

Pożądana trudność: AI jako tutor i ryzyko poznawczego outsourcingu w świetle książki Emergence Boba Burgina



AUTOR

Fundacja Dobre Państwo

STRESZCZENIE / ABSTRACT

Artykuł analizuje napięcie między efektywnością dostarczania odpowiedzi przez AI a procesem głębokiego uczenia się. Autor przywołuje koncepcję „pożądanego trudności”, wskazując, że pewien opór poznawczy i wysiłek włożony w wydobywanie informacji (retrieval practice) są niezbędne do trwałego zapamiętania wiedzy i jej późniejszego transferu. Głównym ryzykiem generatywnej AI jest nadmierna redukcja tarcia poznawczego, która prowadzi do tzw. outsourcingu poznawczego – sytuacji, w której narzędzie przejmie procesy myślowe, zamiast je wspierać. Tekst podkreśla różnicę między doraźnym wynikiem (performance) a rzeczywistym uczeniem się (learning), sugerując, że AI powinno pełnić rolę tutora sterującego poziomem wyzwań, a nie automatu do udzielania natychmiastowych odpowiedzi.

The article analyzes the tension between the efficiency of AI in providing answers and the process of deep learning. The author invokes the concept of 'desired difficulty,' indicating that a certain amount of cognitive resistance and effort spent on retrieving information (retrieval practice) are essential for the permanent retention of knowledge and its subsequent transfer. The main risk of generative AI is the excessive reduction of cognitive friction, which leads to so-called cognitive outsourcing—a situation where the tool takes over thought processes instead of supporting them. The text emphasizes the difference between immediate performance and actual learning, suggesting that AI should act as a tutor managing the level of challenges, rather than an automaton for providing instant answers.

Artykuł analizuje krytyczny rozdźwięk między efektywnością wykonania zadania a rzeczywistym procesem uczenia się w dobie generatywnej sztucznej inteligencji. Autor

stawia tezę, że AI może stać się albo narzędziem poznawczego outsourcingu, które poprzez eliminację tzw. „pożądaney trudności” i tarcia intelektualnego prowadzi do atrofii kompetencji, albo zaawansowanym rusztowaniem (scaffolding), wspierającym rozwój struktur wiedzy. Kluczem do sukcesu nie jest sama technologia, lecz projekt pedagogiczny: systemy AI powinny być projektowane tak, by nie dostarczać natychmiastowych odpowiedzi, lecz wymuszać aktywny wysiłek poznawczy, m.in. poprzez praktykę wydobywania informacji i precyzyjną personalizację oporu intelektualnego. Tekst argumentuje, że w świecie tanich odpowiedzi wartość wiedzy wewnętrznej paradoksalnie rośnie, gdyż stanowi ona jedyny fundament pozwalający na krytyczną weryfikację zewnętrznych systemów. Ostatecznie autor postuluje przejście od oceny produktu końcowego do oceny procesu poznawczego, wskazując na wyłonienie się nowej formy hybrydowej kognicji człowiek-AI.

SŁOWA KLUCZOWE

pożądana trudność

poznawczy outsourcing

generatywna AI

cognitive offloading

retrieval practice

desirable difficulties

scaffolding

hybrydowa kognicja

model ucznia

sprawczość epistemiczna

interleaving

spacing effect

pamięć transakcyjna

mikroadaptacja pedagogiczna

redukcja tarcia poznawczego

Rozdźwięk między efektem końcowym a procesem uczenia

Gdy odpowiedź staje się zbyt łatwa: AI, pamięć, tutoring i przyszłość uczenia się

Praca i edukacja przecinają się w jednym, szczególnym punkcie: człowiek nie zawsze wykonuje zadanie wyłącznie po to, by uzyskać jego rezultat. Często robi to, aby dzięki temu procesowi stać się kimś, kto w przyszłości potrafi wykonać je lepiej. Uczeń rozwiązujący równanie, student analizujący przypadek kliniczny, aplikant samodzielnie rekonstruujący argumentację prawną czy początkujący programista szukający przyczyny błędu wykonują czynności jednocześnie produkcyjne i rozwojowe. Powstaje rezultat zewnętrzny – odpowiedź, diagnoza, kod – ale zachodzi także rezultat wewnętrzny: modyfikacja pamięci, reorganizacja reprezentacji problemu, wypracowanie strategii wyszukiwania, kalibracja pewności oraz zwiększenie zdolności do przyszłego transferu wiedzy.

Sztuczna inteligencja może radykalnie poprawić ten pierwszy rodzaj rezultatu, jednocześnie w określonych warunkach uszkadzając drugi. To właśnie ten rozdźwięk staje się jednym z kluczowych problemów edukacji w epoce generatywnej AI.

Materiał źródłowy dostrzega wagę tego napięcia poprzez pojęcie „pożądaney trudności” i proponuje system AI jako personalizatora wyzwań. Narzędzie miałoby rozpoznawać granice wiedzy ucznia i stawiać dokładnie taki opór, jaki sprzyja trwałemu uczeniu się. Jest to jeden z najbardziej obiecujących elementów tej wizji, jednak wymaga ona istotnej korekty mechanistycznej.

Nie ma podstaw, by twierdzić, że hipokamp świadomie „uznaje” informację za wartą kosztu energetycznego lub że każda trudność automatycznie „uruchamia zapis”. Takie sformułowania są użyteczną metaforą pedagogiczną, a nie neurobiologicznym opisem procesu. Rdzeń teorii brzmi inaczej: pewne warunki, które pogarszają bieżącą płynność wykonania zadania, mogą paradoksalnie poprawiać długotrwałe przechowywanie, dostępność i transfer wiedzy, ponieważ wymuszają aktywne wydobywanie informacji, różnicowanie reprezentacji i ponowne konstruowanie odpowiedzi.

