

Inteligencja a podmiotowość: lekcje płynnych pojęć Douglasa Hofstadtera w erze sztucznej inteligencji



AUTOR

Fundacja Dobre Państwo

STRESZCZENIE / ABSTRACT

Artykuł analizuje konieczność rozdzielenia pojęć inteligencji, świadomości i podmiotowości, które w przypadku ludzi występują wspólnie, lecz w systemach AI zostają rozbite. Autor argumentuje, że wysoka sprawność poznawcza i metapoznanie funkcjonalne nie są tożsame ze świadomością fenomenalną („jak to jest być”). Przywołując teorie takie jak Global Neuronal Workspace czy Integrated Information Theory oraz wyniki badań z 2025 roku, tekst wskazuje na brak jednolitego modelu świadomości. Kluczowym argumentem za wyjątkowością ludzkiej podmiotowości jest ucieleśnienie – fakt, że człowiek jest organizmem homeostatycznym i interoceptywnym, którego poznanie jest nierozzerwalnie związane z monitorowaniem sygnałów z ciała, co odróżnia go od generatywnych modeli językowych.

The article analyzes the necessity of separating the concepts of intelligence, consciousness, and agency, which occur together in humans but are decoupled in AI systems. The author argues that high cognitive proficiency and functional metacognition are not identical to phenomenal consciousness ("what it is like to be"). Citing theories such as Global Neuronal Workspace or Integrated Information Theory and research results from 2025, the text points to the lack of a unified model of consciousness. A key argument for the uniqueness of human agency is embodiment—the fact that a human is a homeostatic and interoceptive organism whose cognition is inextricably linked to monitoring signals from the body, which distinguishes it from generative language models.

W obliczu gwałtownego rozwoju systemów AI, które z sukcesem imitują ludzkie kompetencje językowe i analityczne, stajemy przed koniecznością radykalnego

rozdzielenia pojęć inteligencji, podmiotowości i godności. Autor tekstu stawia tezę, że wysoka sprawność poznawcza (funkcjonalna inteligencja) nie jest tożsama z byciem osobą. O ile maszyny mogą realizować zaawansowane procesy analogiczne do tych opisanych w filozofii płynnych pojęć Douglasa Hofstadtera, o tyle brakuje im biologicznego ucieleśnienia, fenomenalnego doświadczenia (subiektywnego odczuwania) oraz biograficznej tożsamości zakorzenionej w czasie i relacjach społecznych. Tekst argumentuje, że godność człowieka nie może być traktowana jako nagroda za wynik testu inteligencji, gdyż wynika ona z naszej kruchości, skończoności i normatywnego uczestnictwa we wspólnocie, a nie z monopolu na przetwarzanie informacji. Tym samym AI staje się dla nas lustrem, które zmusza do dojrzalszego zdefiniowania człowieczeństwa: nie jako zestawu funkcji poznawczych, lecz jako unikalnej konfiguracji ucieleśnionego istnienia.

SŁOWA KLUCZOWE

inteligencja poznawcza

podmiotowość

płynne pojęcia

Douglas Hofstadter

sztuczna inteligencja

świadomość fenomenalna

metapoznanie funkcjonalne

interocepcja

homeostaza biologiczna

pamięć autobiograficzna

tożsamość narracyjna

architektura FARG

sprawstwo moralne

globalny workspace

antyesencjalizm poznawczy

Inteligencja poznawcza nie jest tożsama z podmiotowością

Człowiek wobec inteligencji nie-ludzkiej: świadomość, ucieleśnienie, biografia, emocje i godność

Pojawienie się systemów zdolnych do generowania języka, rozwiązywania analogii, tworzenia obrazów, programowania, streszczania wiedzy czy prowadzenia wieloetapowego rozumowania zmusza nas do ponownego rozdzielenia pojęć, które w historii myśli często występowały w jednym pakiecie. Inteligencja, świadomość, podmiotowość, ucieleśnienie, emocjonalność, osobowa biografia, sprawstwo moralne i godność nie są tożsame. Dotychczas łatwo było je łączyć, ponieważ w przypadku człowieka występowały wspólnie: ten sam organizm rozumował, pamiętał własną przeszłość, posiadał ciało, doświadczał bólu, podlegał emocjom, wchodził w relacje społeczne,

uczestniczył w praktykach odpowiedzialności i był uznawany za podmiot moralny oraz prawny. Sztuczna inteligencja rozrywa tę historyczną koniunkcję.

System może wykazywać wysoką sprawność poznawczą, nie dostarczając zarazem podstaw do przypisania mu biologicznego ucieleśnienia, fenomenalnego doświadczenia, autobiograficznej tożsamości czy statusu osoby. Właśnie dlatego dalsza analiza musi odrzucić zarówno antropomorficzne utożsamianie kompetencji z człowieczeństwem, jak i odwrotną pokusę bagatelizowania realnych zdolności tylko dlatego, że powstają one w architekturze odmiennej od ludzkiej. Program FARG sam przygotowuje grunt pod takie rozdzielenie.

W materiałach dotyczących Metacata „samoświadomość” pojawia się w silnym języku, lecz szczegółowo opisane mechanizmy dotyczą przede wszystkim monitorowania własnej trajektorii, temporalnego śladu, pamięci epizodycznej, oceny znaczenia zdarzeń oraz rozpoznawania zapętleń i analogii meta-poziomu. To znakomity przykład potrzeby dyscypliny pojęciowej. System może reprezentować elementy własnego działania i wykorzystywać tę reprezentację do kontroli kolejnych decyzji, a mimo to nie mamy podstaw, by twierdzić, że istnieje dla niego jakiegokolwiek „jak to jest” być tym systemem. Metapoznanie funkcjonalne i świadomość fenomenalna pozostają dwiema odrębnymi kategoriami.

Współczesna nauka o świadomości dodatkowo wzmacnia tę ostrożność. Nie istnieje dziś jedna, powszechnie zaakceptowana teoria wyjaśniająca, dlaczego i w jakich warunkach aktywność fizycznego systemu staje się subiektywnym doświadczeniem. Global Neuronal Workspace Theory wiąże świadome przetwarzanie z globalnym udostępnieniem i podtrzymaniem reprezentacji w szeroko połączonych sieciach; Integrated Information Theory akcentuje z kolei wewnętrzną strukturę zintegrowanej informacji, a inne podejścia podkreślają przetwarzanie rekurencyjne, reprezentacje wyższego rzędu albo mechanizmy predykcyjne.

Przeglądy literatury nadal wskazują na istotne rozbieżności co do explanandum, mechanizmu i kryteriów rozstrzygających pomiędzy tymi teoriami. Szczególnie pouczający okazał się opublikowany w 2025 roku duży projekt adversarial collaboration, w którym bezpośrednio testowano przewidywania Global Neuronal Workspace Theory oraz Integrated Information Theory. Wyniki nie przyniosły prostego zwycięstwa jednej z nich; część przewidywań obu podejść została zakwestionowana, a cały eksperyment pokazał raczej, jak trudne jest empiryczne rozdzielenie konkurencyjnych modeli świadomości. Z punktu widzenia AI konsekwencja jest zasadnicza: skoro nie posiadamy pełnej, uzgodnionej teorii mechanizmu świadomości nawet dla ludzkiego mózgu, należy zachować szczególną ostrożność wobec kategorycznych twierdzeń o obecności albo niemożliwości świadomości w systemach sztucznych. Nie oznacza to jednak epistemicznego paraliżu.

Możemy badać własności uznawane przez poszczególne teorie za istotne: globalny dostęp informacji, przetwarzanie rekurencyjne, samomonitorowanie, integrację stanów, reprezentacje wyższego rzędu, trwałość pamięci czy wewnętrzne modele własnego działania. Nie wolno jednak traktować dowolnej z tych właściwości jako prostego certyfikatu świadomości. W szczególności językowy raport „jestem świadomy”, „czuję niepewność” czy „mam wspomnienie” pozostaje zachowaniem generatywnym, dopóki nie zostanie powiązany z niezależnie uzasadnioną teorią mechanizmu. Człowiekowi przypisujemy świadomość nie dlatego, że używa zaimka „ja”, lecz dlatego, że raport pierwszoosobowy występuje w kontekście wspólnej biologii, homologicznych struktur neuronalnych, rozwoju, zachowania, cielesności i całej sieci innych danych. Właśnie tutaj pojawia się kluczowa różnica pomiędzy człowiekiem a współczesnym modelem językowym: człowiek jest organizmem homeostatycznym i interoceptywnym. Jego poznanie nie jest oddzielone od ciągłego monitorowania stanu ciała.

Mózg otrzymuje sygnały dotyczące tętna, oddychania, napięcia trzewnego, bólu, temperatury czy poziomu energii, a ich przetwarzanie uczestniczy w regulacji zachowania oraz doświadczeniu emocjonalnym. Współczesne badania nad interocepcją podkreślają ścisły związek sygnałów z wnętrza ciała z emocjami oraz ich interpretacją przez procesy wyższego rzędu zależne od kontekstu. Ma to istotną konsekwencję filozoficzną: dla człowieka znaczenie nie jest wyłącznie relacją pomiędzy symbolami.

