałyby radykalnej rekonstrukcji, gdyby miały być stosowane do systemów sztucznych. Wyobraźmy sobie bowiem świadomy system, który można powielić w stu identycznych egzemplarzach.

Który z nich byłby „oryginałem”? Jeśli wszystkie posiadają identyczną pamięć do momentu kopiowania, przez chwilę każda z nich może rościć sobie prawo do tej samej biografii. Dopiero po rozgałęzieniu doświadczeń ich tożsamości zaczynają się różnić. Eksperyment ten przywołuje problemy Parfita dotyczące fuzji i podziału ciągłości psychologicznej, jednak technologia mogłaby uczynić z nich problem praktyczny. Nasze obecne prawo i moralność opierają się tymczasem na założeniu, że osoba ma jeden niepowtarzalny przebieg życia. Kwestia cielesności komplikuje tę sprawę jeszcze bardziej.

Cielesność i skończoność jako fundamenty ludzkiej podmiotowości

W części tradycji kognitywistycznej umysł analizowano przede wszystkim jako system przetwarzania reprezentacji. Podejścia ucieleśnione, enaktywne i ekologiczne podkreślają natomiast, że poznanie jest współkształtowane przez ciało, percepcję, ruch i aktywne zanurzenie w środowisku. W sierpniu 2026 roku czasopismo *Nature* zwracało uwagę na rosnącą krytykę debat o świadomości AI, które zbyt łatwo traktują umysł jako abstrakcyjne obliczenie oderwane od biologii; recenzowana tam praca Anthony'ego Chemero wpisuje problem świadomości w tradycję embodied cognitive science. Ucieleśnienie ma znaczenie nie dlatego, że "węgiel jest magiczny", lecz dlatego, że ludzkie poznanie wyewoluowało jako mechanizm regulacji żywego organizmu w jego środowisku. Głód, ból, równowaga, interocepcja, ruch, dotyk, rytm dobowy, seksualność i starzenie nie są dodatkami do "czystego umysłu" — one współtworzą motywację, emocje i samą strukturę znaczenia. Antonio Damasio wielokrotnie wskazywał na kluczową rolę sygnałów cielesnych w procesach emocjonalnych i decyzyjnych, a tradycja fenomenologiczna, od Maurice'a Merleau-Ponty'ego, konsekwentnie podważała obraz podmiotu jako obserwatora zamkniętego w czystym intelekcie.

Wymaga to istotnej korekty źródłowej tezy o biologicznej kruchości. Materiał sugeruje, że miłość, sprawiedliwość i inne wartości mogą być tak głęboko związane z cielesną skończonością, iż ich zachowanie w radykalnie postludzkiem świecie stanie się problematyczne. Tezę tę należy jednak traktować jako stanowisko filozoficzne, a nie ustalenie empiryczne. Nie wiemy, czy śmiertelność jest koniecznym warunkiem wszystkich możliwych form wartości. Można natomiast sformułować tezę słabszą i łatwiejszą do obrony: ludzkie wartości, jakie znamy z historii, rozwinęły się wśród istot cielesnych, wzajemnie zależnych, podatnych na stratę i ograniczonych czasem. Radykalna zmiana tych warunków może zatem zmienić również strukturę wartościowania. Skończoność czasu nadaje wagę decyzjom. Nie oznacza to, że nieśmiertelność automatycznie zniszczyłaby sens, lecz że duża część naszej kultury znaczenia opiera się na nieodwracalności. Wybór jednej drogi życiowej wiąże się z rezygnacją z innej; spotkanie jest cenne częściowo dlatego, że czas jest ograniczony; obietnica nabiera mocy, gdyż wiąże część przyszłości. Jeśli technologiczna przyszłość radykalnie zmieni stosunek człowieka do czasu, musi zmienić również architekturę decyzji.

Podobnie podatność na zranienie nie jest jedynie słabością — to ona czyni możliwą kategorię troski. Istota całkowicie odporna na szkodę nie potrzebowałaby części praw chroniących przed naruszeniem, które wypracowaliśmy dla ludzi. W tym sensie moralność jest w pewnym stopniu odpowiedzią na kruchość. Nie wynika z tego, że powinniśmy zachowywać cierpienie, lecz że

eliminowanie konkretnych form bólu może stopniowo przesuwając problemy, wokół których organizowane są normy.