Robert i Elizabeth Bjork zwracali uwagę na istotną różnicę pomiędzy performance a learning. To, że uczeń w danej chwili wykonuje zadanie sprawnie, nie oznacza, iż powstała trwała wiedza, dostępna po tygodniu, w innym kontekście i bez zewnętrznej podpory. Wręcz przeciwnie – uczeń zmagający się z zadaniem może sprawiać wrażenie mniej kompetentnego podczas treningu, a jednocześnie budować reprezentacje zapewniające później lepszą retencję i transfer. Badania nad desirable difficulties wskazują m.in. na korzystne efekty rozłożenia nauki w czasie, przeplatania typów problemów oraz praktyki wydobywania, w przeciwieństwie do ciągłego ponownego studiowania materiału. Najnowsze eksperymenty potwierdzają ten paradoks: uczestnicy oceniają zblokowaną, łatwiejszą praktykę jako bardziej skuteczną, podczas gdy to przeplatanie prowadzi do lepszych rezultatów w późniejszym teście i transferze. Właśnie dlatego generatywna AI może być z pedagogicznego punktu widzenia narzędziem zarówno niezwykle skutecznym, jak i niezwykle zdradliwym.

Redukcja tarcia poznawczego jako ryzyko utraty głębokiego uczenia

Podstawową przewagą użytkową AI jest redukcja tarcia. Uczeń nie musi już szukać definicji, czekać na konsultację, przeglądać kilku podręczników ani długo zastanawiać się nad pierwszym krokiem rozwiązania – odpowiedź otrzymuje w kilka sekund. Z punktu widzenia wykonania zadania jest to

optymalizacja. Z perspektywy uczenia się kwestia ta zależy od tego, który fragment pracy poznawczej został usunięty. Jeśli AI eliminuje przypadkową przeszkodę – niezrozumiały zapis, brak przykładu czy techniczny problem z dostępem do źródła – może uwolnić zasoby niezbędne do głębszego myślenia. Jeśli jednak usuwa konieczność samodzielnego przypomnienia sobie informacji, wygenerowania hipotezy albo wykrycia sprzeczności, może przejąć proces, który miał zmienić ucznia.

W tym kontekście kluczowe są badania nad retrieval practice. Próba wydobywania wiedzy z pamięci nie jest jedynie sposobem na sprawdzenie, czy informacja została zapamiętana; sam proces wydobywania wzmacnia późniejszą dostępność danych i spowalnia zapomnianie. Efekt ten obserwowano w różnych grupach wiekowych, rodzajach materiałów i warunkach edukacyjnych.

Co więcej, próba przypomnienia ma wartość nawet wtedy, gdy początkowo kończy się niepowodzeniem, o ile uczeń otrzyma później prawidłową informację zwrotną. Z pedagogicznego punktu widzenia sekwencja „spróbuj – pomyśl się – otrzymaj wskazówkę – spróbuj ponownie – dopiero potem zobacz pełną odpowiedź” jest poznawczo cenniejsza niż schemat „zapytaj – przeczytaj poprawną odpowiedź”. AI konwersacyjna może realizować oba te modele: działać jak automat do natychmiastowego dostarczania wyników lub jak tutor kontrolujący moment udzielenia pomocy. To rozróżnienie wykracza poza kwestię dobrego czy złego promptu; oznacza wybór między dwoma odmiennymi modelami pedagogicznymi.

W pierwszym przypadku użytkownik optymalizuje wykonanie zadania z pomocą zewnętrznego systemu. W drugim – system optymalizuje zmianę stanu poznawczego użytkownika. Najlepsza odpowiedź dla zadania nie musi być zatem najlepszą odpowiedzią dla ucznia. Można to zilustrować przykładem matematycznym: uczeń proszący o rozwiązanie równania otrzymuje pięć poprawnych przekształceń prowadzących do wyniku. Po lekturze tekst wydaje się logiczny, a każdy krok znajomy. Płynność przetwarzania wytwarza jednak poczucie rozumienia, które nie musi przetrwać zamknięcia okna rozmowy. Gdyby natomiast system poprosił ucznia o wskazanie pierwszego kroku, poczekał na odpowiedź, rozpoznał błąd i podał minimalną wskazówkę, wymuszając samodzielne generowanie kolejnych etapów, doświadczenie byłoby trudniejsze, ale uczeń wykonałby większą część pracy poznawczej osobiście.

Podobnie jest z tekstem naukowym. Streszczenie wygenerowane przez AI pozwala szybko poznać główne tezy artykułu, lecz samodzielne sformułowanie syntezy wymaga selekcji informacji, ustanowienia hierarchii argumentów i kompresji semantycznej. Procesy te są immanentną częścią uczenia się. Badania nad generatywnymi strategiami poznawczymi wskazują, że wyjaśnianie materiału sobie lub innym prowadzi do lepszej retencji i transferu wiedzy niż bierne studiowanie

treści. Gdy AI „oszczędza” uczniowi konieczność sformułowania myśli własnymi słowami, oszczędza czas, ale jednocześnie może usunąć okazję do reorganizacji reprezentacji poznawczej.

Odciążenie poznawcze nie jest tożsame z utratą kompetencji

Istnieje zasadnicza różnica pomiędzy poznawczym outsourcingiem wyniku a poznawczym rusztowaniem procesu. Rusztowanie ma pomagać wykonującemu wejść wyżej, by ostatecznie umożliwić samodzielne podtrzymywanie konstrukcji. Jeśli jednak podpora pozostaje konieczna przy każdym kolejnym problemie, system poprawia sprawność zespołu człowiek-AI, lecz niekoniecznie kompetencję samego człowieka.