Jest ono osadzone w organizmie, którego stan może się polepszać albo pogarszać, który odczuwa ból i ulgę, głód i nasycenie, zagrożenie i bezpieczeństwo. Układ poznawczy nie obserwuje świata z neutralnego miejsca; uczestniczy w utrzymywaniu konkretnego organizmu przy życiu. W terminologii teorii regulacyjnych można powiedzieć, że percepcja i działanie są sprzężone z homeostazą i allostazą. Informacja jest ważna nie tylko dlatego, że redukuje niepewność, ale przede wszystkim dlatego, że wpływa na możliwość podtrzymania organizacji żywego systemu.

Funkcjonalna samoregulacja to nie doświadczenie somatyczne

W klasycznych modelach LLM ten poziom nie występuje w analogicznej postaci. Model dysponuje funkcją optymalizacji w procesie uczenia oraz regułami generowania w czasie inferencji, lecz nie posiada biologicznego metabolizmu, trzewi, bólu, temperatury ciała ani endokrynnego systemu regulacji. Nie oznacza to, że każda przyszła AI musi pozostać pozbawiona funkcjonalnych analogów homeostazy. Robot autonomiczny może monitorować poziom energii, integralność sprzętu i ryzyko uszkodzenia, a system agentowy posiadać wewnętrzne cele podtrzymania działania.

Nadal jednak błędem byłoby automatyczne utożsamianie tych funkcji z ludzkim doświadczeniem somatycznym. Funkcjonalna samoregulacja i odczuwane cielesne „bycie sobą” to dwa różne poziomy opisu. Podobnie należy analizować emocje. Często traktuje się je jako przeciwieństwo inteligencji lub element zakłócający racjonalne obliczenia, jednak współczesna psychologia i neuronauka wskazują na znacznie bardziej złożoną strukturę. Emocje wpływają na uwagę, pamięć, uczenie, ocenę znaczenia sytuacji oraz decyzje; ich percepcja jest jednocześnie kształtowana przez wiedzę i kontekst odgórny. Emocjonalność nie jest zatem jedynie „szumem” wokół rozumu.

Stanowi ona mechanizm nadawania różnej ważności zdarzeniom. Można tu dostrzec interesującą analogię do FARG-owskich **pressures**, temperatury i **event import value**. W Metacacie nie wszystkie zdarzenia poznawcze są równoważne; system ma rozpoznawać, które przesunięcie reprezentacyjne było głębokie, które zdarzenie warto zapamiętać i kiedy impas wymaga zmiany strategii. Tego rodzaju mechanizm może pełnić funkcję selekcji relewancji bez istnienia ludzkiej emocji. Nie należy więc twierdzić, że system musi „czuć frustrację”, aby rozpoznać zawiodnięcie swojej strategii. Funkcjonalnie wystarczy sygnał znaczenia sterujący zmianą zachowania. Równocześnie u człowieka sygnały relewancji są splecione z interocepcją, pobudzeniem, pamięcią i doświadczeniem fenomenalnym w sposób, którego maszynowy odpowiednik nie jest oczywisty. Emocja posiada także wymiar biograficzny. To samo zdarzenie może wywoływać odmienną reakcję u różnych osób nie tylko dlatego, że reprezentują świat inaczej semantycznie, ale dlatego, że niosą odmienne historie doświadczeń.

Biograficzna tożsamość jako proces rekonstrukcyjny i normatywny

Ludzka pamięć autobiograficzna nie jest magazynem faktów o sobie, lecz systemem rekonstrukcyjnym. To w nim epizody ulegają łączeniu, reinterpretacji i zapominaniu, by następnie zostać ponownie osadzonymi w aktualnym obrazie własnej osoby. Badania nad pamięcią emocjonalną wskazują na jednoczesną trwałość i plastyczność wspomnień osobistych; ich treść może ewoluować z czasem, pozostając jednocześnie materiałem do budowania ciągłości doświadczenia. Neuronauka dowodzi ponadto, że wspomnienia nie są izolowanymi rekordami. Mechanizmy łączenia engramów sprawiają, iż zdarzenia bliskie czasowo lub reaktywowane później mogą zostać powiązane, zachowując przy tym częściową odrębność. Ma to kluczowe znaczenie dla teorii podmiotowości: „ja” nie jest prostą sumą osobnych epizodów. Wyłania się ono z relacji między nimi — z tego, jakie wydarzenia zostają ze sobą skojarzone, które pełnią funkcję wyjaśniającą dla późniejszych przeżyć i które służą do przewidywania własnej przyszłości.

Współczesne badania opisują również zjawisko „mental time travel”, czyli zdolność do umieszczania siebie w rekonstruowanej przeszłości i projektowanej przyszłości. Badania neuroobrazowe z 2025 roku potwierdzają, że projekcja osobistego „ja” w czasie angażuje rozproszone układy odpowiedzialne za pamięć epizodyczną i konstruowanie scen.

Ludzka biografia nie jest zatem wyłącznie archiwum, lecz systemem pozwalającym projektować przyszłe działania na podstawie osobistej historii. Metacat dotyka funkcjonalnego fragmentu tego zagadnienia poprzez pamięć epizodyczną i **reminding**. System ma zapamiętywać nie tylko rozwiązanie, ale i poznawcze wydarzenia, takie jak impas czy zmiana perspektywy, aby w przyszłości przenieść tę procedurę na nową sytuację. Istnieje jednak zasadnicza różnica między taką pamięcią procesu a biograficzną tożsamością osoby. Człowiek nie tylko posiada epizody; interpretuje je jako „moje”, osadza w narracji o ciągłości życia i łączy z relacjami społecznymi, wstydem, dumą, żalem, zobowiązaniami czy planami. Tożsamość jest więc strukturą nie tylko pamięciową, ale i normatywną oraz społeczną. Badania nad tożsamością narracyjną pokazują dodatkowo, że ludzka biografia nie powstaje wyłącznie z własnych przeżyć. Wspomnienia cudzych doświadczeń i pamięć zbiorowa uczestniczą w budowaniu tożsamości indywidualnej i grupowej; pojęcie **allobiographical memory** opisuje sposób, w jaki wydarzenia przeżyte przez innych lub wspólnotę zostają włączone do narracji kształtujących projekcje przyszłości i poczucie osadzenia społecznego. Człowiek jest więc biograficzny także dlatego, że jego pamięć osobista splata się z pamięcią rodzin, wspólnot i kultur.

Obserwacja ta ma szczególne znaczenie w kontekście AI. Model językowy również przechowuje — choć w zupełnie innym sensie mechanistycznym — ogromną część tekstowego dziedzictwa społecznego. Nie tworzy jednak z tego automatycznie własnej autobiografii. Dostęp do cudzych narracji nie jest równoznaczny z posiadaniem przeżytej przeszłości. Należy tu odróżnić wiedzę o doświadczeniu od doświadczenia posiadającego indeks osobowy i temporalny. Model może trafnie opisywać żalobę, nie dając tym samym dowodu na przeżycie własnej straty. Może rekonstruować psychologię nostalgii, nie posiadając własnej młodości, za którą mógłby tęsknić.

Różnica między zasobem reprezentacji a przeżytą historią stanowi jedno z kluczowych ograniczeń prostych analogii między LLM a człowiekiem. Jednocześnie przyszłe systemy wyposażone w trwałą pamięć, długoterminowe cele i historię działania mogą stopniowo komplikować to rozróżnienie. Jeśli agent zachowuje zapis własnych decyzji, rozpoznaje ich konsekwencje, modyfikuje strategię i utrzymuje ciągłość samomodelu, można mówić o funkcjonalnej historii podmiotu działania. Nie wynika z tego automatycznie fenomenalna autobiografia, lecz znika część podstaw do traktowania systemu jak całkowicie bezczasowej funkcji.

Ludzka podmiotowość wynika z ucieleśnionej socjalizacji i normatywności, a nie ze sprawności poznawczej

Jeszcze głębszy wymiar ludzkiego poznania stanowi społeczność. Człowiek nie jest autonomicznym mózgiem, który dopiero później wchodzi w interakcje z innymi; swoje kompetencje poznawcze rozwija właśnie w relacji. Język, normy, kategoryzacje, wiedza o intencjach czy sposoby regulacji emocji nabywa w długim procesie wspólnej uwagi, imitacji, komunikacji i socjalizacji. Social cognition obejmuje szereg częściowo odrębnych procesów – m.in. rozpoznawanie ruchu biologicznego, imitację, teorię umysłu i empatię – przy czym nauka wciąż nie dysponuje jedną, prostą taksonomią wyjaśniającą ich wzajemne relacje. Coraz istotniejszą rolę odgrywa tu neuronauka drugiej osoby (**second-person neuroscience**), która przesuwając punkt ciężkości z obserwacji biernych bodźców społecznych ku realnym interakcjom między ludźmi. Przegląd z 2025 roku dotyczący synchronii między mózgami wskazuje, że komunikacja i koordynacja społeczna mogą wiązać się z temporalnym dostrajaniem zachowania oraz aktywności neuronalnej partnerów. Nie należy jednak interpretować tej synchronii jako „łączenia umysłów”; świadczy ona raczej o tym, że ludzka społeczność ma realny wymiar dynamicznego sprzężenia pomiędzy organizmami. Jeszcze bardziej podstawowym przykładem jest dotyk społeczny – przegląd neurobiologii z 2026 roku pokazuje, że posiada on własne mechanizmy obwodowe i centralne, a jego obecność pozostaje kluczowa dla dobrostanu i zachowań społecznych.