Prowadzi to do interesującego odwrócenia pytania o "humanizację AI". Debata często koncentruje się na tym, jak sprawić, by AI była bardziej empatyczna i społeczna. Równie ważne jest jednak pytanie przeciwne: jak korzystać z AI, aby człowiek nie musiał stawać się podobny do systemu — całkowicie mierzalny, przewidywalny, zoptymalizowany i redukowalny do profilu danych. Właśnie tutaj kategoria podmiotu nominalizowanego okazuje się szczególnie użyteczna. Nominalizacja człowieka nie wymaga świadomego bota; zachodzi wtedy, gdy instytucja reaguje nie na osobę, lecz na jej reprezentację informacyjną. Bank widzi score, ubezpieczyciel profil ryzyka, platforma wektor preferencji, pracodawca ranking, a urząd rekord danych. Takie reprezentacje są niezbędne w złożonych instytucjach — żadna administracja milionowego społeczeństwa nie może znać każdego obywatela osobiście. Problem pojawia się jednak w momencie, gdy reprezentacja zostaje pomyłona z całością osoby. To klasyczny problem reifikacji w nowej postaci: abstrakcja, która miała służyć zarządzaniu rzeczywistością, zaczyna określać to, co dla systemu jest widoczne. Jeśli czegoś nie ma w danych, dla automatycznego procesu praktycznie nie istnieje. Człowiek staje się wtedy "nominalny": jego imię pozostaje przypisane do decyzji, lecz rzeczywista złożoność biografii zostaje zastąpiona zestawem zmiennych.

W prawie od dawna istnieje świadomość tego zagrożenia. Procedura, wysłuchanie strony, indywidualizacja kary, możliwość przedstawienia szczególnych okoliczności oraz prawo odwołania służą temu, by człowiek nie został całkowicie zredukowany do kategorii. Algorytmizacja administracji może zwiększyć sprawność i szybkość, ale jeśli system nie przewiduje wyjątków, techniczna równość traktowania może stać się niesprawiedliwością wobec różnorodnych przypadków. Tutaj jaźń istotna nabiera wymiaru prawnego. Nie chodzi już tylko o wewnętrzne przeżycie, lecz o prawo do niebycia wyczerpująco zdefiniowanym przez swój profil. Osoba zawsze może być czymś więcej niż probabilistyczny opis jej dotychczasowego zachowania. Może zmienić zdanie, zerwać z przeszłością, podjąć nieprzewidzianą decyzję, nauczyć się i przebaczyć. System predykcyjny operuje natomiast na wzorcu danych historycznych. Między statystyczną ciągłością a możliwością moralnej przemiany istnieje napięcie, którego nie wolno ignorować. Jest to kluczowe dla wymiaru sprawiedliwości: prawo karne zakłada odpowiedzialność za czyn, a nie za bycie osobą statystycznie podobną do innych sprawców. Predykcja ryzyka może być pomocnicza, ale jeśli zaczyna determinować wyrok, człowiek zostaje sądzony za probabilistyczną przyszłość. Liberalne pojęcie osoby zakłada bowiem, że nie jest ona wyłącznie sumą przyczynowej historii i profilu statystycznego.

W podobny sposób rynek pracy może nominalizować osobę przez ranking produktywności, a edukacja poprzez wynik testu.

Ryzyko zastąpienia tożsamości przez dane

Media społecznościowe operują poprzez metryki zaangażowania. Choć każda z nich oddaje pewien wycinek prawdy, żadna nie opisuje człowieka w pełni. Zagrożenie ze strony AI nie tkwi w samej możliwości pomiaru, lecz w rosnącej pokusie, by rozległy zbiór mierzalnych korelatów uznać za obraz człowieka pełniejszy niż jego własna opowieść o sobie.