W wielu zastosowaniach zawodowych taki rezultat jest całkowicie akceptowalny. Księgową nie musi przecież ręcznie wykonywać obliczeń, jeśli niezawodne narzędzie zrobi to lepiej. Edukacja ma jednak inny cel: część wiedzy musi zostać zinternalizowana, aby późniejsze myślenie było możliwe bez ciągłego delegowania każdego kroku. Tutaj pojawia się pojęcie cognitive offloading – odciążania poznawczego. Od tysiącleci przenosimy część pamięci na zewnętrzne nośniki: robimy notatki, używamy kalendarzy, zapisujemy listy zakupów czy korzystamy z map. Nie jest to patologia, lecz jedna z podstawowych strategii poznawczych naszego gatunku.

Przegląd opublikowany w Nature Reviews Psychology w 2025 roku wskazuje, że offloading może znacząco poprawiać wykonanie zadania pamięciowego, ale wiąże się z kosztami: gdy dostęp do zewnętrznej podpory niespodziewanie znika, osoby polegające na niej mogą pamiętać gorzej niż ci, którzy byli wcześniej zmuszeni korzystać z pamięci wewnętrznej. Modele teoretyczne sugerują, że ludzie racjonalnie równoważą koszt wysiłku pamięciowego z korzyścią z zewnętrznego zapisu; mogą odciążać elementy o wysokiej wartości, a uwolnione zasoby przeznaczać na zapamiętywanie innych informacji. Nie istnieje więc proste równanie "offloading = pogorszenie mózgu". Zapisanie numeru telefonu pozwala nie utrzymywać go w pamięci roboczej i wykorzystać uwagę do bardziej złożonego zadania. Problem pojawia się wtedy, gdy zewnętrzny system przejmuje funkcję, która miała zostać właśnie wyćwiczona.

Student medycyny może korzystać z bazy leków, gdyż praktykujący lekarz również będzie miał do niej dostęp. Powinien jednak posiadać wystarczająco bogatą wiedzę farmakologiczną, aby rozpoznać absurdalną rekomendację systemu. Prawnik może używać wyszukiwarki orzeczeń, ale musi rozumieć strukturę prawa, by odróżnić precedens relewantny od pozornie podobnego.

Offloading jest bezpieczny dopiero wtedy, gdy człowiek zachowuje metakompetencję oceny pracy narzędzia.

Generatywna AI zmienia skalę problemu, ponieważ nie tylko przechowuje informację, lecz przejmuje kolejne etapy jej organizowania. Tradycyjna wyszukiwarka zwracała źródła; użytkownik musiał je przeczytać, porównać i syntetyzować. Model językowy wykonuje syntezę od razu. Kalkulator przejmował rachunek; LLM może przejąć sformułowanie problemu, dobór argumentów, strukturę tekstu i ocenę wariantów. Cognitive offloading przestaje więc dotyczyć wyłącznie pamiętania faktów – może obejmować operacje wykonawcze i metapoznawcze. Właśnie dlatego potrzebujemy rozróżnienia między pamięcią transakcyjną a intelektualną zależnością.

Daniel Wegner pokazał, że grupy mogą tworzyć systemy pamięci transakcyjnej: poszczególne osoby nie muszą wiedzieć wszystkiego, jeśli wiedzą, kto posiada odpowiednią informację. Internet stał się później gigantycznym zewnętrznym systemem dostępu do wiedzy. Najnowszy przegląd wpływu sieci i AI na pamięć podkreśla, że technologie zmieniają nie tyle samą zdolność pamięciową, co strategię zapamiętywania: częściej pamiętamy drogę do informacji niż jej treść. Może to być adaptacyjne – pod warunkiem, że system zewnętrzny jest dostępny i użytkownik zachowuje wiedzę niezbędną do oceny tego, co odzyskuje.

Co interesujące, ogólne korzystanie z internetu nie maluje prostego obrazu poznawczego upadku. Badanie z 2024 roku wykazało nawet pozytywną korelację pomiędzy częstszym używaniem sieci a wynikami w testach pamięci epizodycznej, co pokazuje, jak ryzykowne są katastroficzne generalizacje z pojedynczych eksperymentów laboratoryjnych. Technologia zmienia konfigurację procesów poznawczych, ale jej skutek zależy od sposobu używania, rodzaju zadania, wieku, kompetencji, niezawodności systemu i tego, co dzieje się z uwolnionymi zasobami.

Projekt pedagogiczny AI decyduje o zysku lub stracie poznawczej

W przypadku generatywnej AI pierwsze dane eksperymentalne są niejednoznaczne. Randomizowane badanie przeprowadzone na Harvardzie i opublikowane w 2025 roku porównało specjalnie zaprojektowanego tutora AI z aktywnym nauczaniem w klasie wśród studentów fizyki. Tutor został skonstruowany zgodnie z zasadami pedagogicznymi, a nie jako zwykły dostęp do otwartego chatbota.

Uczestnicy korzystający z AI osiągnęli większe przyrosty wiedzy w krótszym czasie oraz deklarowali wyższe zaangażowanie i motywację. To mocny argument za tezą, że AI może rzeczywiście zwiększać

skuteczność nauczania, o ile architektura rozmowy została zaprojektowana tak, by uczyć, a nie tylko odpowiadać. Nie pozwala to jednak na ogólny wniosek, że "chatboty poprawiają edukację". W 2026 roku opublikowano semestralne badanie eksperymentalne obejmujące około pięciuset studentów korzystających z chatbota opartego na RAG. Nie stwierdzono w nim statystycznie istotnego wpływu ani na wyniki akademickie, ani na zainteresowanie, samoocenę skuteczności czy zaangażowanie. Rozbieżność między tymi wynikami a badaniem harwardzkim nie musi oznaczać sprzeczności.