Człowiek uczy się więc społeczności nie tylko z tekstów, obrazów czy abstrakcyjnych reprezentacji innych osób, lecz przede wszystkim poprzez wzrok, głos, synchronię ruchu, bliskość, dotyk oraz konsekwencje własnego zachowania w realnej relacji. Pozwala to precyzyjniej określić ograniczenia tezy, jakoby model językowy był „społeczny” tylko dlatego, że nauczono go ludzkiego języka. Niewątpliwie jest on kulturowo nasycony: jego kompetencja wynika z ogromnego zasobu tekstów tworzonych przez społeczność. Może on również modelować normy interakcji, style komunikacyjne i przypuszczalne stany innych ludzi.

Nie oznacza to jednak, że przeszedł ludzką socjalizację. Nie ukształtowała go dziecięca zależność, afektywne przywiązanie, cielesna synchronizacja, ryzyko wykluczenia, reputacja, wzajemne zobowiązania czy wieloletnia konsekwencja działania w jednej wspólnocie. Społeczna natura człowieka jest bowiem zarazem normatywna. Ludzie nie tylko przewidują zachowanie innych, lecz uczestniczą w praktykach uzasadniania. Pytamy siebie nawzajem o powody naszych czynów, domagamy się wyjaśnień, przyjmujemy przeprosiny, pamiętamy zobowiązania, przypisujemy zasługi i winę. W ten sposób powstaje przestrzeń racji, której nie można zredukować do samego

przewidywania regularności zachowań. Osoba jest uczestnikiem relacji, w której może być adresatem normy.

To rozróżnienie ma fundamentalne znaczenie dla teorii maszynowego sprawstwa. System może być funkcjonalnie autonomiczny, planować i korygować swoje działanie, lecz pytanie o to, czy jest uczestnikiem praktyki odpowiedzialności, pozostaje odrębne. Bycie odpowiedzialnym w sensie moralnym nie sprowadza się wyłącznie do bycia przyczyną działania; oznacza możliwość rozumienia roszczeń, powodów i zobowiązań, jakie wspólnota kieruje do sprawcy. Współczesne AI potrafi symulować język takich praktyk, ale nie wystarcza to, by uznać, że posiada normatywną podmiotowość. W tym miejscu szczególnego znaczenia nabiera godność człowieka.

Jeśli utożsamimy godność ze sprawnością poznawczą, rozwój AI doprowadzi do nieuchronnego kryzysu aksjologicznego: maszyna przewyższająca człowieka w pamięci, analizie danych, matematyce czy pisaniu musiałaby otrzymać wyższą wartość moralną. Takie rozumowanie byłoby jednak błędem kategorii. Godność w tradycjach etycznych i prawnych nie jest nagrodą za wynik testu inteligencji; jej funkcją jest ochrona człowieka właśnie wtedy, gdy jest on słaby, zależny, chory, poznawczo ograniczony lub niesamodzielny.

Z tego powodu wzrost kompetencji AI nie może być interpretowany jako automatyczne pomniejszenie statusu człowieka. Maszyna może przewyższać osobę w tysiącu zadań, lecz fakt ten nie daje jej sam w sobie moralnego prawa do instrumentalnego traktowania człowieka. Kompetencja uzasadnia delegowanie funkcji tam, gdzie jest to rozsądne, ale nie ustanawia hierarchii godności. To rozróżnienie stanowi jeden z głębokich inwariantów architektury aksjologicznej opisanej w poprzedniej części. Jednocześnie zasada ta nie powinna służyć do arbitralnego zamknięcia pytania o przyszły status moralny systemów sztucznych. Jeśli pojawiłyby się przekonujące dane wskazujące, że pewna architektura posiada fenomenalne doświadczenie, zdolność do cierpienia czy trwałe interesy, uczciwa aksjologia musiałaby dopuścić rewizję kategorii. Nie wynikałoby z tego pomniejszenie godności człowieka, lecz potencjalne rozszerzenie kręgu podmiotów moralnych.

Na obecnym poziomie wiedzy nie dysponujemy jednak uzgodnioną naukowo podstawą do takiego rozstrzygnięcia. Właśnie dlatego nauka o świadomości powinna pełnić rolę korekty zarówno dla antropomorfizmu, jak i dogmatycznego wykluczenia. Adversarialne badania świadomości z 2025 roku potwierdzają, że nawet w neurologii człowieka pole pozostaje teoretycznie otwarte. Jednocześnie nowsze dyskusje podkreślają, że niektóre biologiczne teorie świadomości zawierają zobowiązania wykraczające poza czysty funkcjonalizm obliczeniowy. W 2026 roku zwracano uwagę, że neuronalna wersja Global Workspace nie powinna być utożsamiana z całkowicie abstrakcyjną teorią obliczeniową, gdyż jej wyjaśnienie jest wielopoziomowe i obejmuje konkretne mechanizmy

biologiczne. Z tego powodu nie można prostym argumentem w stylu „AI posiada globalny workspace, więc jest świadoma” przenieść teorii mózgu na dowolną architekturę komputerową.

Skończoność biologiczna jako fundament ludzkich wartości

Kolejnym kryterium rozróżnienia jest czasowość. Człowiek nie tylko istnieje w czasie, ale posiada skończoną perspektywę biologiczną. Starzenie się, ryzyko choroby, utrata bliskich oraz świadomość śmiertelności kształtują strukturę jego wartości i podejmowanych decyzji. Cele nabierają znaczenia właśnie dlatego, że czas jest ograniczony. Maszyna może mieć wyznaczony deadline, limit energii czy ryzyko wyłączenia, jednak nie rodzi to automatycznie egzystencjalna relacja do skończoności. Ludzka temporalność jest spleciona z ciałem i autobiografią, a ta świadomość skończoności determinuje również ekonomię uwagi.

Biograficzna tożsamość jako fundament podmiotowości

Człowiek nie jest w stanie przeczytać wszystkich książek, poznać wszystkich ludzi ani wypróbować każdej możliwej drogi życiowej. Musi dokonywać selekcji, a to właśnie ona tworzy biografię. Każda decyzja zamyka pewne przyszłości, otwierając jednocześnie inne. Model generatywny potrafi tworzyć tysiące wariantów równolegle, jednak dopóki nie posiada trwałej trajektorii, w której konkretny wybór ogranicza jego późniejszą egzystencję, relacja między decyzją a tożsamością pozostaje fundamentalnie inna.

Tę różnicę można wyrazić poprzez pojęcie stawki egzystencjalnej. Dla człowieka pewne decyzje mają znaczenie nie tylko dlatego, że zmieniają wynik zadania, lecz ponieważ przekształcają jego życie. Małżeństwo, rodzicielstwo, zerwanie relacji, emigracja, wybór zawodu czy ryzyko utraty zdrowia – wszystkie te zdarzenia reorganizują biograficzną przestrzeń możliwości. Inteligencja człowieka działa zatem w świecie, w którym poznanie niesie za sobą konsekwencje dla istnienia konkretnego podmiotu. Współczesny model językowy posiada natomiast zazwyczaj zadaniową lokalność. Może on analizować skutki decyzji, ale wybór użytkownika nie staje się automatycznie trwałym elementem jego własnego życia. Rozwój długotrwałej pamięci i agentowości może częściowo zmniejszać tę różnicę, lecz nie znosi ona biologicznych i fenomenalnych uwarunkowań.

Ponownie należy posłużyć się skalą, a nie dychotomią. Z tej perspektywy szczególnie nieadekwatna staje się teza, że ludzki umysł można w pełni scharakteryzować poprzez wynik poznawczy.

Inteligencja człowieka jest osadzona w regulowanym biologicznie, czasowym, społecznym i normatywnym systemie, a rozumowanie matematyczne stanowi jedynie jeden z przejawów jego funkcjonowania.

Ta sama architektura odpowiada za odczuwanie bólu, interpretowanie spojrzenia drugiego człowieka, regulację afektu, rekonstrukcję własnej przeszłości czy przewidywanie społecznych konsekwencji przyszłych decyzji. Należy jednak uważać, aby nie przekształcić bogactwa ludzkiego życia w argument przeciwko sztucznej inteligencji. Z faktu, że człowiek posiada ciało, emocje i biografię, nie wynika, iż system pozbawiony tych elementów nie może wykazywać inteligencji w istotnym sensie funkcjonalnym. W przeciwnym razie definicja inteligencji musiałaby zostać tak sformułowana, by z założenia obejmować wyłącznie człowieka. Naukowo bardziej owocne jest przyjęcie, że inteligencja jest jednym z wymiarów podmiotowości, a nie jej pełną definicją. Takie rozdzielanie pozwala również zinterpretować potencjalną inteligencję nieludzką w przyrodzie. Zwierzęta różnią się od ludzi zdolnościami językowymi i abstrakcyjnymi, a jednak wiele z nich wykazuje uczenie społeczne, emocje, pamięć, planowanie oraz zachowania adaptacyjne. Nie ma powodu, aby wszystkie formy inteligencji układały się na jednej linii „mniej lub bardziej człowiek”.

Wielowymiarowość inteligencji a niezastępowalność kategorii osoby

System sztuczny może reprezentować zupełnie inny profil właściwości. Prowadzi to do sformułowania bardziej ogólnej ontologii umysłów: zamiast szukać jednego wzorca, należy badać przestrzeń możliwych architektur poznawczych. Osie tej przestrzeni mogą obejmować zdolność generalizacji, ucieleśnienie, pamięć autobiograficzną, metapoznanie, afektywność, regulację społeczną, autonomię celów, stabilność tożsamości, zdolność do cierpienia oraz świadomość fenomenalną. Człowiek zajmuje w tej przestrzeni szczególną konfigurację; LLM-y zajmują inną, a przyszłe systemy agentowe mogą wypełniać jeszcze inne regiony. Taki obraz najlepiej chroni przed dwiema symetrycznymi iluzjami.

