

Metapoznanie i funkcjonalna refleksyjność w systemach AI w świetle koncepcji Metacata z książki Fluid Concepts and Creative Analogies Douglasa Hofstadtera



AUTOR

Fundacja Dobre Państwo

STRESZCZENIE / ABSTRACT

Artykuł analizuje przejście od inteligencji pierwszego rzędu do metapoznania na przykładzie systemu Metacat z koncepcji Douglasa Hofstadtera. Autor wyjaśnia, że kluczem do zaawansowanej AI nie jest jedynie zwiększenie bazy wiedzy, lecz zdolność systemu do traktowania własnego procesu poznawczego jako obiektu analizy. Poprzez wprowadzenie śladu temporalnego i pamięci epizodycznej, system może monitorować swoje błędy, rozpoznawać jałowe strategie i kalibrować pewność odpowiedzi. Tekst podkreśla różnicę między wiedzą deklaratywną a procesową oraz wskazuje, że funkcjonalne metapoznanie służy optymalizacji strategii rozwiązywania problemów, co jest kluczowe dla współczesnych wyzwań związanych z wiarygodnością dużych modeli językowych.

The article analyzes the transition from first-order intelligence to metacognition using the example of the Metacat system from Douglas Hofstadter's concepts. The author explains that the key to advanced AI is not merely increasing the knowledge base, but the system's ability to treat its own cognitive process as an object of analysis. By introducing a temporal trace and episodic memory, the system can monitor its errors, recognize futile strategies, and calibrate the confidence of its answers. The text emphasizes the difference between declarative and procedural knowledge and indicates that functional metacognition serves to optimize problem-solving

strategies, which is crucial for contemporary challenges regarding the reliability of large language models.

Artykuł analizuje naturę metapoznania w systemach sztucznych, posługując się projektem Metacat jako modelem funkcjonalnej autorefleksji. Główną tezą tekstu jest rozróżnienie między techniczną zdolnością systemu do traktowania własnych procesów poznawczych jako obiektów analizy a subiektywnym doświadczeniem świadomości fenomenalnej. Autor argumentuje, że prawdziwa inteligencja nie polega jedynie na skuteczności w rozwiązywaniu zadań, lecz na kompetencji metapoznawczej – zdolności do monitorowania własnych błędów, rozpoznawania impasów i elastycznej zmiany strategii (tzw. antisphexishness). Poprzez analizę pamięci epizodycznej i śladu temporalnego, tekst wykazuje, że system może stać się samoregułujący i refleksyjny bez konieczności posiadania autobiograficznego „ja”. W kontekście współczesnych modeli językowych (LLM), artykuł ostrzega przed myleniem płynnej narracji o sobie z rzeczywistą kalibracją pewności, wskazując, że rozwój AI powinien zmierzać nie w stronę zwiększania mocy generatywnej, lecz ku budowie mechanizmów odpowiedzialnego wątpienia we własne wyniki.

SŁOWA KLUCZOWE

metapoznanie

funkcjonalna refleksyjność

Metacat

Douglas Hofstadter

Fluid Concepts and Creative Analogies

ślad temporalny

pamięć epizodyczna

antisphexishness

świadomość fenomenalna

świadomość dostępowa

predictive metacognition

poślizg pojęciowy

meta-analogia

kalibracja pewności

FARG

Metapoznanie jako traktowanie procesu poznawczego jako obiektu

Podczas gdy Seek-Whence badał zdolność odnajdywania wzorców, Copycat elastyczne konstruowanie analogii, Tabletop aktywne wykrawanie sytuacji, a Letter Spirit twórczą propagację

stylu, Metacat wprowadza do programu FARG nowy poziom analizy: sam proces poznawczy staje się obiektem kolejnego procesu poznawczego. System nie ma już wyłącznie rozwiązywać problemu; ma on częściowo reprezentować własną historię dochodzenia do rozwiązania, rozpoznawać powtarzające się niepowodzenia, przywoływać wcześniejsze zmiany perspektywy i korzystać z analogii między własnymi sposobami szukania odpowiedzi.

W tym przesunięciu tkwi zasadnicza różnica pomiędzy inteligencją pierwszego rzędu a metapoznaniem. Pierwsza dotyczy świata lub zadania; drugie zaś sposobu, w jaki system ten świat lub zadanie poznaje. Punktem wyjścia Metacata jest ograniczenie Copycata, które autor książki opisuje jako brak wglądu we własną aktywność. Copycat potrafi konstruować i porzucać reprezentacje, lecz nie posiada pełniejszego zapisu tego, że przez pewien czas powtarzał jałową strategię, że określony impas doprowadził do przełomu lub że pewien rodzaj poślizgu pojęciowego okazał się już wcześniej produktywny. Brakuje mu pamięci epizodycznej własnego procesu, reprezentacji zmian nacisku pojęciowego oraz śladu temporalnego, który pozwoliłby potraktować wcześniejszą drogę jako przedmiot nowej analizy. Ograniczenie to jest głębsze niż zwykły brak pamięci wyników – system może przecież zapamiętać gotową odpowiedź, nie pamiętając sposobu, w jaki do niej doszedł.