Wskazuje ona raczej, że "AI tutor" nie jest jedną, jednorodną interwencją. Kluczowe znaczenie ma projekt pedagogiczny, przedmiot, intensywność użytkowania, integracja z zajęciami, zachowanie uczniów oraz charakter samego modelu. Jeszcze bardziej ostrzegający wynik przyniosło randomizowane badanie z 2025 roku, w którym 120 studentów uczyło się materiału z pomocą ChatGPT albo metodami tradycyjnymi; po 45 dniach przeprowadzono niezapowiedziany test retencji. Grupa korzystająca z ChatGPT uzyskała średnio 57,5 procent poprawnych odpowiedzi wobec 68,5 procent w grupie tradycyjnej. Różnica była statystycznie istotna i odpowiadała efektowi o umiarkowanie dużej wielkości. Pojedyncze badanie nie dowodzi, że korzystanie z ChatGPT pogarsza pamięć w każdym kontekście, ale dobrze obrazuje mechanizm ryzyka: narzędzie może poprawić bieżący komfort uczenia, jednocześnie zmniejszając liczbę operacji, dzięki którym wiedza zostałaby utrwalona.

Wyniki pozytywne i negatywne nie muszą się zatem wzajemnie znosić. Mogą opisywać dwa różne sposoby użycia tej samej klasy technologii. AI, która zadaje pytanie przed podaniem odpowiedzi, wymusza wydobywanie, dostosowuje wskazówkę do błędu, powraca do materiału po określonym czasie i prosi o zastosowanie zasady w nowym kontekście, może zwiększać pożądaną trudność. AI, która na każde pytanie natychmiast generuje kompletne rozwiązanie, może tę trudność usuwać. To samo narzędzie technologiczne może być tutorem albo maszyną do poznawczego outsourcingu. Właśnie dlatego propozycję materiału źródłowego, według której AI mogłaby personalizować trudność i znać "krawędzie naszej wiedzy", należy potraktować poważnie.

W tradycyjnej klasie nauczyciel musi zarządzać heterogeniczną grupą. To, co dla jednej uczennicy jest trywialne, dla drugiej może wykraczać poza dostępny zakres kompetencji. System konwersacyjny może teoretycznie znacznie częściej mierzyć stan wiedzy konkretnej osoby, dostosowywać kolejne pytania i zmieniać poziom podpory niemal w czasie rzeczywistym. To właśnie mikroadaptacja może być najważniejszą przewagą edukacyjnej AI – istotniejszą niż sam dostęp do ogromnego repozytorium informacji. Nie należy jednak bezkrytycznie łączyć tej możliwości z klasycznym "problemem dwóch sigm" Benjamina Blooma.

Źródło stwierdza, że nauczanie konwersacyjne jeden-na-jeden daje wyniki "o dwa rzędy wielkości" lepsze i sprawia, że przeciętny uczeń przewyższa 98 procent rówieśników. Pierwsza część tego

zdania jest matematycznie niepoprawna: dwa sigma oznaczają około dwóch odchyłeń standardowych, a nie dwa rzędy wielkości. Historyczna praca Blooma z 1984 roku rzeczywiście opisywała wyniki indywidualnego tutoringu około 2 SD powyżej typowego nauczania grupowego, co w idealizowanym rozkładzie odpowiadałoby przesunięciu przeciętnego ucznia w okolice 98. percentyla. Jednak współczesna literatura nakazuje dużo większą ostrożność.

Rozszerzona metaanaliza 265 randomizowanych badań tutoringu, opublikowana jako working paper w 2024 roku, wskazała średni efekt około 0,42 SD w pełnej próbie. Dla dużych programów efekty spadały jednak do poziomu 0,21 SD przy 400–999 uczestnikach i 0,16 SD przy co najmniej tysiącu uczniów. Autorzy zwracają uwagę, że klasyczne badania Blooma były prowadzone na małych grupach, a skala programu znacząco obniża przeciętne efekty. Nie oznacza to, że indywidualizacja jest mało skuteczna, lecz że słynne "2 sigma" nie powinny być przenoszone na AI jako gwarantowany wynik technologiczny.

Co więcej, tutoring Blooma był tutoringiem ludzkim, a nie eksperymentem z LLM. Nie wolno zatem formułować równania "jeden na jeden = 2 sigma = chatbot". AI może potencjalnie usunąć najważniejsze ograniczenie ekonomiczne klasycznego tutoringu, czyli koszt indywidualnego czasu eksperta, ale aby wykorzystać ten potencjał, musi odtworzyć nie samą liczbę uczestników rozmowy, lecz kluczowe właściwości interakcji: diagnozowanie błędów, dostosowanie tempa, dobieranie przykładów, regulowanie trudności, monitorowanie zrozumienia i motywowanie ucznia.

Dynamiczny model ucznia jako klucz do precyzyjnego rusztowania

W tym miejscu powraca kwestia modelu ucznia. Dobry tutor nie dysponuje jedynie wiedzą o przedmiocie; posiada on także roboczą teorię tego, co wie konkretna osoba, gdzie leży źródło jej błędów, jak silne jest błędne przekonanie i jaki kolejny krok będzie wystarczająco trudny, a jednocześnie wciąż osiągalny. System edukacyjny AI przyszłości będzie zatem prawdopodobnie wymagał dwóch modeli jednocześnie: modelu domeny oraz dynamicznego modelu ucznia. Ta druga reprezentacja mogłaby obejmować historię błędów, czas od ostatniego użycia pojęcia, poziom pewności, zdolność transferu oraz informację o tym, czy odpowiedź została wygenerowana samodzielnie, czy dopiero po wielu podpowiedziach. Jest to cel znacznie ambitniejszy niż współczesna personalizacja, która ogranicza się do zmiany stylu wyjaśnienia.