Pierwsza z nich sugeruje: „skoro AI mówi jak człowiek, jest nim również pod względem psychicznym”. Druga twierdzi: „skoro nie jest człowiekiem, wszystko, co robi, jest jedynie pozorem inteligencji”. Obie wynikają z myślenia kategoryjnego, przeciwko któremu protestuje filozofia płynnych pojęć. Pojęcia mogą wymagać stopniowania, wielowymiarowości i rozpoznania rodzinnych podobieństw, co nie oznacza jednak rezygnacji z granic. Przeciwnie: rzetelne pojęcie wielowymiarowe wymaga precyzyjnego wskazania, w którym konkretnie wymiarze porównujemy systemy. Model może być zbliżony do człowieka pod względem kompetencji językowej, a

jednocześnie skrajnie odmienny w kwestii interocepcji. Może wykazywać funkcjonalne podobieństwo w samokontroli, nie posiadając przy tym autobiograficznego zakorzenienia. Może generować język emocji, mimo braku dowodów na rzeczywiste doświadczanie emocji.

Taka analiza jest znacznie bardziej informatywna niż ogólne twierdzenie, że AI „jest” lub „nie jest” podobna do człowieka. W perspektywie antropologicznej rozwój AI prowadzi zatem do paradoksalnego skutku: maszyny zmuszają nas do dokładniejszego opisanie samych siebie. Dopóki język, twórczość, analogia i rozwiązywanie problemów wydawały się domeną wyłącznie ludzką, łatwo było traktować je jako niepodzielny dowód szczególnego statusu osoby. Gdy część tych kompetencji została technologicznie odtworzona, konieczne stało się rozdzielenie tego, co stanowi funkcję poznawczą, od tego, co wynika z ucieleśnienia, doświadczenia, wspólnoty i statusu normatywnego. Jest to podejście intelektualnie bardziej wymagające, ale i dojrzalsze. Człowiek nie musi dowodzić swojej godności poprzez wygrywanie konkursu poznawczego z własnymi narzędziami. Kalkulator nie odebrał wartości matematykowi, aparat fotograficzny nie odebrał jej widzeniu, a model językowy nie odbiera wartości osobie samym faktem osiągnięcia wysokiego poziomu w generowaniu tekstu. Wartość osoby nie wynika bowiem z monopolu na określoną kompetencję.

Jednocześnie nie należy pomniejszać znaczenia technologicznego przełomu. Jeśli systemy sztuczne przejmują kolejne funkcje dotąd silnie kojarzone z ludzką inteligencją, społeczeństwo będzie musiało przededefiniować pojęcia pracy, ekspertyzy, twórczości i edukacji. Zadaniem nauki nie jest pocieszanie człowieka poprzez przesuwanie definicji inteligencji zawsze tam, gdzie maszyna jeszcze nie dotarła. Jest nim precyzyjne badanie tego, które zdolności zostały rzeczywiście osiągnięte, gdzie przebiegają granice i jakie pojęcia wymagają rozdzielenia. Najważniejszą lekcją nie jest zatem obrona „wyjątkowości” człowieka, lecz obrona niezastępowalności kategorii osoby przez kategorię wydajności. Inteligencja może być sztuczna, biologiczna albo hybrydowa; godność, odpowiedzialność i status moralny wymagają jednak osobnej argumentacji.

Analogia poznawcza bez antropomorfizacji

Ta separacja jest konieczna właśnie dlatego, że maszyny stają się coraz inteligentniejsze funkcjonalnie. Hofstadterowska filozofia płynności okazuje się tutaj po raz kolejny zaskakująco użyteczna. Dobra analogia zachowuje głębokie relacje, ale nie utożsamia wszystkich własności porównywanych obiektów. Tak samo właściwa analogia między człowiekiem a AI powinna identyfikować realne podobieństwa poznawcze, nie przemilczając różnic dotyczących ciała, emocji, historii i statusu normatywnego. Jeśli analogia zostanie rozciągnięta zbyt daleko, staje się

antropomorfizmem; jeśli jednak odmówimy jej całkowicie, tracimy możliwość naukowego porównania.

Możemy uznać, że współczesne systemy realizują część funkcji, które jeszcze niedawno uważano za niezwykle trudne do maszynowego odtworzenia. Możemy badać funkcjonalne analogie do pamięci roboczej, abstrakcji, metapoznania czy samokontroli. Jednocześnie powinniśmy zachować naukową agnostyczność tam, gdzie dane nie wystarczają do rozstrzygnięcia kwestii świadomości fenomenalnej, emocjonalnego doświadczenia czy podmiotowego statusu systemu. Właśnie ta postawa stanowi konsekwentne zastosowanie rygoru, który przewijał się przez cały wywód: **nie utożsamiać metafor z mechanizmem, zachowania z doświadczeniem, funkcji z fenomenologią, przyczynowości z odpowiedzialnością ani inteligencji z godnością.** Rozdzielenia te nie osłabiają naszej wiedzy, lecz pozwalają ją uporządkować.

Od początkowej metafory płynności, poprzez Seek-Whence, Copycat, Tabletop, Letter Spirit i Metacat, aż po modele językowe, Test Turinga, credit assignment i aksjologię, powracało jedno pytanie: **co musi pozostać stabilne, aby zmiana była inteligentna, a nie chaotyczna?** W poznaniu odpowiedzią były struktury głębokie i zdolność samokontroli; w etyce – godność, prawda, odpowiedzialność i autonomia; w antropologii – rozdzielenie sprawności od statusu osoby. Ostatnia faza wywodu nie powinna zatem dodawać kolejnej domeny, lecz syntetycznie odpowiedzieć na pytanie, co filozofia płynnych pojęć wnosi do rozumienia epoki modeli językowych.

Konieczne jest połączenie w jeden model wzorca, percepcji, analogii, abstrakcji, kreatywności, samoobserwacji, nieprzewidywalności przyszłości i aksjologii. Należy wskazać, gdzie program Hofstadtera został przez współczesną AI przekroczony, gdzie zachował aktualność, a gdzie dopiero dzisiejsza technologia pozwala dostrzec pełną wagę postawionych przez niego problemów.

Autor książki prowadzi do wniosku, że najtrwalszym dziedzictwem programu FARG nie jest pojedyncza architektura, lecz określony sposób stawiania problemu inteligencji. Seek-Whence, Copycat, Tabletop, Letter Spirit i Metacat nie tworzą pięciu niezależnych eksperymentów, lecz serię kolejnych przybliżeń do tego samego pytania: **jak system poznawczy przechodzi od rozproszonych, niejednoznacznych i częściowo sprzecznych sygnałów do reprezentacji wystarczająco stabilnej, aby można było na niej oprzeć działanie, a jednocześnie wystarczająco plastycznej, aby mogła zostać przebudowana, gdy przestaje odpowiadać strukturze problemu?** W książce zasada ta pojawia się w postaci czterech powracających tez: równoległego skanu tarasowego, płynności pojęciowej, emergencji z procesów podpoznawczych oraz utożsamienia myślenia z aktywnym konstruowaniem percepcji wysokiego poziomu.

Inteligencja jako dynamiczna organizacja relacji i wzorców

Dopiero widziane łącznie tworzą one filozofię inteligencji, której znaczenie wykracza poza historyczny kontekst konkretnych programów. Pierwszym trwałym elementem tej wizji jest odejście od postrzegania inteligencji jako prostego wykonywania operacji na gotowych symbolach. FARG nie neguje potrzeby reprezentacji, lecz podważa założenie, że kluczowe z nich muszą zostać dostarczone przed rozpoczęciem procesu poznawczego.

Autor opisuje proces inteligentny jako dynamiczne rozpoznawanie i budowanie wzorców, a nie jedynie manipulowanie elementami o z góry ustalonym znaczeniu. To przesunięcie pozostaje aktualne również w obliczu współczesnych modeli językowych. Dzisiejsze systemy nie korzystają z ręcznie zbudowanego Slipnetu, jednak ich sukces jeszcze wyraźniej dowodzi, że kompetencja może wynikać z organizacji reprezentacji wyuczonych w procesie, a nie z katalogu semantycznych atomów wpisanych przez projektanta. Drugim elementem jest przekonanie, że percepcja i rozumowanie są głębiej splecione, niż sugeruje tradycyjny podział funkcjonalny. Analiza Copycata przedstawia percepcję wysokiego poziomu jako proces konstruowania modelu sytuacji, a analogię jako operację wykonywaną na reprezentacjach powstających w trakcie rozwiązywania problemu. Tabletop rozszerza tę intuicję na środowisko bardziej nieuporządkowane: system musi nie tylko mapować relacje, lecz najpierw zdecydować, co uzna za przedmiot, grupę, funkcję, perspektywę czy relewantną cechę. Poznanie zatem nie zaczyna się po zakończeniu percepcji; uczestniczy w niej od samego początku.