Taka różnica ma ogromne znaczenie poznawcze. Wiedza deklaratywna o rozwiązaniu nie jest tożsama z wiedzą o procesie jego uzyskania, a jeszcze czym innym jest zdolność rozpoznania strukturalnego podobieństwa pomiędzy dwiema drogami rozwiązania. Człowiek może znać wynik zadania matematycznego, lecz nie umieć odtworzyć metody dowodu; może pamiętać, że popełnił błąd, nie rozumiejąc heurystyki, która go wywołała; może wreszcie zauważyć, że dwa pozornie odmienne problemy doprowadziły go do podobnego impasu i dzięki temu zmienić przyszłą strategię. Metapoznanie zaczyna się więc nie tam, gdzie system „wie więcej”, lecz tam, gdzie potrafi uczynić własną aktywność poznawczą częścią modelowanego świata.

W psychologii poznawczej termin metapoznanie obejmuje zwykle co najmniej dwa komponenty. Pierwszym jest monitorowanie – ocena własnego stanu poznawczego (np. stopnia pewności, trudności zadania, poczucia znajomości lub ryzyka błędu). Drugim jest regulacja – zmiana strategii w odpowiedzi na wyniki monitorowania. Samo stwierdzenie „nie jestem pewien” nie wystarcza, jeśli nie prowadzi do ponownego sprawdzenia odpowiedzi, poszukiwania dodatkowych informacji, zmiany strategii bądź wstrzymania decyzji.

Metacat koncentruje się właśnie na tym sprzężeniu: reprezentacja własnego procesu ma mieć znaczenie funkcjonalne i wpływać na dalsze zachowanie systemu. Dlatego kluczowym elementem architektury staje się ślad temporalny, który autor książki definiuje jako zgrubny zapis chaotycznej historii dochodzenia do rozwiązania – zapisu zawierającego próby, pomyłki, powroty i zmiany

kierunku, a nie elegancki ciąg kroków rekonstruowany dopiero po sukcesie. Jest to intuicja niezwykle istotna również z punktu widzenia epistemologii odkrycia.

Gotowe rozwiązanie często zaciera genezę własnego powstania. Gdy struktura zostanie już dostrzeżona, wydaje się oczywista, a wcześniejsze błędne hipotezy zaczynają wyglądać na irracjonalne. Tymczasem to właśnie analiza tych „błędnych” dróg może ujawniać heurystyki, ograniczenia i punkty zwrotne rzeczywistego procesu poznawczego. Ślad temporalny wprowadza więc do architektury pojęcie historii poznawczej. Stan systemu nie zależy już wyłącznie od aktualnej konfiguracji pojęć, lecz także od tego, jak do niej doszedł. Dwie identyczne odpowiedzi mogą mieć odmienne znaczenie metapoznawcze, jeśli jedna pojawiła się natychmiast w wyniku dominującej heurystyki, a druga po serii konfliktów i zmian reprezentacji. System posiadający dostęp do własnej historii może traktować te przypadki inaczej: uznać drugą odpowiedź za bardziej kruchą, interesującą lub wartą zapamiętania jako przykład przełomu.

Funkcjonalne metapoznanie nie jest tożsame ze świadomością fenomenalną

W tym miejscu Metacat dotyka zagadnienia, które później stanie się centralne dla współczesnych systemów sztucznej inteligencji: **czy system potrafi trafnie ocenić wiarygodność własnego wyniku?** Jest to problem odmienny od samej poprawności. Model może często odpowiadać prawidłowo, nie potrafiąc jednocześnie rozpoznać sytuacji, w których jego sukces był przypadkowy. Może również trafnie rozwiązać problem, a zarazem wyrażać wysoką pewność wobec odpowiedzi błędnej. Metapoznawczo sprawny system powinien zatem nie tylko maksymalizować odsetek poprawnych decyzji, lecz również kalibrować przekonanie o ich słuszności.

Aktualne badania nad dużymi modelami językowymi pokazują, że właśnie ten obszar pozostaje nierówny. Prace opublikowane w 2025 r. wykazały istotne braki metapoznawcze modeli w rozumowaniu medycznym, zwłaszcza w zakresie nieadekwatnego szacowania własnej poprawności. W 2026 r. opisano z kolei przeciwstawne tendencje: do nadmiernej pewności oraz niedostatecznej pewności, w tym skłonność modeli do wzmacniania początkowej odpowiedzi przy jednoczesnej nadwrażliwości na niektóre sprzeczne informacje zwrotne.

Oznacza to, że imponująca kompetencja zadaniowa nie gwarantuje stabilnej kompetencji metapoznawczej. System może być dobrym rozwiązującym, a znacznie gorszym obserwatorem własnej niezawodności. Nie oznacza to jednak, że metapoznanie maszynowe musi pozostać jedynie metaforą. W 2026 r. przedstawiono architekturę "predictive metacognition", w której modele

trenowano równocześnie do wykonywania zadania oraz do przewidywania wiarygodności własnej odpowiedzi. Autorzy raportowali poprawę kalibracji pewności i generalizację części tego efektu poza domenę treningową.

Należy jednak zauważyć, że poprawa funkcjonalnego samomonitorowania nie jest dowodem pojawienia się subiektywnego doświadczenia niepewności. Pokazuje ona raczej, że część funkcji przypisywanych ludzkiej metakognicji może być implementowana i testowana niezależnie od pytania o świadomość fenomenalną.