System naprawdę optymalizujący proces uczenia nie powinien pytać przede wszystkim: „jak podać odpowiedź, aby użytkownik ją zrozumiał?”. Powinien raczej zapytać: „jaką operację powinien teraz

wykonać sam użytkownik, aby po zakończeniu tej interakcji posiadał trwalszą i bardziej transferowalną reprezentację?”. Z takiej perspektywy natychmiastowe udzielenie odpowiedzi może być czasami pedagogicznym błędem. Gdy uczeń nie zna rozwiązania, system musi rozróżnić kilka przypadków: brak odpowiedzi może wynikać z nieznamomości pojęcia, chwilowej niedostępności pamięci, błędnego modelu problemu, nieuważnego czytania lub przeciążenia poznawczego.

W każdym z tych scenariuszy optymalna jest inna interwencja. Uczniowi, który posiada wiedzę, lecz ma trudność z jej wydobyciem, podanie pełnej odpowiedzi może odebrać szansę na wartościową próbę retrieval. Z kolei osobie zupełnie pozbawionej podstaw długa seria nieudanych prób może przynieść jedynie frustrację i utrwalać chaos. Pożądana trudność przestaje być pożądana w momencie, gdy przekracza zasoby umożliwiające uczenie się. To zastrzeżenie jest kluczowe, gdyż termin „desirable difficulty” bywa nadużywany. Nie każda trudność poprawia zapamiętywanie. Nieczytelna czcionka, niejasny wykład, źle sformułowane pytanie czy zbędnie skomplikowany interfejs zwiększają jedynie obciążenie poznawcze, nie przynosząc korzyści edukacyjnej. Badania nad percepcyjną „dysfluency” dostarczały niespójnych wyników, a późniejsze analizy wskazały na liczne warunki brzegowe.

Celem pedagogicznym nie jest maksymalizacja trudności sama w sobie, lecz tworzenie trudności diagnostycznie związanej z procesem, który ma zostać wyćwiczony. AI oferuje tutaj wyjątkową precyzję. Zamiast arbitralnie utrudniać materiał, może stopniować zakres podpowiedzi: najpierw poprosić o samodzielną próbę, następnie wskazać kategorię błędu, później podać fragment informacji i dopiero na końcu przedstawić rozwiązanie. Przy kolejnym podobnym zadaniu wsparcie może zostać ograniczone. Pedagogika określa takie podejście jako scaffolding oraz stopniowe wycofywanie podpory. Generatywny tutor ma potencjał do realizacji tej zasady z dokładnością, która w dużych klasach była dotąd nieosiągalna.

Jeszcze większy potencjał drzemie w spacingu. Tradycyjny tutor spotyka się z uczniem w określonych godzinach; system cyfrowy natomiast pamięta, kiedy dana wiedza była ostatnio wydobywana i może zaplanować kolejne przypomnienie w interwale dobranym do wcześniejszych wyników. Nie chodzi tu o mechaniczne powtórzenie faktu. System może zaprojektować nowy problem wymagający użycia tej samej zasady w innym kontekście – wtedy powtórka staje się jednocześnie treningiem transferu.

Podobnie AI może organizować interleaving, czyli przeplatanie kategorii problemów. Uczeń rozwiązujący dwadzieścia identycznych zadań często nie musi rozpoznawać typu procedury, gdyż wie, że każde kolejne zadanie należy do tej samej kategorii. Przeplatanie zmusza go natomiast do najpierw samodzielnego zdiagnozowania rodzaju problemu.

AI jako lustro kalibracyjne i narzędzie weryfikacji procesu

W praktyce doraźne wyniki bywają gorsze, przez co uczeń czuje się mniej kompetentny, mimo że późniejsza retencja i transfer wiedzy mogą być lepsze. Badania z 2024 roku wskazują właśnie na ten rozdzźwięk: większy wysiłek i niższa subiektywna ocena procesu przy interleavingu idą w parze z lepszymi efektami długofalowymi. Inteligentny tutor mógłby celowo zarządzać tą iluzją, wyjaśniając użytkownikowi, dlaczego większa trudność nie musi oznaczać gorszego uczenia. Prowadzi to do metapoznania. Człowiek nie tylko przyswaja wiedzę, ale dokonuje sądu nad tym, czy już się nauczył. Te sądy bywają systematycznie błędne. Łatwość ponownego czytania, znajomość słownictwa czy płynność śledzenia poprawnej odpowiedzi mogą wytworzyć iluzję kompetencji. Student utwierdza się w przekonaniu: „to przecież rozumiem” – dopóki nie zostanie poproszony o samodzielne wyprowadzenie argumentu. Desirable difficulties są często unikane właśnie dlatego, że subiektywnie przypominają gorszą naukę.

Właśnie w tej domenie AI może odegrać rolę bardziej wartościową niż encyklopedia, stając się lustrem kalibracyjnym. Zamiast jedynie podawać odpowiedzi, system mógłby pytać użytkownika o poziom pewności przed ich wyświetleniem, a następnie konfrontować tę pewność z faktyczną trafnością. Z czasem pozwoliłoby to wskazać obszary nadmiernej pewności oraz niedoszacowania własnej wiedzy. Uczenie się oznaczałoby wtedy nie tylko zwiększanie liczby poprawnych odpowiedzi, lecz przede wszystkim poprawę zdolności rozpoznawania, kiedy naprawdę wiem, a kiedy jedynie czuję znajomość. Kompetencja ta będzie kluczowa w świecie, w którym zewnętrzna odpowiedź stała się niemal darmowa. Dawniej niewiedza ujawniała się po prostu jako brak możliwości udzielenia odpowiedzi; w epoce AI można przedstawić błyskotliwą wypowiedź na temat, którego się nie rozumie, ponieważ system wygenerował ją za nas.