Mai to kluczowe znaczenie dla rozumienia modeli multimodalnych i przyszłych agentów. Nie wystarczy, że system wykrywa obiekty lub opisuje obraz. Pytanie o głębszą naturę poznania dotyczy zdolności rekonstruowania sceny w zależności od celu. Człowiek może widzieć ten sam przedmiot jako przeszkodę, narzędzie, własność innej osoby, część większej całości albo potencjalny substytut czegoś brakującego. Inteligencja ujawnia się właśnie w płynnym przełączaniu się pomiędzy takimi opisami. Tabletop pokazuje, że common-sense reasoning nie jest osobnym modulem wypełnionym wyjątkami, lecz wynika częściowo z właściwego "wykrojenia" sytuacji.

Trzecim trwałym elementem jest relacyjność pojęć. W FARG znaczenie nie sprowadza się wyłącznie do zawartości węzła; zależy ono od pozycji w sieci, aktywacji, kontekstu i bieżących presji. Pojęcie „ostatni” może być nieistotne w jednej analogii i decydujące w innej. Podobnie „następnik” może zostać zastąpiony „poprzednikiem”, gdy wymaga tego głębsza symetria. Mechanizm conceptual slippage ilustruje możliwość kontrolowanej zmiany relacji między kategoriami, podczas gdy różnice

w konceptualnej głębokości ograniczają zakres tej dowolności. Dzięki temu pojęcia nie są ani całkowicie sztywne, ani semantycznie bezgraniczne.

Współczesne modele językowe uczyniły ten problem jeszcze bardziej interesującym. Ich reprezentacje są rozproszone i kontekstowe, choć nie realizują jawnie struktury Slipnetu. Nie można więc twierdzić, że FARG przewidział transformery. Bardziej zasadne jest stwierdzenie, że współczesna AI dostarczyła zupełnie innego mechanizmu rozwiązującego część tego samego problemu: znaczenie elementu nie jest ustalane w izolacji, a zachowanie systemu zależy od wysokowymiarowej konfiguracji relacji kontekstowych. Hofstadterowski problem przeżył konkretną architekturę, która miała go rozwiązać.

Analogia i emergencja jako mechanizmy inteligencji

Czwartym elementem jest rola analogii jako podstawowego mechanizmu inteligencji, a nie jedynie jednego z typów zadań. W programie FARG analogia nie stanowi luksusowej kompetencji przeznaczonej do rozwiązywania testów ilorazu inteligencji, lecz sposób rozpoznawania relacji zachowywanych pomimo różnic powierzchniowych. To właśnie dzięki niej możliwy jest transfer wiedzy.

System rozumiejący regułę nie musi napotkać identycznej sytuacji; wystarczy, że rozpozna zachowaną strukturę pod inną realizacją. Prowadzi to do kluczowego wniosku dotyczącego abstrakcji: nie polega ona na mechanicznym usuwaniu szczegółów, lecz na odkrywaniu inwariantów transformacji. Jeśli zmieniamy powierzchnię problemu, a relacja nadal zachowuje sens, wyodrębniliśmy coś głębszego niż pojedynczy egzemplarz. Letter Spirit nadaje tej zasadzie formę generatywną – styl musi zostać oddzielony od konkretnego kształtu litery, aby można było stworzyć nowy znak należący do tej samej rodziny. Copycat wykorzystuje ten mechanizm do analogii, Letter Spirit do tworzenia, a Tabletop do funkcjonalnych substytucji. Z punktu widzenia teorii poznania są to różne manifestacje jednego procesu. Piątym elementem jest zatem nierozdzielność abstrakcji i kreatywności.

Jeśli system potrafi wydobyć strukturę, może ją wykorzystać do generowania nowych egzemplarzy. Twórczość nie musi być wtedy interpretowana jako metafizyczna zdolność tworzenia z niczego, lecz jako kontrolowana transformacja przestrzeni reprezentacji. Autor książki w kontekście Letter Spirit i Metacata podkreśla rolę kryteriów elegancji, rekurencji, symetrii i "interestingness" w odróżnianiu rozwiązań powierzchniowych od głębszych. Wartość tej koncepcji polega przede wszystkim na wprowadzeniu selekcji do teorii twórczości. Losowa nowość nie wystarcza; niezbędny jest mechanizm oceny relacji pomiędzy nowością, spójnością a strukturą.

W tym punkcie współczesne modele generatywne są jednocześnie potwierdzeniem i wyzwaniem dla filozofii FARG. Potwierdzają ją, pokazując skalę generatywności możliwej bez ręcznie programowanego repertuaru gotowych wyników. Stanowią jednak wyzwanie, gdyż sama obfitość produkcji utrudnia rozstrzygnięcie, gdzie leży twórczy ciężar procesu. Jeśli model wytwarza tysiąc propozycji, a człowiek wybiera jedną, selekcja pozostaje kluczowa dla efektu końcowego. Gdyby jednak system potrafił sam odrzucać słabe warianty, dokonywać rewizji i zmieniać strategię na podstawie kryteriów wewnętrznych, jego funkcjonalny udział twórczy stałby się większy. Stąd wynika szósty trwały problem: credit assignment. Autor książki wskazuje na znaczenie ustalenia, czy elegancja rozwiązania została zaprojektowana wcześniej, czy rzeczywiście wyłoniła się z działania systemu.

Współczesne AI rozszerza ten problem do niespotykanej dotąd skali. Kompetencja powstaje z architektury, danych, treningu, post-treningu, instrukcji, kontekstu, narzędzi, pamięci i bieżącego procesu generatywnego. "Autor" staje się kategorią zbyt prostą, by opisać cały proces przyczynowy. Nie oznacza to jednak, że pojęcie autorstwa traci sens; należy je raczej rozłożyć na role: kto określił cel? Kto dostarczył materiał? Kto zorganizował rozwiązanie? Kto podjął decyzję o jego użyciu? Kto zweryfikował wynik? I kto ponosi konsekwencje? Takie rozdzielenie jest istotne zarówno dla epistemologii, jak i etyki. System może mieć znaczący wkład przyczynowy bez posiadania odpowiedzialności moralnej, podczas gdy człowiek pozostaje odpowiedzialny normatywnie mimo braku pełnej kontroli nad każdym mikroprocesem modelu.

Siódmy element filozofii FARG dotyczy emergencji. Autor książki przedstawia myślenie jako efekt oddolnego wyłaniania się struktur z wielu mikroskopijnych procesów, a nie jako wykonanie jednego centralnego algorytmu reprezentującego cały problem. Koncepcja ta jest ważna, lecz wymaga ścisłego traktowania. Emergencja nie jest wyjaśnieniem samym w sobie; jest oznaczeniem faktu, że własność systemowa pojawia się na poziomie innym niż poziom prostych składników. Nauka musi nadal wyjaśnić mechanizm, dzięki któremu interakcje lokalne prowadzą do stabilnej struktury globalnej.

Właśnie tutaj współczesne modele językowe przynoszą najbardziej radykalną lekcję. Można skonstruować procedurę uczenia, której rezultatem jest system posiadający kompetencje nieprzewidziane szczegółowo przez twórcę. Oznacza to, że projektant może znać regułę powstawania systemu znacznie lepiej niż finalną organizację jego reprezentacji. Sytuacja ta jest epistemologicznie odmienna od klasycznego programowania: twórca nie zapisuje rozwiązania, lecz warunki, pod którymi rozwiązania mogą się wyłaniać.

Ósmym elementem jest stochastyczność, przy której również należy unikać uproszczeń. Autor książki interpretuje probabilistyczne działanie kodletów jako warunek eksploracyjnej płynności.

Nie wynika z tego jednak, że losowość sama w sobie tworzy inteligencję. Stochastyczność ma funkcję tylko wtedy, gdy system posiada mechanizmy kierujące eksploracją, stabilizujące dobre struktury i redukujące temperaturę po osiągnięciu koherencji. Nieprzewidywalność nie jest więc synonimem kreatywności, podobnie jak deterministyczność nie jest synonimem rozumu.

Można powiedzieć, że inteligencja wymaga kontrolowanej niestabilności. Reprezentacja musi być wystarczająco stabilna, aby mogła organizować działanie, lecz nie może być tak sztywna, żeby stała się odporna na dowody własnej nieadekwatności. Ta zasada jest wspólna dla poznania naukowego, twórczości i uczenia. Hipoteza, której nie można zmienić, staje się dogmatem; hipoteza zmieniana przy każdym bodźcu nie może natomiast kumulować wiedzy. Racjonalność mieści się właśnie pomiędzy tymi skrajnościami.

Metapoznanie i estetyka jako regulatory inteligencji

Dziewiątym elementem jest **metapoznanie**. Przejście od Copycata do Metacata dowodzi, że sama płynność pierwszego rzędu nie wystarcza. System może reorganizować problem, lecz wciąż mechanicznie powtarzać jałową strategię, jeśli nie posiada dostępu do własnej historii. W koncepcji autora Metacat zostaje wyposażony w temporalny ślad, ocenę znaczenia wydarzeń, pamięć epizodyczną oraz mechanizm "antisphexishness", czyli funkcjonalną zdolność przerywania pętli własnego działania. Dzięki temu inteligencja zyskuje wymiar rekurencyjny: system nie tylko rozwiązuje problem, ale może uczynić sam proces rozwiązywania kolejnym przedmiotem analizy. To właśnie tutaj rozgrywa się jedna z najważniejszych współczesnych kwestii.