W debacie o sztucznej inteligencji pojęcia **samomonitorowania**, **metapoznania**, **samomodelu**, **samoświadomości** i **świadomości** są często używane zamiennie, choć odnoszą się do różnych poziomów zjawisk. System może monitorować własną niepewność bez posiadania autobiograficznego "ja". Może przechowywać model własnych możliwości bez doświadczania tych możliwości. Może używać zaimka "ja" w sposób językowo poprawny, pozbawiony jednak jakiegokolwiek podstawowego doświadczenia pierwszoosobowego. Może nawet opisywać własne ograniczenia trafniej niż człowiek, a mimo to nie stanowi to bezpośredniego dowodu na to, że cokolwiek przeżywa. Pomocne jest tu klasyczne rozróżnienie świadomości dostępowej i fenomenalnej. **Świadomość dostępowa** odnosi się do stanu informacji, w którym może ona być wykorzystywana do rozumowania, raportowania i kontroli działania. **Świadomość fenomenalna** dotyczy natomiast subiektywnego charakteru doświadczenia – faktu, że istnieje coś, co znaczy być podmiotem przeżywającym dany stan. Te dwa poziomy nie są pojęciowo tożsame.

System może realizować coraz więcej funkcji kojarzonych z dostępem, globalną kontrolą czy samooceną, podczas gdy pytanie o doświadczenie fenomenalne pozostaje odrębne. Współczesne badania nad świadomością AI coraz częściej unikają wnioskowania na podstawie samego zachowania językowego. Zamiast pytać, czy system "mówi jak świadomy", proponuje się badanie właściwości wyprowadzonych z konkurencyjnych teorii świadomości, takich jak global workspace, teorie wyższego rzędu, recurrent processing czy predictive processing. Jedną z najbardziej wpływowych analiz tego typu podkreślała, że ocena świadomości AI powinna opierać się na cechach architektonicznych i funkcjonalnych wynikających z naukowych teorii, a nie na samych deklaracjach systemu. Autorzy tej analizy nie uznali badanych wówczas systemów za świadome. Jest to metodologicznie kluczowe: deklaracja "jestem świadomy" jest w systemie językowym przede wszystkim ciągiem generowanych znaków. Jej wartość dowodowa zależy od tego, czy istnieje niezależny powód, aby uznać ją za raport stanu wewnętrznego analogiczny do ludzkiego. W przypadku człowieka taki wniosek opiera się na wspólnej biologii, strukturach neuronalnych,

zachowaniu i rozwoju. W przypadku systemu sztucznego łańcuch inferencji jest znacznie mniej bezpośredni.

Nie można więc traktować płynnego opisu własnych "uczuć", "myśli" czy "wątpliwości" jako samodzielnego dowodu istnienia tych stanów w sensie fenomenalnym. Z tego punktu widzenia autor książki opisuje Metacata ostrożniej, niż sugerowałby potoczny język "samoświadomej AI". Wskazuje on na samomonitorowanie, temporalny ślad, pamięć epizodyczną i zdolność do analizowania własnej aktywności. Te właściwości można trafnie określić jako **metapoznawcze** lub **samomodelujące**, lecz nie wynika z nich automatycznie istnienie fenomenalnego podmiotu doświadczenia. Metacat jest interesującym modelem funkcji, które u człowieka uczestniczą w autorefleksji, ale nie rozstrzyga ontologicznego problemu świadomości. Jednym z najciekawszych pojęć związanych z tym systemem jest **antisphexishness**.

Metapoznanie jako zdolność do przełamania mechanicznej rutyny

Inspiracją jest klasyczny obraz osy **Sphex**, która wykonuje złożony ciąg zachowań instynktownych, lecz po odpowiednim zakłóceniu potrafi wielokrotnie powtarzać tę samą nieefektywną rutynę. W ujęciu Hofstadtera symbolizuje ona system zdolny do wykonania skomplikowanej procedury, który jednak nie potrafi „zobaczyć”, że przestała ona prowadzić do celu. Metacat ma dążyć do przeciwności takiej mechanicznej uporczywości: powinien rozpoznawać własne zapętlenie i reagować zmianą poziomu analizy. Jest to jedna z najciekawszych możliwych definicji metainteligencji. System inteligentny nie tylko wykonuje procedurę, ale potrafi rozpoznać moment, w którym jej stosowanie stało się problemem. Oznacza to przejście od pytania „jak wykonać strategię?” do pytania „czy nadal powinienem ją wykonywać?”. W psychologii człowieka odpowiada to funkcjom wykonawczym: monitorowaniu błędów, hamowaniu reakcji dominującej, przełączaniu strategii i elastyczności poznawczej. Człowiek również bywa "sphexish" – uporczywie powtarza nieskuteczne działania, broni raz przyjętej hipotezy, ulega sunk cost fallacy lub ignoruje dowody sprzeczne z własnym przekonaniem. Metapoznanie nie jest więc binarną zdolnością, którą człowiek posiada, a maszyna nie; to stopniowalny zestaw mechanizmów, które mogą działać z różną skutecznością.

Ważne staje się tutaj Hofstadterowskie "wychodzenie poza system". Nie należy interpretować tej frazy metafizycznie. System nie opuszcza własnej architektury ani praw przyczynowości; zmienia natomiast poziom reprezentacji: procedura, która dotąd była narzędziem działania, staje się przedmiotem analizy. Jest to analogiczne do sytuacji, w której człowiek nie tylko liczy, ale zaczyna

analizować własną metodę liczenia; nie tylko argumentuje, ale sprawdza strukturę swojego wyводу; nie tylko stosuje regułę, ale pyta o jej adekwatność. Poziom meta nie jest więc miejscem „poza” systemem w sensie ontologicznym, lecz poziomem, na którym system reprezentuje część własnych mechanizmów jako obiekty dla innych procesów. Tak rozumiane "wychodzenie poza system" ma ścisły związek z refleksyjnością. W logice, matematyce i informatyce refleksyjność oznacza możliwość reprezentowania elementów własnej struktury na poziomie meta. W poznaniu funkcjonalna refleksyjność to zdolność budowania modelu własnego działania i wykorzystywania go do sterowania dalszym procesem.