Ocena kompetencji na podstawie produktu staje się przez to coraz mniej miarodajna. Należy przejść na ocenę procesu: zdolności obrony stanowiska, zastosowania zasady w nowym przypadku, wykrycia błędu, rekonstrukcji argumentu bez podpory czy krytyki odpowiedzi AI. Oznacza to kryzys tradycyjnego zadania domowego jako artefaktu oceny. Esej, kod, analiza przypadku czy tłumaczenie przestały być niezawodnym dowodem posiadanej kompetencji. Nie wynika z tego jednak, że należy zakazać korzystania z AI.

Oznacza to raczej, że edukacja musi częściej mierzyć to, czego nie da się delegować lub co po delegowaniu łatwo ujawnić: rozmowę obronną, pracę iteracyjną, zmianę stanowiska pod wpływem kontrargumentu, transfer do nieoczekiwanego problemu, rekonstrukcję procesu i zdolność krytyki własnego rozwiązania. Paradoksalnie AI może pomóc przeprowadzić tę zmianę. System może

generować unikalne warianty problemów, prowadzić oralne mikroegzaminy, adaptacyjnie dążyć uzasadnienie i sprawdzać, czy wiedza przenosi się na nowe konfiguracje. Zautomatyzowany tutor może więc osłabić wartość prostego zadania pisemnego, a jednocześnie dostarczyć narzędzi do znacznie częstszej oceny formatywnej. Na tym tle szczególnego znaczenia nabiera źródłowa historia fiszki jako technologii, która narzuciła strukturę procesowi uczenia i pomogła dziecku przejść od poznawczego chaosu do bardziej uporządkowanej praktyki. Materiał interpretuje ją jako mikromodel emergencji: prosta zewnętrzna rama może przekształcić sposób uczenia się biologicznego mózgu. Właśnie w tej skromniejszej postaci analogia między fiszką a AI jest bardzo mocna. Dobre narzędzie edukacyjne nie musi „wkładać wiedzy” do mózgu; może zmienić trajektorię interakcji człowieka z własną pamięcią. Fiszka jest zresztą interesującym poprzednikiem adaptacyjnej AI: po jednej stronie znajduje się bodziec, po drugiej odpowiedź, a uczący musi najpierw wygenerować treść z pamięci, by dopiero potem sprawdzić wynik.

Inteligentny tutor może tę prostą logikę rozszerzyć: rozpoznawać rodzaj błędu, generować analogiczne przykłady, zwiększać odstęp między powtórkami, przeplatać kategorie, dodawać wskazówki i mierzyć pewność.

Wiedza wewnętrzna jako fundament weryfikacji AI

Narzędzie to nie musi zatem zastępować fiszki; może stać się dynamiczną wersją tej metody, zdolną do modelowania ucznia. W tym miejscu warto precyzyjniej zdefiniować źródłowy meta-learning. O ile w uczeniu maszynowym termin ten ma znaczenie techniczne, o tyle w edukacji człowieka adekwatniej jest rozumieć go jako rozwijanie wiedzy o tym, jak skutecznie się uczyć. Obejmuje on strategie planowania, monitorowania, wydobywania informacji, organizowania powtórek, modyfikacji metody po niepowodzeniu oraz oceny własnego stanu wiedzy. Najnowsze przeglądy dotyczące learning-to-learn w epoce generatywnej AI wskazują właśnie na retrieval, spacing i interleaving jako mechanizmy wspierające trwałą naukę, zauważając jednocześnie, że metapoznawcze planowanie i samoocena są wciąż niedostatecznie obecne w projektowaniu edukacyjnych zastosowań AI.

Jeżeli więc fakty stają się tanie, nie wynika z tego, że wiedza staje się zbędna. Przeciwnie: dostęp do nieskończonej liczby odpowiedzi zwiększa wartość struktur pozwalających odróżnić odpowiedź dobrą od pozornie dobrej. Człowiek pozbawiony wewnętrznego modelu domeny nie ma podstaw do oceny modelu zewnętrznego. Lekarz bez medycyny nie zweryfikuje klinicznej sugestii AI; prawnik bez prawa nie rozpozna fikcyjnego precedensu; historyk bez wiedzy chronologicznej może nie zauważyć eleganckiej anachronii. Weryfikacja jest kompetencją drugiego rzędu, lecz wymaga ona

wiedzy pierwszego rzędu. Podważa to popularną tezę, że w epoce AI "nie warto już niczego zapamiętywać". Choć wiele informacji rzeczywiście nie musi być przechowywanych z dawną szczegółowością, nie oznacza to, że można skutecznie myśleć bez bogatej wiedzy wewnętrznej. Pamięć robocza operuje bowiem na strukturach dostępnych w pamięci długotrwałej.

Ekspert nie analizuje problemu wyłącznie dzięki ogólnemu IQ; dysponuje tysiącami zorganizowanych reprezentacji, które umożliwiają szybkie rozpoznawanie wzorców. Zewnętrzna baza danych może dostarczać faktów, ale nie zastąpi automatycznie architektury skojarzeń niezbędnej do zadawania właściwych pytań. W tym punkcie edukacja epoki AI powraca do biologii Kandela i analizowanej na początku artykułu pamięci. Uczenie jest zmianą systemu. Jeśli po sesji z AI zmienił się wyłącznie dokument na ekranie, a reprezentacje ucznia pozostały niezmienione, wykonano pracę, lecz nie dokonano uczenia. Jeżeli jednak interakcja wymusiła aktywne przypominanie, rekonfigurację pojęć, wykrywanie błędów i transfer, technologia uczestniczyła w przebudowie systemu poznawczego. Rozróżnienie to dotyczy również pisania: wygenerowanie dobrego akapitu przez AI jest rezultatem tekstowym, podczas gdy samodzielne zmaganie się z kolejnością przesłanek, wyborem pojęcia i rozpoznaniem sprzeczności stanowi rezultat poznawczy. Nie oznacza to, że pisanie z AI jest intelektualnie jałowe.