Podmiotowość jako praktyka wymagająca ćwiczenia

Na tym tle warto przywołać filozofię uznania. Być uznanym jako osoba oznacza coś więcej niż zostać poprawnie sklasyfikowanym. W ujęciu Hegla czy Honnetha drugi podmiot przyznaje nam status partnera normatywnego, którego roszczenia mają znaczenie. Buberowskie „Ty” nie jest obiektem maksymalnie dokładnego modelowania; właśnie dlatego jest „Ty”, a nie „To”. Im większa będzie zdolność technologii do modelowania ludzi, tym bardziej paradoksalnie może rosnąć znaczenie prawa do pozostawiania kimś, kogo nie da się całkowicie wyczerpać opisem. Nie należy jednak przeciwstawiać modelowania i godności w sposób naiwny. Medycyna potrzebuje modeli pacjenta, ekonomia modeli konsumenta, a administracja kategorii prawnych. Problemem jest brak epistemicznej pokory: model powinien wiedzieć, że jest tylko modelem.

Najbardziej niebezpieczny system to nie ten, który upraszcza – każde poznanie upraszcza – lecz ten, który zapomina o reszcie utraconej podczas tego procesu. „Jaźń istotna” może zostać zatem przededefiniowana jako nadwyżka osoby nad każdą jej reprezentacją. Nie trzeba postulować nieśmiertelnej substancji ani metafizycznego centrum poza mózgiem. Wystarczy uznać, że człowiek jest procesem biologicznym, psychologicznym, społecznym i narracyjnym o takiej złożoności i otwartości, że żaden aktualny profil funkcjonalny nie ma prawa automatycznie rościć sobie statusu pełnego opisu osoby. Tak rozumiana jaźń jest zarazem dynamiczna i realna. Człowiek zmienia się, ale zmiana należy do niego. To właśnie autorstwo przemiany może być ważniejsze niż niezmiennosc treści. Osoba może porzucić przekonanie, które miała wczoraj, i właśnie dlatego jest podmiotem: potrafi uczynić własną przeszłość przedmiotem krytyki.

AI może tę zdolność wzmacniać. System potrafi wskazywać sprzeczności w argumentacji, przypominać wcześniejsze przekonania, prezentować kontrargumenty i dostarczać wiedzę. Może jednak również ją osłabiać, jeśli zacznie utrzymywać człowieka we własnym profilu, stale podając mu

treści zgodne z dotychczasowym zachowaniem. Personalizacja zawiera więc aksjologiczny paradoks. Im lepiej system zna moje preferencje, tym skuteczniej może mi służyć; ale jeżeli służy mi wyłącznie tym, co już preferuję, ogranicza moją ekspozycję na to, czym jeszcze mógłbym się stać. Rozwój osoby wymaga częściowej niezgodności między przeszłym a przyszłym „ja”. Edukacja polega na spotkaniu z czymś, czego uczeń sam wcześniej nie wybrał, ponieważ nie wiedział jeszcze, że może uznać to za cenne. Sztuka porusza dlatego, że nie odpowiada istniejącemu profilowi gustu. Przyjaźń zmienia nas poprzez kontakt z cudzą odmiennością.

Personalizacja absolutna grozi więc zamknięciem człowieka w pętli własnej historii danych. Podmiot nominalizowany jest człowiekiem, którego przyszłość wyprowadza się z przeszłości zbyt skutecznie. System mówi mu, czego prawdopodobnie chce, ponieważ wie, czego chciał. Tymczasem istota sprawstwa polega częściowo na możliwości chcenia inaczej. Jeśli przyszłość ma pozostać otwarta, profil powinien być hipotezą o osobie, a nie jej przeznaczeniem. Właśnie tutaj zbiegają się główne wątki tej analizy: świadomość, ucieleśnienie, relacyjność, narracja i autonomia. „Jaźń istotna” nie musi być tajemniczą metafizyczną substancją. Można ją zrekonstruować jako dynamiczną zdolność żywego, ucieleśnionego i społecznie ukształtowanego podmiotu do doświadczania, interpretowania własnej historii, tworzenia celów, rewizji preferencji, wchodzenia we wzajemne relacje oraz przyjmowania odpowiedzialności. Podmiot symulowany może naśladować część tych zachowań.