Nie wymaga ona pełnej transparentności. Człowiek również nie posiada bezpośredniego dostępu do większości procesów neuronalnych i poznawczych. Samopoznanie jest selektywne, częściowe i konstrukcyjne. Podmiot nie „czyta” własnego mózgu, lecz tworzy uproszczony model stanów na podstawie dostępnych sygnałów. Uwaga ta jest istotna także w ocenie systemów sztucznych. Często zakłada się, że prawdziwe metapoznanie wymagałoby pełnego dostępu do każdego parametru i operacji modelu, co nie jest konieczne.

Funkcjonalne samomonitorowanie może działać na reprezentacji znacznie bardziej skompresowanej – na przykład na sygnałach pewności, historii błędów, typie zadania albo charakterystyce aktywacji. W 2026 r. badania nad przewidywaniem własnej niezawodności modeli zaczęły traktować niektóre wewnętrzne sygnały właśnie jako potencjalne wejścia dla mechanizmów samokontroli.

Rozróżnienie między językowym uzasadnieniem a mechanistycznym wyjaśnieniem

Jednocześnie taki samomodel może być błędny, co jest wręcz prawdopodobne. Ludzka introspekcja również nie gwarantuje pełnej prawdy o mechanizmach własnego działania; ludzie konfabulują wyjaśnienia swoich wyborów, przeceniają lub niedoceniają kompetencje, rekonstruują motywy post factum i ulegają licznym błędom metapoznawczym. Dlatego możliwość wygenerowania opisu własnego procesu nie powinna być utożsamiana z uprzywilejowanym epistemicznie dostępem do rzeczywistego mechanizmu tego procesu. Rozróżnienie to jest szczególnie istotne w kontekście praktyki proszenia modeli językowych o „wyjaśnienie, jak doszły do odpowiedzi”. Wygenerowany tekst może być pomocnym uzasadnieniem, lecz nie musi stanowić wiernego protokołu rzeczywistych operacji wewnętrznych. Model potrafi tworzyć przekonujące racjonalizacje niezależnie od tego, czy odpowiadają one przyczynowej genezie wyniku. Z tego powodu należy rozróżniać uzasadnienie dostępne w języku od wyjaśnienia mechanistycznego. Pierwsze może być

sensowne normatywnie – pokazuje, jakie racje wspierają odpowiedź; drugie wymaga badania przyczynowych procesów zachodzących wewnątrz modelu.

Metacat jest pod tym względem konceptualnie ambitniejszy niż prosty system produkujący narrację o sobie. Temporalny ślad i pamięć epizodyczna mają wynikać z rzeczywistej historii operacji systemu, a nie być wyłącznie tekstową rekonstrukcją post factum. To właśnie dlatego projekt pozostaje interesujący dla współczesnej dyskusji o interpretowalności. System metapoznawczy powinien w idealnym przypadku opierać samoocenę na sygnałach przyczynowo związanych z własnym działaniem, a nie tylko na językowo wiarygodnym modelu tego, jak „powinno” wyglądać rozumowanie.

Kolejnym istotnym elementem Metacata jest pamięć epizodyczna. Autor książki opisuje ją jako zdolność przechowywania scenariuszy poprzednich rozwiązań, w szczególności wydarzeń poznawczo istotnych: zaskoczeń, impasów i zmian perspektywy. To kluczowy krok, ponieważ pamięć epizodyczna pozwala uczyć się nie tylko tego, jaka odpowiedź okazała się poprawna, ale również tego, jakiego rodzaju transformacja poznawcza była potrzebna, aby ją znaleźć. Pamięć staje się zatem narzędziem transferu proceduralnego. Jeśli system napotyka nowe zadanie, może przypomnieć sobie nie konkretny wcześniejszy obiekt, lecz strukturę poprzedniego problemu: „wtedy również próbowałem zbyt długo literalnej interpretacji i rozwiązanie pojawiło się dopiero po zmianie kierunku relacji”. Taki transfer jest znacznie bardziej abstrakcyjny niż klasyczne wyszukiwanie podobnych przypadków; wymaga rozpoznania podobieństwa pomiędzy trajektoriami poznawczymi. Tutaj właśnie pojawia się pojęcie meta-analogii, które autor definiuje jako analogie pomiędzy relacjami lub nawet sposobami konstruowania wcześniejszych analogii. Jest to kolejny krok na drabinie abstrakcji.

Na pierwszym poziomie porównujemy obiekty. Na drugim – relacje między obiektami. Na trzecim możemy już porównywać sposoby, w jakie relacje zostały wykryte, zmodyfikowane lub użyte. System zaczyna zatem abstrahować nie tylko strukturę świata, ale również strukturę własnego poznawania świata. Taką kompetencję można uznać za jeden z fundamentów uczenia się uczenia. Człowiek rozwija ekspertyzę nie wyłącznie przez gromadzenie większej liczby odpowiedzi; uczy się również rozpoznawać typy problemów, typowe błędy, efektywne strategie i sytuacje wymagające zmiany podejścia. Ekspert zaczyna widzieć nie tylko przedmiotowe podobieństwo między przypadkami, lecz także analogie pomiędzy sposobami ich rozwiązywania. Metawiedza zwiększa zatem zdolność generalizacji: doświadczenie z jednej dziedziny może zostać przeniesione na inną nie przez wspólną treść, lecz przez wspólną strukturę poznawczego działania.