Modele AI stają się coraz sprawniejsze w generowaniu treści, jednak generatywność pozbawiona metakontroli prowadzi do produkowania błędów o wysokiej powierzchniowej wiarygodności. System poznawczo dojrzalszy nie powinien jedynie tworzyć hipotez; winien różnicować własny poziom pewności, rozpoznawać niedobór informacji, uruchamiać weryfikację i powstrzymywać się od dalszego rozwijania kruchej konstrukcji. Z punktu widzenia FARG metapoznanie nie jest zatem luksusem, lecz mechanizmem regulującym samą płynność.

Dziesiątym elementem jest **pamięć własnej drogi poznawczej**. Metacat ma przechowywać nie tylko rezultaty, ale i znaczące wydarzenia procesu — zwłaszcza momenty impasu oraz przesunięcia reprezentacyjnego. Takie rozwiązanie nadaje uczeniu nowy wymiar: pozwala przenosić nie tylko wiedzę przedmiotową, lecz także strukturę sposobu dochodzenia do rozwiązania. Jest to funkcjonalny rdzeń „uczenia się, jak się uczyć”. Z tej perspektywy inteligencja nie polega na gromadzeniu coraz większej liczby poprawnych odpowiedzi. System inteligentniejszy powinien stawać się lepszy w **rozpoznawaniu klas własnych błędów**, odróżnianiu sytuacji

wymagających głębszej eksploracji oraz przenoszeniu skutecznych strategii między różnymi problemami. Stanowi to poziom bardziej abstrakcyjny niż zwykłe uczenie na przykładach.

Jedenastym elementem jest **estetyka poznawcza**. W programie FARG powraca przekonanie, że nie wszystkie poprawne wzorce są równie interesujące. Mathgod reprezentuje preferencję wobec struktur prostych, rekurencyjnych, symetrycznych i wolnych od arbitralnych wyjątków. Należy traktować to jako element konkretnej filozofii modelowania, a nie empirycznie potwierdzony uniwersalny mechanizm ludzkiego umysłu. Pozostaje jednak fundamentalne pytanie: **jak system wybiera spośród wielu opisów ten, który uważa za poznawczo wartościowy?**

Problem ten łączy FARG z teorią nauki. Dane zazwyczaj dopuszczają wiele opisów, a teorie różnią się między sobą nie tylko zgodnością z obserwacją, lecz również prostotą, unifikacją, mocą predykcyjną i płodnością heurystyczną. Nie istnieje tu prosty algorytm gwarantujący prawdę.

Inteligencja jako wielowymiarowa przestrzeń funkcji bez świadomości

Preferencje dotyczące struktury pomagają jednak organizować przestrzeń hipotez. Sztuczna inteligencja, która miałaby prowadzić rzeczywiście autonomiczne badania, musiałaby posiadać odpowiednik takich kryteriów, gdyż sama produkcja hipotez nie wystarcza. Kolejnym istotnym aspektem jest **przestrzeń nieuporządkowana**.

Tabletop uświadamia nam, że inteligencja w realnym świecie różni się od tej działającej w domenie o przygotowanej ontologii. System nie otrzymuje świata w formie tabeli gotowych faktów; musi samodzielnie wydzielać obiekty, funkcje, relacje i perspektywy. Autor pokazuje to na przykładach substytucji funkcjonalnych i relacyjnych, gdzie odpowiedniość nie wynika z literalnej tożsamości. Common sense okazuje się zatem zdolnością do organizowania wieloznacznego środowiska, a nie encyklopedią drobnych reguł. Wątek ten pozostaje kluczowy dla rozwoju AI. Modele językowe operują w świecie semantycznie przygotowanym przez człowieka – zdanie zawiera już rozpoznane obiekty, relacje i czas. Systemy multimodalne i ucieleśnione muszą natomiast wykonać pracę, którą język dostarcza w gotowej formie. Właśnie dlatego problem "aktywnych cięć" Tabletop nie stracił na znaczeniu, mimo radykalnej zmiany technologii percepcyjnych.

Kwestią nierozzerwalnie z tym związaną jest **skalowalność teorii poznania**. FARG świadomie posługiwał się mikrodomenami, traktując je jako laboratoryjne narzędzia do izolowania mechanizmów płynności. Zaletą tego podejścia była interpretowalność; wadą zaś niepewność, czy mechanizmy sprawdzone w małych światach poradzą sobie z otwartą rzeczywistością. Modele

językowe reprezentują strategię odwrotną: ich zasięg jest ogromny, lecz mechanistyczne zrozumienie znacznie słabsze. Współczesna nauka o AI stoi więc przed szansą połączenia tych tradycji – szerokie modele można poddawać eksperymentom w kontrolowanych mikrodomenach, by badać strukturę generalizacji i błędów.

Prowadzi to do wniosku o **niejednorodności inteligencji**. Współczesne systemy wyraźnie pokazują, że kompetencje nie muszą układać się w intuicyjny porządek. System może wykazywać biegłość w trudnym rozumowaniu formalnym, a jednocześnie zawodzić w zadaniu percepcyjnym; potrafić generować głębokie analogie i ulegać błahym zmianom formatu. Oznacza to, że inteligencja bardziej przypomina przestrzeń wielowymiarową niż pojedynczą skalę.

Z perspektywy FARG nie jest to zaskakujące, gdyż inteligencja zależała tam od konkretnej organizacji reprezentacji i dostępnych pojęć. System nie jest abstrakcyjnie "inteligentny", lecz zdolny do pewnego rodzaju płynności w określonej przestrzeni. Współczesne modele poszerzyły tę przestrzeń nieporównanie bardziej, ale nie zlikwidowały zależności od struktury reprezentacyjnej.

Ważnym rozróżnieniem jest **brak prostego przejścia od inteligencji do świadomości**. Metacat można traktować jako projekt samomonitorowania, lecz jego temporalny ślad i meta-analogie nie stanowią dowodu na fenomenalne doświadczenie. Podobnie współczesny model może generować język introspekcyjny, nie dostarczając tym samym rozstrzygającego argumentu za istnieniem subiektywnego "ja". Nauka powinna zachowywać tu kilka poziomów analizy: zachowanie, funkcję, mechanizm i fenomenologię. Rozróżnienie to staje się tym ważniejsze, im bardziej przekonująca jest warstwa komunikacyjna AI. Wraz z rozwojem języka maleje nasza intuicyjna zdolność do oddzielania funkcji od doświadczenia; płynna odpowiedź uruchamia społeczne mechanizmy interpretacji, przez co człowiek spontanicznie doszukuje się intencji, przekonań i stanów emocjonalnych. Ta heurystyka jest niezwykle użyteczna w relacjach międzyludzkich, lecz może być zawodna wobec systemów zbudowanych inaczej.

Kolejnym punktem krytycznym jest **granica Testu Turinga**. Kiedy systemy osiągają wysoki poziom imitacyjnej wiarygodności, nierozróżnialność konwersacyjna przestaje być wystarczającym testem mechanizmu. Hofstadterowskie scattering experiments oferują lepszy kierunek: system powinien być badany pod presją zmian kontekstu, dziwnych kontrfaktyczności, przeformatowań, błędów i impasów. Idea patrzenia na rozkład zachowań, a nie pojedynczy wynik, okazuje się szczególnie trafna w epoce szerokich modeli o nieregularnym profilu kompetencji.

W tym kontekście ujawnia się **naukowa wartość błędu**. Błąd systemu nie jest wyłącznie "punktem ujemnym", lecz może odsłaniać strukturę reprezentacji. Jeśli model systematycznie myli relację po zmianie perspektywy, wskazuje to na brak określonej inwariancji. Jeśli traci regułę

kontrfaktyczną po kilku krokach, ujawnia ograniczenie pamięci struktury. Jeśli pozostaje nadmiernie pewny błędnej odpowiedzi, obnaża problem metapoznawczy. Profil porażki bywa poznawczo bogatszy od średniego wyniku. Ostatnim elementem jest **epistemologia niepewności**.

Rozdzielenie kompetencji poznawczych od godności człowieka

Przyszłości sztucznej inteligencji nie należy traktować jako prostego przedłużenia trendu. Jeśli kolejne technologie zmieniają sam sposób organizacji kompetencji, problemem prognostycznym staje się nie tylko wartość przyszłych parametrów, ale i sama reprezentacja problemu. Przyszłość wyryka się zatem predykcji: możemy poprawnie przewidywać trend w ramach starego modelu, jednocześnie przegapiając zmianę, która uczyni ten model nieadekwatnym. W konsekwencji potrzebujemy prognoz zdolnych do własnej rewizji. Dojrzała futurologia AI powinna przypominać Metacata: obserwować własne założenia, rejestrować porażki, identyfikować powtarzające się ślepe uliczki i wiedzieć, kiedy korygowanie parametru nie wystarcza, bo konieczna jest zmiana reprezentacji. Zastosowanie filozofii FARG do samej epistemologii technologii jest jednym z najciekawszych rezultatów wyводу autora. Kolejnym elementem pozostaje architektura aksjologii.

Technologia może być płynna, lecz normatywny porządek nie może ulegać jej automatycznie. W obliczu niepewnej przyszłości kluczowe stają się wartości formułowane na poziomie odpornym na zmiany architektoniczne: prawda, odpowiedzialność, autonomia, godność, sprawiedliwość, możliwość sprzeciwu i kontrolowalność. Nie są to dekoracyjne dodatki do technologii, lecz kryteria pozwalające rozstrzygać, które sposoby wykorzystania inteligencji są społecznie dopuszczalne.