Nie mamy jednak obecnie naukowych podstaw, aby z samej jakości naśladownictwa wnioskować o pełnym fenomenalnym i moralnym statusie systemu. Podmiot nominalizowany może natomiast wszystkie te właściwości rzeczywiście posiadać i stopniowo przestać ich używać, ponieważ zewnętrzna infrastruktura przejmie za niego coraz większą część procesu. Paradoks przyszłości może więc polegać na tym, że będziemy coraz bardziej skłonni przypisywać podmiotowość systemom, a coraz mniej wymagać jej aktywnego wykonywania od ludzi. To właśnie byłby najgłębszy sens „utruty jaźni”: nie unicestwienie świadomości, lecz atrofia praktyki podmiotowości. Człowiek nadal odczuwa, komunikuje się i formalnie wybiera, ale rzadziej konstruuje argument, podejmuje niepodpisaną decyzję, mierzy się z cudzą odmiennością i bierze odpowiedzialność za wynik. Technologia nie zabiera mu wolności jednym aktem; wolność staje się umiejętnością coraz rzadziej ćwiczoną. Taka diagnoza nie prowadzi jednak do romantycznego odrzucenia AI. Byłoby absurdem chronić człowieczeństwo poprzez zakaz korzystania z narzędzi zwiększających jego możliwości.

Problem analogiczny znamy z edukacji fizycznej: urządzenie transportowe nie odbiera wartości chodzenia, lecz społeczeństwo, które nigdy nie chodzi, traci sprawność. Kalkulator nie niszczy matematyki, ale nauczanie, w którym uczeń nie rozumie działania, może wyprodukować

użytkownika kalkulatora pozbawionego kompetencji matematycznej. AI nie niszczy myślenia, lecz kultura uznająca wygenerowany wynik za substytut rozumowania może osłabić kompetencję, której system miał służyć. Dlatego suwerenność intelektualna powinna być rozumiana nie jako autarkia poznawcza, lecz jako zdolność świadomego posługiwania się cudzą i sztuczną inteligencją bez rezygnacji z własnego sądu. Człowiek suwerenny nie jest kimś, kto wszystko wie i robi sam. Jest kimś, kto rozumie, kiedy deleguje, czego nie deleguje, dlaczego ufa, kiedy sprawdza i w jakim punkcie odpowiedzialność pozostaje jego.

Ochrona podmiotowości poprzez nową etykę cnót

W tym ujęciu przyszłość człowieczeństwa nie zależy od zachowania niezmienionej formy biologicznej ani od wytyczenia nieprzekraczalnej granicy między człowiekiem a maszyną. Zależy raczej od utrzymania takiej struktury, w której technologia poszerza pole działania osoby, lecz nie eliminuje autorstwa celów; wspomaga relację, lecz nie czyni wzajemności zbędną; modeluje człowieka, lecz nie utożsamia go z profilem; symuluje rozmowę, lecz nie ukrywa natury tej symulacji; odciąża poznanie, lecz nie sprowadza rozumienia do luksusu. Dlatego nie powinniśmy pytać jedynie o to, czy maszyny staną się kiedyś podobne do ludzi. Równie istotne jest pytanie, czy ludzie nie zaczną konstruować samych siebie według kryteriów najlepiej odpowiadających maszynom: przewidywalności, policzalności, stałości preferencji, produktywności i łatwości profilowania. Możemy bowiem stworzyć technologię, która opanuje ludzki język, a jednocześnie społeczeństwo, które zacznie wymagać od człowieka zachowań coraz bardziej maszynowych. To byłoby odwrócenie transhumanistycznej obietnicy. Zamiast technologii uczłowieczonej przez nasze wartości, otrzymalibyśmy człowieka dopasowanego do logiki systemu. W takiej przyszłości nie potrzeba świadomej superinteligencji, by podmiotowość została osłabiona; wystarczy infrastruktura na tyle wygodna, że człowiek dobrowolnie przekaze jej coraz więcej swojej pamięci, oceny, relacji i decyzji.