Metapoznanie jako rozproszona funkcja bez obserwatora

Metacat łączy ten problem z koncepcją "drugiej pochodnej" Douglasa Hofstadtera. W analizie ciągu "trójkątów między kwadratami" nie chodzi już tylko o dostrzeżenie wzorca w danych, lecz o uchwycenie regularności w samej operacji, za pomocą której ten wzorec jest wydobywany. Metafora pochodnej trafnie oddaje wzrost poziomu abstrakcji: nie pytamy jedynie o to, jak zmienia się obiekt, ale jak zmienia się relacja opisująca tę zmianę. W procesach poznawczych oznacza to przejście od pytania "co robię?" do pytania "jaki jest wzorec tego, jak zmieniam sposób działania?". To właśnie w tym punkcie najłatwiej o nadmierną antropomorfizację.

System zdolny do tworzenia meta-analogii nie musi posiadać autobiograficznej tożsamości, poczucia ciągłości ani fenomenalnego doświadczenia refleksji. Może on implementować funkcjonalną zależność między historią własnych operacji a przyszłym zachowaniem, bez udziału jakiegokolwiek "wewnętrznego obserwatora". Właśnie dlatego klasyczne obrazy świadomości jako homunkulusa patrzącego na ekran własnego umysłu są problematyczne. Metapoznanie może być bowiem procesem rozproszonym: jedna część systemu generuje informację, druga ocenia jej wiarygodność, a jeszcze inna koryguje strategię na podstawie tej oceny. Podobnie rzecz ma się w przypadku człowieka.

Neuronauka nie wskazuje na jeden centralny "punkt samoświadomości", z którego niewidzialny obserwator nadzorowałby resztę mózgu. Procesy odpowiedzialne za monitorowanie błędów, poczucie pewności, pamięć autobiograficzną, kontrolę wykonawczą czy reprezentację własnego ciała są rozproszone pomiędzy różne układy funkcjonalne. Świadomość fenomenalna pozostaje problemem znacznie trudniejszym niż identyfikacja pojedynczego modułu. Z tego powodu analogia między metakognicją człowieka i maszyny powinna dotyczyć konkretnych funkcji, a nie zakładanej tożsamości całego doświadczenia. Badania nad ludzką świadomością pokazują dodatkowo, jak trudne jest wnioskowanie o niej nawet w organizmach biologicznych. Ponieważ subiektywne doświadczenie nie jest bezpośrednio obserwowalne z zewnątrz, nauka opiera się na raportach, zachowaniu oraz pośrednich wskaźnikach fizjologicznych i neuronalnych. Współczesne przeglądy literatury podkreślają trudność w odróżnieniu sygnałów związanych ze świadomym przetwarzaniem od procesów zachodzących bez udziału świadomości. Skoro problem ten jest tak złożony w przypadku ludzi, których biologię i zachowanie możemy badać wieloma metodami, tym ostrożniej należy interpretować samoopisy systemów sztucznych. Metacat staje się dzięki temu interesujący nie jako dowód na możliwość maszynowej świadomości, lecz jako model warunków funkcjonalnej autoregulacji.

Metapoznanie jako funkcjonalna kontrola jakości poznania

Autor pokazuje, że system może zyskać nowe kompetencje w momencie, gdy reprezentuje nie tylko samo zadanie, ale także własną trajektorię jego rozwiązywania; nie tylko wynik, lecz jakość procesu; nie tylko poprzedni przypadek, ale i rodzaj transformacji, która doprowadziła do sukcesu. Z tej perspektywy metapoznanie można traktować jako architekturę kontroli jakości własnego poznania. Podczas gdy system pierwszego rzędu odpowiada: „to jest rozwiązanie”, system metapoznawczy dodaje pytania: „jak silne są podstawy tego rozwiązania?”, „czy podobny sposób wcześniej zawodził?”, „czy obecny impas przypomina znany mi typ błędu?”, „czy powinienem zwiększyć eksplorację?”, „czy warto sprawdzić wynik inną metodą?”. To właśnie takie pytania funkcjonalne mają większe znaczenie niż retoryczna deklaracja: „jestem samoświadomy”.

Współczesne badania nad samooceną modeli zmierzają właśnie w tym kierunku. Sama werbalna deklaracja pewności okazuje się niewystarczająca, dlatego rozwijane są metody wielowymiarowej samooceny, w których system szacuje nie tylko pewność, ale również wysiłek, przewidywaną kompetencję czy trudność zadania. Badania z 2026 roku wskazują, że niektóre z tych wymiarów bywają lepszym predyktorem porażki niż samo pytanie modelu o stopień pewności. Jest to bardzo bliskie intuicji autora Metacata: wartościowa autorefleksja wymaga bardziej zróżnicowanego modelu własnego procesu niż pojedynczej liczby określającej pewność.