Może być ono wręcz bogatsze, jeśli człowiek krytykuje kilka wariantów, porównuje argumentacje, żąda kontrprzykładów i dokonuje ostatecznej syntezy. Wtedy model rozszerza przestrzeń eksploracji, lecz to człowiek pozostaje systemem dokonującym selekcji. Problem zaczyna się tam, gdzie delegowana jest również ta selekcja: AI stawia pytanie, wyszukuje źródła, formułuje tezę, tworzy argumentację, sprawdza kontrargument i pisze wniosek, a użytkownik jedynie akceptuje efekt końcowy. Powstaje wtedy znakomity artefakt przy bardzo małej zmianie poznawczej użytkownika. To edukacyjny odpowiednik automatyzacji pracy: wysoka produktywność nie świadczy o tym, kto nabył kompetencję. Edukacyjna AI powinna zatem czasami celowo odmawiać natychmiastowej wydajności. Komentarz opublikowany w *Communications Psychology* w 2026 roku określa ten problem szerzej jako ryzyko "frictionless AI" – technologii usuwającej z pracy, relacji i uczenia się wszelkie formy oporu, mimo że niektóre z nich są warunkiem rozwoju.

Rozróżnienie tarcia bezproduktywnego od rozwojowego jako fundament projektowania AI

Nie chodzi tutaj o romantyzację cierpienia czy utrudnianie życia dla samej idei trudności. Kluczowe jest rozróżnienie między tarciem bezproduktywnym a tarciem rozwojowym. To pierwsze to źle zaprojektowany formularz, brak dostępu do materiałów, niejasna instrukcja czy konieczność

wykonywania mechanicznej pracy, która nie wnosi żadnej wartości poznawczej. Takie przeszkody AI powinna usuwać. Tarcie rozwojowe natomiast to wysiłek związany z przypominaniem sobie informacji, konieczność dokonania rozróżnienia, samodzielne sformułowanie hipotezy, zderzenie z kontrprzykładem, oczekiwanie na feedback czy poprawianie własnego błędu. Przed takimi trudnościami technologia powinna często chronić użytkownika przed własną zdolnością do ich zbyt szybkiego usunięcia.

Wymaga to zupełnie nowej filozofii projektowania interfejsów edukacyjnych. Tradycyjny UX dąży do minimalizacji liczby kliknięć i skrócenia czasu potrzebnego na uzyskanie wyniku. Interfejs edukacyjny może natomiast wymagać celowego opóźnienia. System, zanim wyświetli rozwiązanie, może oczekiwać próby ze strony użytkownika; może ukrywać część informacji, dopóki uczeń nie sformułuje hipotezy, lub odmówić napisania całego eseju, zastępując to sekwencją naprowadzających pytań. Z perspektywy klasycznej wygody jest to rozwiązanie gorsze, lecz z punktu widzenia neurokognitywistyki może okazać się skuteczniejszym narzędziem nauki. Nie oznacza to jednak, że każdy uczeń powinien być traktowany tak samo. Dla eksperta natychmiastowy dostęp do wyniku może być produktywnym offloadingiem rutynowej czynności, podczas gdy dla początkującego ta sama automatyzacja usunie etap niezbędny do zbudowania schematu poznawczego. AI staje się interesująca właśnie dzięki zdolności do dynamicznej zmiany poziomu wsparcia wraz z przyrostem kompetencji użytkownika.

To, co dziś służy za rusztowanie, jutro powinno zostać częściowo wycofane. W tym miejscu system AI mógłby realizować zasadę zbliżoną do strefy najbliższego rozwoju Wygotskiego. Uczeń nie powinien otrzymywać wyłącznie zadań, które już potrafi rozwiązać, ani takich, które są całkowicie poza jego zasięgiem. Największy potencjał rozwojowy drzemie w obszarze, w którym samodzielne wykonanie jeszcze zawodzi, lecz minimalne wsparcie umożliwia sukces. Generatywny tutor posiada tu istotną przewagę: może regulować zakres pomocy niemal po każdym zdaniu ucznia. Taka personalizacja jest jednak wymagająca epistemicznie. Model musi trafnie odróżnić brak wiedzy od chwilowego błędu, a brak motywacji od braku zdolności czy niepewność konstruktywną od przeciążenia poznawczego. Może się pomylić. Jeśli system pomaga zbyt szybko, obniża wysiłek niezbędny do nauki; jeśli zbyt długo odmawia wsparcia – generuje frustrację. Personalizacja trudności jest zatem problemem sterowania analogicznym do procesów biologicznych: należy utrzymywać system w dynamicznym zakresie między niedostateczną a nadmierną perturbacją.

Nauczyciel jako kurator socjalizacji epistemicznej i krytycznego myślenia

Właśnie dlatego nauczyciel nie staje się automatycznie zbędny, nawet jeśli AI potrafi indywidualizować ćwiczenia. Trafna jest propozycja przesunięcia jego roli w stronę "kuratorowania przestrzeni poszukiwań" i meta-learningu. Nauczyciel może poświęcać mniej czasu na mechaniczne przekazywanie tych samych wyjaśnień, a więcej na diagnozę rozwoju, projektowanie sekwencji doświadczeń, budowanie motywacji czy organizowanie współpracy. To on ocenia oryginalność rozumowania i wprowadza ucznia w normy konkretnej wspólnoty wiedzy. Edukacja nie jest bowiem wyłącznie transferem informacji; jest również socjalizacją epistemiczną. Student fizyki uczy się, co fizyk uznaje za dowód, student historii – jak ważyć źródła, a przyszły lekarz – kiedy objaw jest diagnostycznie istotny i kiedy nie należy ufać pierwszej odpowiedzi.