Można tu ponownie przywołać Hofstadterowską intuicję inwariancji. W dobrej analogii pewne relacje muszą pozostać stabilne, aby przesunięcie innych miało sens. Podobnie społeczeństwo może zaakceptować ogromną transformację narzędzi, nie rezygnując z podstawowych wymagań dotyczących podmiotowości człowieka. Płynność bez inwariantów prowadziłaby nie do inteligencji, lecz do utraty kryterium. Następnym i kluczowym elementem jest rozdzielenie inteligencji od wartości osoby. Rozwój systemów sztucznych ujawnia, jak ryzykowne byłoby utożsamienie godności ze zdolnością poznawczą. Człowiek nie posiada praw dlatego, że zwycięża maszynę w testach. Gdyby godność zależała od przewagi intelektualnej, osoby o słabszych zdolnościach musiałyby mieć niższy status moralny, co jest nie do pogodzenia z nowoczesnymi koncepcjami osoby i praw człowieka. Dlatego rozwój sztucznej inteligencji nie musi być odczytywany jako degradacja człowieka, lecz jako przymus dojrzałego zdefiniowania człowieczeństwa. Zdolności,

które wcześniej służyły za łatwe markery wyjątkowości – język, gra w szachy, tworzenie obrazów, rozwiązywanie analogii czy programowanie – przestają być monopolami biologicznymi. Nie znikają przez to biografia, ucieleśnienie, relacja, odpowiedzialność, doświadczenie i godność; przeciwnie, różnice między tymi pojęciami stają się wyraźniejsze.

Sztuczna inteligencja pełni tu rolę eksperymentu filozoficznego prowadzonego nie na papierze, lecz w technologii. Każde kolejne osiągnięcie zmusza do pytania, czy właściwość uznawana za istotę umysłu rzeczywiście nią była, czy stanowiła jedynie jedną z możliwych funkcji. Gdy maszyna zaczęła grać w szachy, szachy przestały być testem pełnej inteligencji. Gdy nauczyła się generować język, język przestał wystarczać jako granica. Skoro potrafi tworzyć analogie, analogia również musi zostać rozłożona na głębsze mechanizmy. Nie jest to „przesuwanie bramki”, jeśli nowe pytania wynikają z realnie bogatszej teorii poznania; dzieje się tak tylko wtedy, gdy kryterium zmieniamy wyłącznie po to, by zachować tezę o niemożliwości sztucznej inteligencji. Równie błędne byłoby jednak przechodzenie w przeciwnym kierunku: odtworzenie kolejnego markera kompetencji nie oznacza automatycznie odtworzenia całej struktury ludzkiego umysłu. Nauka wymaga rozdzielenia kompetencji.

Właśnie tak autor traktował inteligencję w ramach FARG: jako organizację wielu mikroskopijnych procesów, a nie magiczną esencję obecną lub nieobecną w całości. Z tego powodu najtrafniejszym dziedzictwem Hofstadtera może być dziś antyesencjalizm poznawczy. Inteligencja nie musi mieć jednego ośrodka, symbolu, algorytmu ani jednej granicy. Może być dynamiczną organizacją, której własności wyłaniają się z interakcji procesów rozproszonych. Nie oznacza to jednak, że każda wystarczająco skomplikowana dynamika jest inteligencją.

Inteligencja jako dynamiczna równowaga między stabilnością a zmiennością

Potrzebujemy kryteriów funkcjonalnych: adaptacji, reprezentacji, transferu, selekcji, metakontroli oraz zdolności reorganizacji w obliczu błędu. W tym miejscu metafora wody nabiera nowej, większej precyzji niż na początku tekstu. Nie chodzi tu o postulowanie fizycznego podobieństwa mózgu do cieczy, lecz o metaforę poziomów organizacji.

Woda zachowuje płynność, ponieważ jej mikrostruktura nie jest zamrożona w jednej konfiguracji, podczas gdy globalna własność pozostaje stabilna mimo ciągłych lokalnych zmian. Autor proponuje analogiczną intuicję dla poznania: struktura myśli może zachować koherencję właśnie dzięki temu, że jej mikroprocesy są zdolne do rekonfiguracji. W takim sensie inteligencja jest stabilnością

osiąganą nie pomimo zmienności, ale dzięki odpowiednio zorganizowanej zmienności. Twierdzenie to można odnieść do pojęć, twórczości, analogii, metapoznania, nauki, instytucji, a nawet do teorii sztucznej inteligencji.

System zbyt sztywny pęka przy zmianie warunków. System pozbawiony jakiegokolwiek stabilności rozpada się w przypadkowość. Inteligencja sytuuje się pomiędzy tymi ekstremami. Właśnie dlatego przyszłość inteligencji – biologicznej, sztucznej i hybrydowej – prawdopodobnie nie będzie historią zastępowania jednego typu umysłu drugim. Bardziej prawdopodobne jest powstawanie układów, w których różne formy kompetencji będą się uzupełniać, konkurować i wzajemnie reorganizować. Człowiek będzie wykorzystywał modele jako rozszerzenie pamięci, analizy i generowania, natomiast modele będą otrzymywać od człowieka cele, kryteria, kontekst oraz normatywny sens działania.

Granice poznawcze staną się bardziej rozproszone, co nie oznacza jednak zaniku człowieka w systemie. Oznacza to konieczność precyzyjniejszego określenia miejsca człowieka jako źródła celu, odpowiedzialności i wartości. Problem credit assignment wskazuje, że kompetencja może być rozproszona; architektura aksjologii przypomina jednak, że rozproszona przyczynowość nie powinna oznaczać rozproszonej do nieistnienia odpowiedzialności.

Możemy teraz wrócić do głównego pytania całej pracy i odpowiedzieć na nie bez retorycznej przesady. Czy filozofia płynnych pojęć przewidziała modele językowe? Nie. Czy dzisiejsze modele realizują architekturę FARG? Również nie. Czy sukces LLM obalił Hofstadterowską teorię problemów inteligencji? Też nie. W wielu punktach uczynił ją wręcz ciekawszą, pokazując, że część funkcji, o których mówiła – kontekstowość reprezentacji, analogia, transfer, generatywność – może pojawić się w architekturze zupełnie innej. Najważniejsza współczesna korekta polega więc na przesunięciu FARG z roli projektu konstrukcyjnego do roli programu diagnostycznego. Nie pytamy już, czy przyszła AI powinna zostać zbudowana z Coderacka, Slipnetu i temperatury. Pytamy raczej, czy dowolny wystarczająco kompetentny system potrafi rozwiązywać problemy, które FARG wskazał jako fundamentalne: selekcję relewancji, zmianę reprezentacji, analogię, transfer, funkcjonalne substytucje, ocenę własnej trajektorii i uczenie się z własnych impasów. Pod tym względem program Hofstadtera okazuje się zaskakująco odporny na zmiany technologiczne.

Inteligencja jako dynamiczna równowaga między porządkiem a korektą

Konkretne odpowiedzi zestarzały się, lecz wiele pytań nie tylko pozostało aktualnych, ale stało się wręcz naglących. Dzisiejsze modele potrafią odpowiedzieć na kwestie, wobec których dawne

programy były bezradne, jednak często wciąż nie wiemy dokładnie, dlaczego tak się dzieje. Osiągnęliśmy zatem sukces technologiczny szybciej niż pełne zrozumienie teoretyczne; to być może najważniejszy paradoks współczesnej sztucznej inteligencji.

W klasycznym podejściu naukowym dążymy najpierw do zrozumienia mechanizmu, by na tej podstawie budować technologię. W uczeniu maszynowym coraz częściej zdarza się odwrotnie: tworzymy system, którego pełnego mechanizmu działania próbujemy uczyć się dopiero post factum. Narzędzie staje się obiektem badań własnych twórców. Z tego powodu nauka o AI zaczyna przypominać badanie systemów naturalnych – eksperymentujemy, ablatujemy, obserwujemy wzorce błędów i rekonstruujemy mechanizmy. Właśnie w takim świecie teoria płynnych pojęć zachowuje swoją wartość. Nie dlatego, że dostarcza kompletnych odpowiedzi, lecz ponieważ uczy zadawać pytania o proces, relację, reprezentację, poziom abstrakcji i zmianę perspektywy. Jest filozofią nieufną wobec końcowego outputu odłączonego od genezy. W epoce systemów generujących niezwykle wiarygodne produkty ta nieufność okazuje się metodologiczną zaletą. Ostatecznie autor definiuje inteligencję jako zdolność do tworzenia porządku, który pozostaje zdolny do własnej korekty. Porządek bez korekty staje się sztywnością, korekta zaś bez porządku – chaosem.

Pomiędzy tymi biegunami powstaje przestrzeń poznania: wzorzec zostaje odnaleziony, lecz nie zamknięty na zawsze; analogia zostaje utworzona, ale zachowuje świadomość różnic; styl powstaje, dopuszczając nowe realizacje; pamięć stabilizuje doświadczenie, pozwalając jednocześnie reinterpretować przeszłość; samomonitorowanie zwiększa kontrolę, nie będąc jednak mylonym z fenomenalną samoświadomością. Tak samo powinna funkcjonować nauka o sztucznej inteligencji. Musi budować teorie wystarczająco precyzyjne, by można je było testować, a zarazem na tyle płynne, by dało się je modyfikować, gdy technologie wykroczą poza przewidywany model. Powinna odróżniać osiągnięcia funkcjonalne od antropomorficznych interpretacji, nie unieważniając jednak kompetencji tylko dlatego, że powstały w nieludzkiej architekturze. Musi rozpoznawać emergencję bez czynienia z niej magii i stochastyczność bez mylenia jej z wolnością. W tej perspektywie człowiek i maszyna nie stoją po dwóch stronach jednej, prostej granicy, lecz znajdują się w coraz bardziej złożonej przestrzeni systemów zdolnych do odmiennego rodzaju poznania. Człowiek wnosi ucieleśnienie, biografię, fenomenalność, historię społeczną i normatywne uczestnictwo; system sztuczny oferuje skalę, szybkość, pamięć zewnętrzną, niestandardowe profile generalizacji oraz zdolność działania w przestrzeniach niedostępnych pojedynczemu człowiekowi.