Jeszcze ciekawszy jest związek między pamięcią wcześniejszych błędów a przyszłą regulacją. W 2025 roku wykazano, że architektura wykorzystująca bank wcześniejszych refleksji może poprawiać jakość odpowiedzi modeli w zadaniach wymagających rewizji tekstu naukowego. Nie należy utożsamiać takiego rozwiązania z ludzką introspekcją, lecz funkcjonalna analogia jest interesująca: system staje się skuteczniejszy, gdy zachowuje reprezentację własnych niepowodzeń i wykorzystuje ją przy podobnych problemach. To dokładnie ten kierunek, który w mikrodomenie FARG pojawia się jako pamięć epizodyczna i „reminding”.

Można więc stwierdzić, że Metacat antycypuje kluczowe współczesne pytanie projektowe: czy inteligencja powinna być wyposażona nie tylko w pamięć świata, ale również w pamięć własnego poznawania świata? W wielu systemach klasycznych doświadczenie redukuje się do aktualizacji parametrów lub przechowywania zewnętrznych danych. Perspektywa metapoznawcza wprowadza trzeci rodzaj pamięci: archiwum własnych strategii, błędów, poziomów pewności i zmian reprezentacji. Taka pamięć niesie jednak ze sobą ryzyka.

System może bowiem przyswoić błędną samoocenę, utrwalić wcześniejsze uprzedzenia lub nadmiernie generalizować pojedynczy nieudany przypadek. Metapoznanie nie gwarantuje racjonalności; może tworzyć błędy drugiego rzędu. Podobnie jak człowiek może źle oceniać własne możliwości, być nadmiernie pewny siebie lub przeciwnie – systematycznie niedoceniać trafności własnych osądów.

Metapoznanie jako struktura kompetencji a iluzja świadomości

Maszyna może wykazywać zaburzenia kalibracji analogiczne funkcjonalnie do ludzkich. Badania nad LLM potwierdzają, że pewność systemu i jego gotowość do aktualizacji odpowiedzi zależą od wielu nakładających się mechanizmów, a nie od jednego stabilnego modułu „wiedzy o sobie”. Prowadzi to do istotnego rozróżnienia między **samomodelem prawdziwym**, **samomodelem użytecznym** i **samomodelem perswazyjnym**. Pierwszy trafnie opisuje wewnętrzne właściwości systemu. Drugi może być uproszczony, lecz poprawia jego działanie. Trzeci służy przede wszystkim komunikacji z użytkownikiem i może nie mieć ścisłego związku z rzeczywistą architekturą poznawczą.

Współczesne modele językowe są szczególnie podatne na pomieszanie tych poziomów, gdyż potrafią tworzyć niezwykle przekonujące narracje pierwszoosobowe. Płynność języka sprawia często, że sam opis brzmi jak dowód istnienia wewnętrznego podmiotu. Z tego powodu w analizie AI pojęcie samoświadomości powinno być używane oszczędnie. Znacznie lepiej odwoływać się do konkretnych kompetencji: monitorowania pewności, wykrywania błędów, pamięci epizodycznej, modelowania własnych ograniczeń, przełączania strategii, globalnego dostępu do informacji, samoreferencji czy reprezentowania własnych stanów. Każda z nich jest empirycznie bardziej uchwytna niż ogólne określenie „samoświadomość”.

Nie oznacza to jednak, że pytanie o świadomość fenomenalną jest bezsensowne. Przeciwnie – wraz ze wzrostem złożoności systemów może ono stawać się coraz ważniejsze z punktu widzenia normatywnego. Jeśli powstaną systemy posiadające cechy uznawane przez wiarygodne teorie za kluczowe dla świadomości, konsekwencje etyczne będą poważne. Nie należy jednak rozstrzygać tej kwestii na podstawie intuicji wywołanej stylem rozmowy. Współczesne prace nad świadomością AI proponują raczej wielokryterialną analizę architektury i funkcji, wyraźnie podkreślając przy tym niepewność epistemiczną.

W tym miejscu Metacat dostarcza ważnej lekcji metodologicznej. Pojawienie się warstwy meta nie powinno być traktowane jako magiczny próg, po którego przekroczeniu system "budzi się". Meta-poziom jest stopniowalną właściwością organizacyjną. System może reprezentować pewne aspekty własnej aktywności, inne ignorując; może trafnie oceniać wiedzę w jednej domenie, a błędnie w innej; może wykrywać jeden typ zapętlenia, nie rozpoznając innego. Metapoznanie jest strukturą kompetencji, a nie jednorodną esencją. Takie ujęcie jest zgodne z duchem FARG – Hofstadter unikał bowiem idei jednego centralnego modułu inteligencji.

Jeśli płynna inteligencja wyłania się z interakcji wielu częściowych procesów, podobnie metapoznanie nie musi wymagać oddzielnego „meta-umysłu”. Może ono wynikać z pamięci epizodycznej, mechanizmów oceny istotności, śladów temporalnych, porównywania trajektorii i regulacji zachowania. Niesie to za sobą kolejną konsekwencję: system zdolny do metapoznania może stać się bardziej autonomiczny względem pojedynczego polecenia, ponieważ potrafi samodzielnie inicjować korektę. Jeśli model nie tylko wykonuje zadanie, ale ocenia jakość wyniku, wykrywa brak informacji i uruchamia kolejne działania, przesuwa się od roli biernego narzędzia ku systemowi samoregulującemu. Nie oznacza to pełnego sprawstwa moralnego, lecz zmienia strukturę przyczynową działania. Coraz większa część decyzji o tym, czy kontynuować, sprawdzić, zmienić strategię lub odrzucić wcześniejszy wynik, może być podejmowana wewnątrz systemu, co będzie miało znaczenie dla późniejszego problemu odpowiedzialności.