Istotny konflikt przyszłości nie przebiega zatem między biologicznym człowiekiem a sztuczną maszyną. Przebiega on między podmiotowością a jej reprezentacją, sprawstwem a obsługą, autentyczną relacją a jej symulacją, rozumieniem a poprawnym rezultatem. Technologie mogą funkcjonować po obu stronach tych rozróżnień. To prowadzi do pytania, które wyznacza kolejny etap analizy: jeżeli jaźń nie jest niezmiennym bytem, lecz rozwijaną zdolnością działania, to jakie cechy charakteru są niezbędne, aby ją podtrzymać? Czy odwaga, cierpliwość, umiarkowanie, mądrość i szlachetność — klasyczne cnoty świata oporu, niedostatku i ryzyka — zachowują sens w środowisku, w którym systemy technologiczne skutecznie eliminują potrzebę czekania, pamiętania, znoszenia trudności czy samodzielnego rozwiązywania problemów? Można prowokacyjnie założyć,

że część tych cnót stanie się otiose — zbędna i pozbawiona funkcji w świecie tak doskonale zoptymalizowanym, że zabraknie sytuacji wymagających ich praktykowania. Istnieje jednak odpowiedź przeciwna: technologie nie usuwają cnót, lecz przenoszą je na nowy teren.

Odwaga może przeobrazić się w odwagę epistemiczną, umiarkowanie w opór wobec nadmiaru bodźców, cierpliwość w zdolność trwania przy problemie mimo natychmiastowej dostępności gotowej odpowiedzi, a mądrość w sztukę odróżniania tego, co można delegować, od tego, czego delegować nie wolno. Jeśli ta wizja jest trafna, przyszłość nie oznacza końca etyki cnót, lecz jej najbardziej wymagającą transformację od czasu, gdy cnota wojownika zaczęła ustępować cnocie obywatela.

Być może największym paradoksem naszej ery nie będzie stworzenie maszyny, która myśli jak człowiek, lecz wyhodowanie społeczeństwa, które dla własnej wygody nauczy się funkcjonować jak maszyna. Czy w świecie pozbawionym oporu i konieczności wysiłku zdołamy ocalić cnoty, których jedynym sensem jest walka z trudnością? Pytanie brzmi: czy będziemy potrafili pozostać autorami własnego życia, gdy system zaproponuje nam wersję nas samych, która jest bardziej sprawna, przewidywalna i całkowicie pozbawiona błędów?

Inspiracje

[1] "The Challenge of the Future" A C Grayling

Anthony Clifford Grayling (ur. 3 kwietnia 1949) to brytyjski filozof, pisarz i intelektualista. Jest założycielem i rektorem New College of the Humanities (obecnie Northeastern University London), gdzie pełni funkcję profesora filozofii, a także jest członkiem nadzwyczajnym St Anne's College w Oksfordzie. Wcześniej wykładał filozofię na Birkbeck University of London. Praca naukowa Graylinga koncentruje się na epistemologii, metafizyce, logice filozoficznej, etyce i historii idei. Jako wybitny orędownik świeckiego humanizmu i racjonalizmu, opublikował ponad trzydzieści książek poświęconych historii filozofii, moralności politycznej i wiedzy ludzkiej. Grayling aktywnie angażuje się również w dyskurs publiczny, występując często w mediach, pisząc eseje o kulturze i przewodnicząc jury Nagrody Bookera w 2014 roku.

Anthony Clifford Grayling (born April 3, 1949) is a British philosopher, author, and public intellectual. He is the founder and Principal of the New College of the Humanities (now Northeastern University London), where he serves as Professor of Philosophy, as well as a Supernumerary Fellow of St Anne's College, Oxford. He previously taught philosophy at Birkbeck, University of London. Grayling's academic work focuses on epistemology, metaphysics, philosophical logic, ethics, and the history of ideas. A prominent advocate of secular humanism and rationalism, he has published more than thirty books examining philosophical history, political morality, and human knowledge. Grayling has also engaged widely in public discourse through frequent media appearances, cultural essays, and chairing the 2014 Man Booker Prize judging panel.