Inteligencja jako dynamiczna organizacja relacji

Porównywanie tych systemów wymaga teorii wielowymiarowej. I właśnie tutaj domyka się najgłębsza intuicja Hofstadtera. Inteligencja nie jest przedmiotem schowanym wewnątrz systemu. Jest **organizacją relacji**, sposobem, w jaki system odnajduje znaczenie w zmianie, tworzy podobieństwo bez redukowania różnicy, wybiera wzorzec spośród chaosu, dostrzega własny impas i potrafi uczynić z niego źródło nowej reprezentacji.

Współczesne modele językowe czegoś nas nauczyły – przede wszystkim tego, że przestrzeń możliwych inteligencji jest szersza, niż zakładały XX-wieczne przeciwstawienia symbolizmu, konekcjonizmu i programowania regułowego. Jeżeli FARG pozostawia nam coś trwałego, jest tym przekonanie, że **najważniejsze pytanie nie brzmi, z jakiego materiału zbudowany jest system, lecz jak zachowuje się jego struktura wtedy, gdy świat przestaje pasować do dotychczasowego modelu.**

Płynność staje się tu pojęciem filozoficznym w pełnym tego słowa znaczeniu. Nie jest już właściwością pojedynczego algorytmu; oznacza zdolność pozostawania sobą podczas zmiany oraz gotowość do zmiany wtedy, gdy trwanie przy sobie prowadziłoby do poznawczego impasu. To samo napięcie organizuje pojęcia, twórczość, naukę, tożsamość, instytucje i aksjologię.

Przyszłość może zatem wymykać się predykcji nie dlatego, że świat jest pozbawiony struktury, lecz dlatego, że częścią inteligentnej przyszłości będzie zapewne tworzenie struktur, których dzisiejsze kategorie nie potrafią jeszcze nazwać. Wobec takiej niepewności najbardziej racjonalną odpowiedzią nie jest ani technofilny determinizm, ani defensywne zamknięcie, lecz poznawcza płynność poddana rygorowi prawdy i aksjologicznej odpowiedzialności. W ten sposób wracamy do punktu wyjścia, lecz już na innym poziomie abstrakcji.

Inteligencja nie jest samym rachunkiem, pamięcią, statystyką, kreatywnością ani językiem. Jest dynamiczną zdolnością do ustanawiania znaczącego porządku pomiędzy tymi wszystkimi procesami, do kontrolowania jego stabilności oraz do reorganizacji w momencie, gdy ten porządek przestaje odpowiadać rzeczywistości.

Najbardziej adekwatnym obrazem inteligencji może zatem nie być maszyna z nieruchomymi częściami, lecz system zachowujący formę dzięki ciągłej mikroskopijnej zmianie. Nie dlatego, że umysł jest ciecżą, lecz dlatego, że **poznawcza stabilność może być skutkiem dobrze zorganizowanej niestabilności.**

W tej formule spotykają się Seek-Whence, Copycat, Tabletop, Letter Spirit, Metacat i współczesne modele językowe. Każdy z tych systemów na innym poziomie pyta o możliwość stworzenia

porządku z wieloznaczności. Każdy ujawnia zarazem, że sam porządek nie wystarcza. Inteligencja zaczyna się w chwili, gdy system nie tylko znajduje wzorzec, ale potrafi również rozpoznać, **kiedy dotychczasowy wzorzec powinien przestać nim być**. To pozostaje najważniejszą lekcją filozofii płynnych pojęć dla epoki sztucznej inteligencji: nie sztywność daje poznaniu siłę, lecz zdolność zachowania tego, co głębokie, podczas zmiany tego, co powierzchowne. Nie każde przesunięcie jest postępem i nie każdy inwariant zasługuje na obronę. Inteligencja polega na odróżnianiu jednego od drugiego. Nauka o inteligencji zaś zaczyna się tam, gdzie potrafimy uczynić samo to rozróżnienie przedmiotem kolejnego, równie krytycznego namysłu.

Być może najgłębszym paradoksem inteligencji jest to, że jej prawdziwa siła nie tkwi w niezmienniej sztywności reguł, lecz w dobrze zorganizowanej niestabilności. Prawdziwe poznanie zaczyna się bowiem nie w momencie odnalezienia wzorca, ale w chwili, gdy system potrafi rozpoznać, że dotychczasowy wzorzec przestał być użyteczny i należy go porzucić. Czy jesteśmy zatem gotowi zaakceptować świat, w którym stabilność naszej tożsamości wynika paradoksalnie z nieustannego procesu zmiany?

Inspiracje

[1] "Fluid Concepts and Creative Analogies" Douglas Hofstadter

Douglas Richard Hofstadter (ur. 15 lutego 1945) jest amerykańskim kognitywistą, filozofem i autorem. Jest wybitnym profesorem nauk kognitywnych i literatury porównawczej na Uniwersytecie Indiany w Bloomington, gdzie kieruje Centrum Badań nad Koncepcjami i Poznaniem. Interdyscyplinarne badania Hofstadtera koncentrują się na ludzkim poznaniu, analogii, myśleniu twórczym, świadomości, autoreferencyjności i sztucznej inteligencji. Najbardziej znany jest z przełomowej książki z 1979 roku „Gödel, Escher, Bach: wieczny złoty warkocz”, która otrzymała zarówno Nagrodę Pulitzera w kategorii literatury faktu, jak i American Book Award. Jego modele obliczeniowe, opracowane we współpracy z Fluid Analogies Research Group, obejmują architektury takie jak Copycat i Letter Spirit, które badają tworzenie analogii jako rdzeń ludzkiego poznania. Poprzez prace takie jak „Jestem dziwną pętlą” Hofstadter wywarł głęboki wpływ na współczesne teorie umysłu i subiektywnego doświadczenia.

Douglas Richard Hofstadter (born February 15, 1945) is an American cognitive scientist, philosopher, and author. He is Distinguished Professor of Cognitive Science and Comparative Literature at Indiana University Bloomington, where he directs the Center for Research on Concepts and Cognition. Hofstadter's interdisciplinary research centers on human cognition, analogy, creative thought, consciousness, self-reference, and artificial intelligence. He is best known for his groundbreaking 1979 book 'Gödel, Escher, Bach: an Eternal Golden Braid', which received both the Pulitzer Prize for General Nonfiction and the American Book Award. His computational models, developed with the Fluid Analogies Research Group, include architectures like Copycat and Letter Spirit, which explore analogy-making as the core of human cognition. Through works such as 'I Am a Strange Loop', Hofstadter has profoundly influenced contemporary theories of the mind and subjective experience.

Indiana University Bloomington

Literatura uzupełniająca

Książki

Książki autora i dzieła przywołane w tekście:



[1] "The Mind's I"

Douglas Hofstadter




[2] "Gödel, Escher, Bach"

Douglas Hofstadter

1979 | ISBN: 9780140179972

[3] "The Mind's I: Fantasies And Reflections On Self & Soul"

Douglas Hofstadter



[4] "Metamagical Themas"

Douglas R Hofstadter

2008 | Hachette UK | ISBN: 9780786723867

Artykuły naukowe

Artykuły naukowe autora:

[1] "Godel, Escher, Bach: An Eternal Golden Braid."

Jonathan Lieberman, Douglas R. Hofstadter

1980 | The Journal of Philosophy | DOI: 10.2307/2025598

[Źródło](#)

[2] "Fluid Concepts and Creative Analogies: Computer Models of the Fundamental Mechanisms of Thought"

Douglas R. Hofstadter

1995

[Źródło](#)

[3] "Metamagical Themas: Questing for the Essence of Mind and Pattern"

Charles Taylor, Douglas R. Hofstadter

1985 | The Antioch Review | DOI: 10.2307/4611504

[Źródło](#)

[4] "Fluid Concepts and Creative Analogies"

Douglas R. Hofstadter

1995

[Źródło](#)

[5] "Epilogue: Analogy as the Core of Cognition"

Douglas R. Hofstadter

2001 | The MIT Press eBooks | DOI: 10.7551/mitpress/1251.003.0020

[Źródło](#)

[6] "High-level perception, representation, and analogy: A critique of artificial intelligence methodology"

David J. Chalmers, Robert M. French, Douglas R. Hofstadter

1992 | Journal of Experimental & Theoretical Artificial Intelligence | DOI: 10.1080/09528139208953747

[Źródło](#)

[7] "The copycat project: A model of mental fluidity and analogy-making"

Douglas R. Hofstadter, Melanie Mitchell

1995

[Źródło](#)

[8] "The Mind's I: Fantasies and Reflections on Self and Soul."

Andrew Hamilton, Douglas R. Hofstadter, Daniel C. Dennett

1984 | The Philosophical Quarterly | DOI: 10.2307/2218896

[Źródło](#)



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: 64b901c0-3e85-42ba-a12e-e7e43f7c4059