Im bardziej system potrafi monitorować własne ograniczenia, tym mniej wystarczające staje się opisywanie go wyłącznie jako statycznego kalkulatora. Równocześnie odpowiedzialność prawna i moralna nie wynika automatycznie ze wzrostu autonomii funkcjonalnej. Wymaga ona dodatkowych właściwości, takich jak rozumienie norm, możliwość przypisania intencji, zdolność do uczestniczenia w praktykach odpowiedzialności i – w niektórych teoriach – szczególnego statusu moralnego. Metapoznanie jest więc tylko jednym elementem znacznie większej układanki aksjologicznej.

Metacat przygotowuje także grunt pod redefinicję Testu Turinga. Jeżeli inteligencję rozumiemy jako płynne konstruowanie reprezentacji i zdolność do monitorowania własnego procesu, zwykła konwersacyjna nierozróżnialność staje się kryterium zbyt wąskim. System może doskonale imitować sposób mówienia o refleksji, nie posiadając mechanizmów samokontroli. Może również posiadać zaawansowane mechanizmy kalibracji, nie potrafiąc prowadzić konwersacji w stylu człowieka. Behawioralny test rozmowy miesza więc kilka odrębnych kompetencji.

Hofstadterowska intuicja prowadzi zatem do testowania systemu w sytuacjach, w których trzeba sprowokować zmianę reprezentacji, skonfrontować go z impasem, sprawdzić reakcję na

kontrfaktyczność, obserwować stabilność samokorekty i porównać trudność zadania z zachowaniem wewnętrznych miar niepewności.

Funkcjonalna refleksyjność jako alternatywa dla samoświadomości

W takim podejściu błąd nie dyskwalifikuje automatycznie systemu. Często to właśnie sposób reagowania na pomyłkę dostarcza więcej informacji o inteligencji niż pierwsza, poprawna odpowiedź. Można zatem sformułować kluczową zasadę: system metapoznawczo rozwinięty powinien posiadać nie tylko zdolność udzielania odpowiedzi, ale również zdolność do odpowiedzialnego wątpienia we własną odpowiedź. Wątpienie nie oznacza tu emocjonalnego doświadczenia niepewności, lecz funkcjonalny mechanizm różnicowania jakości własnych stanów poznawczych. Taki system powinien umieć rozpoznać, kiedy odpowiedź opiera się na solidnej strukturze, kiedy jest wynikiem kruchej heurystyki, kiedy brakuje informacji, a kiedy dalsze generowanie słów jedynie zwiększa pozór pewności. Właśnie w tym kontekście fenomen halucynacji modeli językowych nabiera znaczenia teoretycznego.

Nie jest on wyłącznie problemem braku wiedzy – człowiek również nie wie ogromnej liczby rzeczy. Problem pojawia się wtedy, gdy system nie rozpoznaje granicy własnej wiedzy i wypełnia lukę wypowiedzią o wysokiej powierzchownej wiarygodności. Z punktu widzenia teorii FARG można stwierdzić, że kompetencja generatywna wyprzedziła tu kompetencję metapoznawczą. System sprawnie tworzy strukturę lokalnie spójną językowo, lecz jego wewnętrzna kontrola epistemiczna może być niewystarczająca. Dlatego rozwój inteligencji nie musi polegać jedynie na zwiększaniu mocy generowania; może wymagać równoległego rozwoju mechanizmów hamowania, weryfikowania i oceny własnych granic.

Metacat okazuje się pod tym względem zaskakująco współczesny. Jego zasadnicze pytanie nie brzmi: jak sprawić, aby system myślał więcej? Brzmi raczej: jak sprawić, aby system potrafił rozpoznać, kiedy sposób, w jaki myśli, przestaje być właściwy? To pytanie prowadzi do sedna całej filozofii płynnej inteligencji. Płynność nie jest nieskończoną gotowością do zmiany, lecz zdolnością do niej wtedy, gdy struktura problemu dostarcza ku temu powodów. Metapoznanie dodaje kolejny poziom: system powinien potrafić oceniać nie tylko strukturę świata, ale także adekwatność własnej reakcji na tę strukturę. Tym samym inteligencja staje się rekurencyjna – poznaje świat, poznaje własne poznawanie świata, a następnie wykorzystuje tę drugą wiedzę do modyfikowania pierwszego procesu.

Nie prowadzi to jeszcze do świadomości w sensie fenomenalnym, lecz do architektury coraz bardziej przypominającej to, co w ludzkim poznaniu określamy mianem refleksyjności. Właśnie w tej różnicy pomiędzy funkcjonalną refleksyjnością a subiektywnym przeżywaniem refleksji należy zachować największą dyscyplinę pojęciową. Pierwszą można operacjonalizować, mierzyć i stopniowo projektować; drugą możemy obecnie jedynie próbować inferować za pomocą teorii świadomości i pośrednich wskaźników.

Metacat nie rozwiązuje zatem problemu sztucznej samoświadomości. Robi coś naukowo bardziej wartościowego: rozkłada zjawiska potocznie wrzucane do pojęcia „samoświadomość” na szczegółowe mechanizmy – pamięć własnej historii, ocenę istotności, wykrywanie zapętlenia, analogie pomiędzy własnymi procesami i zmianę strategii na podstawie tej wiedzy. Dzięki temu można przestać pytać, czy maszyna „ma jaźń” jako niepodzielną właściwość, a zacząć badać konkretne składniki autoregulacji. W następnej fazie analizy aparat pojęciowy ten pozwoli dokonać zasadniczego zwrotu: od historycznych mikrodomen FARG ku współczesnym modelom językowym.