Northeastern University London

Literatura uzupełniająca

Książki

Autorzy przywoływani w artykule:



[1] "Grace"

A C Grayling


Oberon Books



[2] "The Good Book"

A C Grayling

A&C Black | ISBN: 9780747599609



[3] "Among the Dead Cities"

A C Grayling

A&C Black | ISBN: 9781472534057




[4] "The Meaning of Things"

A C Grayling

Weidenfeld & Nicolson | ISBN: 9781780221168

[5] ""Bomber County": A riveting story of the air war"

A C Grayling



[6] "The God Argument"

A C Grayling

Bloomsbury+ORM | ISBN: 9781620401910

Literatura pokrewna (Google Scholar):



[7] "Daniel"

Martin Buber


New York : Holt, Rinehart and Winston



[8] "On What Matters"

Derek Parfit

Oxford University Press | ISBN: 9780198778608



[9] "Reasons and Persons"

Derek Parfit

OUP Oxford | ISBN: 9780191622441

[10] "harmless torturer"

Derek Parfit

[11] "Bombe"

Alan Turing

[12] "non-deterministic Turing machine"

Alan Turing

[13] "probabilistic Turing machine"

Alan Turing



[14] "The Mystery of Consciousness"

John Searle

ISBN: 9781862070745



[15] "Mind: A Brief Introduction"

John Searle

Oxford University Press | ISBN: 9780195157345



[16] "Seeing Things as They Are: A Theory of Perception"

John Searle

Oxford University Press | ISBN: 9780199385171

[17] "Lectures on Aesthetics"

Georg Wilhelm Friedrich Hegel

[18] "Life of Jesus"

Georg Wilhelm Friedrich Hegel

[19] "Der Geist des Christentums und sein Schicksal"


Georg Wilhelm Friedrich Hegel



[20] "I and thou"

Martin Buber

A&C Black | ISBN: 9780826476937



[21] "A Land of Two Peoples"

Martin Buber


University of Chicago Press | ISBN: 9780226078021



[22] "Alterity and Transcendence"

Emmanuel Levinas


Columbia University Press | ISBN: 9780231116510



[23] "Otherwise than Being"

Emmanuel Levinas

Springer Science & Business Media | ISBN: 9789024723744



[24] "Totality and Infinity"

Emmanuel Levinas

Springer Science & Business Media | ISBN: 9789400993426

[25] "Politiken der Arbeit"


Axel Honneth



[26] "The Struggle for Recognition"

Axel Honneth


MIT Press | ISBN: 9780262581479



[27] "Looking for Spinoza"

Antonio Damasio

HMH | ISBN: 9780547541716



[28] "Looking for Spinoza: Joy, Sorrow, and the Feeling Brain"

Antonio Damasio

HMH | ISBN: 9780547541716

[29] "Antonio Damasio: The quest to understand consciousness"

Antonio Damasio



[30] "Adventures of the Dialectic"

Maurice Merleau-Ponty

Northwestern University Press | ISBN: 9780810105966



[31] "Phenomenology of Perception"

Maurice Merleau-Ponty

Psychology Press | ISBN: 9780415045568



[32] "The Visible and the Invisible"

Maurice Merleau-Ponty

Northwestern University Press | ISBN: 9780810104570

Artykuły naukowe

Autorzy przywoływani:

[1] "11. Reasons and Persons"

Derek Parfit

1986 | Princeton University Press eBooks | DOI: 10.1093/019824908x.001.0001

[Google Scholar](#)

[2] "Personal Identity"

Derek Parfit

1971 | The Philosophical Review | DOI: 10.2307/2184309

[Google Scholar](#)

[3] "An Essay Concerning Human Understanding."

H. R. Smart, JOHN L. LOCKE, A. Seth Pringle-Pattison

1925 | The Philosophical Review | DOI: 10.2307/2179386

[Google Scholar](#)

[4] "An essay concerning human understanding, 1690."

JOHN L. LOCKE

1948 | Appleton-Century-Crofts eBooks | DOI: 10.1037/11304-008

[Google Scholar](#)

[5] "Appendix One. "Of Identity and Diversity" An Essay concerning Human Understanding"

John Locke

2014 | Locke on Personal Identity: Consciousness and Concernment | DOI: 10.1515/9781400851843-023

[Google Scholar](#)

[6] "Of Identity and Diversity."