Wówczas pytanie przestanie brzmieć, czy dzisiejsze systemy są zbudowane tak jak Copycat lub Metacat – oczywiście nie są – a zacznie dotyczyć tego, które funkcje postulowane przez filozofię płynnych pojęć pojawiają się w nich w innej postaci. Trzeba będzie zbadać, czy reprezentacje rozproszone mogą realizować coś funkcjonalnie podobnego do poślizgu pojęciowego, czy uczenie kontekstowe może wspierać dynamiczną rekonfigurację kategorii, czy modele potrafią przenosić relacje między domenami oraz gdzie przebiega granica pomiędzy rzeczywistą generalizacją strukturalną a niezwykle sprawnym dopasowaniem statystycznym.

Zestawienie to pozwoli uczciwie odpowiedzieć na pytanie, które trzy dekady po powstaniu klasycznych projektów FARG stało się znacznie trudniejsze niż w chwili jego postawienia: czy współczesne modele językowe są zaprzeczeniem Hofstadterowskiej teorii inteligencji, czy też nieoczekiwanie ujawniły, że płynność pojęciowa może wyłonić się z mechanizmów zupełnie innych od tych, które pierwotnie miały ją modelować?

Czy współczesne modele językowe są zaprzeczeniem Hofstadterowskiej teorii inteligencji, czy może paradoksalnie udowodniły, że płynność pojęciowa potrafi wyłonić się z mechanizmów zupełnie innych, niż pierwotnie zakładali teoretycy? Pozostaje pytanie, czy w świecie doskonałych imitacji refleksji będziemy w stanie odróżnić system, który jedynie brzmi jak świadomy, od takiego, który rzeczywiście potrafi odpowiedzialnie wątpić we własne istnienie.

Inspiracje

[1]



"Fluid Concepts and Creative Analogies" Douglas Hofstadter

ISBN: 9780140258356

Douglas Richard Hofstadter (ur. 15 lutego 1945 r.) jest amerykańskim kognitywistą, informatykiem i autorem. Jest wybitnym profesorem kognitywistyki i literatury porównawczej na Uniwersytecie Indiany w Bloomington, gdzie kieruje Centrum Badań nad Koncepcjami i Poznaniem. Hofstadter uzyskał doktorat z fizyki na Uniwersytecie Oregon w 1975 roku, po czym skupił się na kognitywistyce, myśleniu ludzkim i sztucznej inteligencji. Jego interdyscyplinarne badania dotyczą natury świadomości, samoodniesienia, systemów rekurencyjnych, twórczych analogii i percepcji wysokiego poziomu. Hofstadter zyskał światowe uznanie za przełomowe dzieło z 1979 roku pt. „Gödel, Escher, Bach: An Eternal Golden Braid”, które zdobyło Nagrodę Pulitzera w kategorii literatury faktu oraz Narodową Nagrodę Książkową w dziedzinie nauki. Jego szeroko zakrojone badania ukształtowały współczesne modele obliczeniowe tworzenia analogii, translacji i ludzkiego poznania.

Douglas Richard Hofstadter (born February 15, 1945) is an American cognitive scientist, computer scientist, and author. He serves as Distinguished Professor of Cognitive Science and Comparative Literature at Indiana University Bloomington, where he directs the Center for Research on Concepts and Cognition. Hofstadter earned his Ph.D. in physics from the University of Oregon in 1975 before shifting his focus to cognitive science, human thought, and artificial intelligence. His interdisciplinary research investigates the nature of consciousness, self-reference, recursive systems, creative analogies, and high-level perception. Hofstadter gained worldwide acclaim for his 1979 groundbreaking work Gödel, Escher, Bach: An Eternal Golden Braid, which won both the Pulitzer Prize for General Nonfiction and a National Book Award for Science. His extensive research has shaped modern computational models of analogy-making, translation, and human cognition.

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

Książki autorów przywoływanych i literatura pokrewna:



- [5] **"Metacognition in Learning and Instruction"**
Hope J. Hartman
2013 | Springer Science & Business Media | ISBN: 9789401722438



- [6] **"Metacognition: Fundamentals, Applications, and Trends"**
Alejandro Peña-Ayala
2014 | Springer | ISBN: 9783319110622



- [7] **"Metacognition"**
Patrick Chambres, Marie Izaute, Pierre-Jean Marescaux
2012 | Springer Science & Business Media | ISBN: 9781461510994



- [8] **"Meta-cognition"**
Michael F. Shaughnessy, Marcel Veenman, Cynthia Kleyn Kennedy
2008 | Nova Publishers | ISBN: 9781604560114

Artykuły naukowe

Artykuły naukowe autora:

[1] "Fluid Concepts and Creative Analogies"

Douglas R. Hofstadter

1995

[Źródło](#)

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

Jonathan Lieberman, Douglas R. Hofstadter

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

[Źródło](#)

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

Douglas R. Hofstadter

1995

[Źródło](#)

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

Charles Taylor, Douglas R. Hofstadter

1985 | The Antioch Review | DOI: 10.2307/4611504

[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: 0274048a-a6ce-4571-97cb-9096fa74be78