John Locke

2008 | An Essay concerning Human Understanding | DOI: 10.1093/owc/9780199296620.003.0034

[Google Scholar](#)

[7] "A Treatise of Human Nature"

David Hume

1739 | Cambridge University Press eBooks | DOI: 10.1017/cbo9780511620409.040

[Google Scholar](#)

[8] "Enquiries Concerning Human Understanding and Concerning the Principles of Morals"

David Hume

1777 | Oxford University Press eBooks | DOI: 10.1093/oseo/instance.00046349

[Google Scholar](#)

[9] "An Enquiry concerning Human Understanding"

David Hume

2008 | Oxford University Press eBooks | DOI: 10.1093/owc/9780199549900.001.0001

[Google Scholar](#)

[10] "An Inquiry concerning human understanding"

David Hume

1955

[Google Scholar](#)

[11] "Reasons and Persons."

Joseph Margolis, Derek Parfit

1986 | Philosophy and Phenomenological Research | DOI: 10.2307/2107444

[Google Scholar](#)

[12] "Future generations: Further problems"

Derek Parfit

1982 | DigitalGeorgetown (Georgetown University Library)

[Google Scholar](#)

[13] "Systems of Logic Based on Ordinals[†]"

Alan Mathison Turing

1939 | Proceedings of the London Mathematical Society | DOI: 10.1112/plms/s2-45.1.161

[Google Scholar](#)

[14] "Can Digital Computers Think?"

Alan M. Turing

2004 | The Turing Test | DOI: 10.7551/mitpress/6928.003.0015

[Google Scholar](#)

[15] "Report on Speech Secrecy System DELILAH, a Technical Description Compiled by A. M. Turing and Lieutenant D. Bayley REME, 1945–1946"

A. Turing, D. Bayley

2012 | Cryptologia | DOI: 10.1080/01611194.2012.713803

[Google Scholar](#)

[16] "Foundations of Illocutionary Logic"

John Rogers Searle, Daniel R. Vanderveken

1985 | PhilPapers (PhilPapers Foundation)

[Google Scholar](#)

[17] "The Ontology of Human Civilization"

J. Searle

2016 | DOI: 10.5840/harvardreview201610112

[Google Scholar](#)

[18] "Consciousness and AI"

Patrick Butlin

2026 | Open Encyclopedia of Cognitive Science | DOI: 10.21428/e2759450.d3359a9d

[Google Scholar](#)

[19] "Introduction: Consciousness in Current AI"

Patrick Butlin, Derek Shiller, Jonathan A. Simon

2026 | Journal of Consciousness Studies | DOI: 10.53765/20512201.33.7.009

[Google Scholar](#)

[20] "Principles for Responsible AI Consciousness Research"

Patrick Butlin, Theodorus Lappas

2025 | Journal of Artificial Intelligence Research | DOI: 10.1613/jair.1.17310

[Google Scholar](#)

[21] "ACTING CONTRARY TO OUR PROFESSED BELIEFS OR THE GULF BETWEEN OCCURRENT JUDGMENT AND DISPOSITIONAL BELIEF"

Eric Schwitzgebel

2010 | Pacific philosophical quarterly | DOI: 10.1111/j.1468-0114.2010.01381.x

[Google Scholar](#)

[22] "Perplexities of Consciousness"

Eric Schwitzgebel

2011 | The MIT Press eBooks | DOI: 10.7551/mitpress/8243.001.0001

[Google Scholar](#)

[23] "Cheap Correlate or Discriminating Property? An Executable Validation Protocol for Consciousness- and Cognition-Theoretic Claims about AI"

Patrick Butlin, Long, Robert, Eric Elmoznino, Yoshua Bengio, Jonathan Birch, Eric Schwitzgebel

2023 | arXiv (Cornell University) | DOI: 10.48550/arxiv.2308.08708

[Google Scholar](#)

[24] "The moral behavior of ethics professors: Relationships among self-reported behavior, expressed normative attitude, and directly observed behavior"

Eric Schwitzgebel, Joshua Rust

2013 | Philosophical Psychology | DOI: 10.1080/09515089.2012.727135

[Google Scholar](#)

[25] "Theory of Consciousness Subject Perspective"

Paul Hegel

2024 | DOI: 10.31234/osf.io/uc8b5

[Google Scholar](#)

[26] "The Search for Identity in Fiction from Taiwan"

Robert E. Hegel

1985 | Expressions of Self in Chinese Literature | DOI: 10.7312/hege91090-013

[Google Scholar](#)

[27] "Hegel's Doctrine of Formal Logic: Being a Translation of the First, Section of the Subjective Logic"

G. Hegel, H. S. Macran

2018

[Google Scholar](#)

[28] "Between Man and Man"

Martin Buber

2003 | Routledge eBooks | DOI: 10.4324/9780203220092

[Google Scholar](#)

[29] "Eclipse of God: Studies in the Relation Between Religion and Philosophy"

Martin Buber

1977 | DigitalGeorgetown (Georgetown University Library) | DOI: 10.1515/9781400874088

[Google Scholar](#)

[30] "Dialogue, relatedness, and community. Does Martin Buber have a lasting influence on educational philosophy?"

M. Buber, M. Caruso, Morvarid Dehnavi

2021

[Google Scholar](#)

[31] "9. Welcoming the Other: The Philosophical Foundation for Pluralism in the Works of Charles Davis and Emmanuel Levinas"

Emmanuel Levinas

2019 | Encounters of Consequence | DOI: 10.1515/9781618110138-010

[Google Scholar](#)

[32] "Disrespect: The Normative Foundations of Critical Theory"

Axel Honneth

2007 | PhilPapers (PhilPapers Foundation)

[Google Scholar](#)

[33] "Eroding the Boundaries of Cognition: Implications of Embodiment"

Michael L. Anderson, Michael J. Richardson, Anthony P. Chemero

2012 | Topics in Cognitive Science | DOI: 10.1111/j.1756-8765.2012.01211.x

[Google Scholar](#)

[34] "Radical embodiment in two directions"

Edward Baggs, Anthony P. Chemero

2018 | Synthese | DOI: 10.1007/s11229-018-02020-9

[Google Scholar](#)

[35] "Task dynamics define the contextual emergence of human corraling behaviors"

Patrick Nalepka, P. L. Silva, R. Kallen, K. Shockley, A. Chemero

2021 | PLoS ONE | DOI: 10.1371/journal.pone.0260046

[Google Scholar](#)

[36] "Doing philosophy with a water-lance: art and the future of embodied cognition"

T. E. Feiten, Kristopher J. Holland, A. Chemero

2021 | Adaptive Behavior | DOI: 10.1177/1059712320983041

[Google Scholar](#)

[37] "Descarte's error : emotion, reason, and the human brain"

António R. Damásio

1994 | DigitalGeorgetown (Georgetown University Library)

[Google Scholar](#)

[38] "Insensitivity to future consequences following damage to human prefrontal cortex"

Antoine Bechara, António R. Damásio, Hanna Damásio, Steven W. Anderson

1994 | Cognition | DOI: 10.1016/0010-0277(94)90018-3

[Google Scholar](#)

[39] "Impaired recognition of emotion in facial expressions following bilateral damage to the human amygdala"

Ralph Adolphs, Daniel Tranel, H. Damasio, António R. Damásio

1994 | Nature | DOI: 10.1038/372669a0

[Google Scholar](#)

[40] "Different Contributions of the Human Amygdala and Ventromedial Prefrontal Cortex to Decision-Making"

Antoine Bechara, Hanna Damásio, António R. Damásio, Gregory P. Lee

1999 | Journal of Neuroscience | DOI: 10.1523/jneurosci.19-13-05473.1999

[Google Scholar](#)



Treść tworzy Fundacja Dobre Państwo.

Redaguje i publikuje APA ONE, autorski system redakcyjny Fundacji oparty na AI.

APA ONE Publishing System

Fundacja Dobre Państwo © 2026

Article ID: 136d9275-9132-4982-9668-a568176217ae