Naukowiec uczy się nie tylko samych rozwiązań, lecz standardów ich uzasadniania. Są to normy praktyki społecznej, przekazywane częściowo poprzez uczestnictwo we wspólnocie ekspertów. AI może tę socjalizację wspierać, ale może też generować jej pozór. Model potrafi tworzyć teksty przypominające artykuły naukowe, nie ponosząc jednak odpowiedzialności autora za prawdziwość twierdzeń. Może symulować pewność profesora, jednocześnie halucynując źródła. Dlatego edukacja w epoce AI musi uczyć nie tylko obsługi systemów generatywnych, lecz przede wszystkim rozumienia warunków wiarygodności ich wypowiedzi. Z tej perspektywy krytyczne czytanie staje się kompetencją ważniejszą niż samo pisanie. Badania z 2024 roku wskazują, że zadania wymagające krytyki tekstów poprawiają zdolność analitycznego czytania skuteczniej niż zwykłe streszczanie.

W świecie, w którym AI generuje dowolnie gładkie treści, uczeń powinien być regularnie konfrontowany z materiałem zawierającym subtelne błędy, brakujące przesłanki i pozornie wiarygodne źródła. Celem nie jest wtedy wypracowanie odpowiedzi, lecz rozpoznanie, dlaczego danej odpowiedzi nie należy przyjąć. Można zatem odwrócić tradycyjną relację człowiek-AI: zamiast prosić model o ocenę ucznia, proces edukacyjny można zaprojektować tak, by to uczeń oceniał model.

Jeśli AI wygeneruje kilka wariantów argumentacji, z których jeden zawiera ukryty błąd, uczeń musi wskazać różnicę, uzasadnić decyzję i poprawić wadliwy tok rozumowania. Model przestaje być wtedy wyrocznią, a staje się partnerem treningowym produkującym kontrolowaną zmienność. Jest to kluczowe, gdyż prawdziwa inteligencja ekspercka objawia się nie w umiejętności podania odpowiedzi, lecz w rozpoznaniu sytuacji, w której typowe rozwiązanie zawodzi. Początkujący zapamiętuje regułę; ekspert zna warunki brzegowe. AI świetnie radzi sobie z regułami, dlatego

edukacja człowieka powinna koncentrować się na wyjątkach, konfliktach i problemach niedookreślonych – tam, gdzie kilka rozsądnych zasad prowadzi do sprzecznych rekomendacji. Takie zadania są najtrudniejsze do standaryzacji i historycznie najbardziej kosztowne edukacyjnie.

Wymagają one dialogu i indywidualnego feedbacku. Jeśli AI obniży koszt tego dialogu niemal do zera, może paradoksalnie umożliwić odejście od masowej pedagogiki testu na rzecz sokratejskiej rozmowy. Potencjał ten nie realizuje się jednak automatycznie wraz z otwarciem okna chatbota – wymaga świadomego projektu dydaktycznego. Tutoring AI powinien być zatem oceniany nie przez pryzmat szybkości odpowiedzi, lecz według tego, jak często skutecznie powoduje powstanie wiedzy odpornej na jego własną nieobecność.

Kryterium to jest znacznie bardziej wymagające niż satysfakcja użytkownika. Uczniowie mogą preferować tutorów nadmiernie pomagających, podobnie jak wolą łatwiejsze formy praktyki. System optymalizowany wyłącznie pod engagement może stać się edukacyjnie nadopiekuńczy. Pojawia się tu konflikt funkcji celu analogiczny do problemu alignment: platforma może optymalizować czas korzystania i poczucie sukcesu, podczas gdy edukacja powinna optymalizować trwałą kompetencję. Te miary nie muszą być zbieżne. Uczeń zadowolony z płynnej sesji niekoniecznie uczy się więcej. System, który czasem mówi „najpierw spróbuj sama”, może uzyskać gorszą ocenę komfortu, ale lepszy wynik edukacyjny. Takie rozumienie pozwala także inaczej spojrzeć na „halucynacje”.

Sprawczość epistemiczna i hybrydowa kognicja jako cel edukacji z AI

W zwykłym zastosowaniu błędy są wadą systemu. W odpowiednio zaprojektowanym ćwiczeniu mogą jednak stać się materiałem pedagogicznym, o ile pozostają kontrolowane, a nauczyciel lub system referencyjny zna prawidłową odpowiedź. Uczeń, ucząc się rozpoznawać nieistniejące źródła, błędne inferencje i zbyt kateryczne twierdzenia, rozwija odporność epistemiczną potrzebną nie tylko wobec AI, ale także wobec ludzkiej dezinformacji. Docelowym rezultatem takiej edukacji nie jest człowiek rywalizujący z AI w szybkości generowania faktów, lecz taki, który posiada dobry model tego, co warto delegować, czego delegować nie wolno i kiedy należy odzyskać kontrolę nad procesem poznawczym. To poziom kompetencji wyższy niż klasyczna biegłość narzędziowa; można go nazwać sprawczością epistemiczną.

Sprawczość ta wymaga pamięci – bez wystarczającego zasobu zinternalizowanej wiedzy człowiek nie wie, czego nie wie. Wymaga metapoznania, by rozpoznawać własną niepewność, oraz wiedzy o

narzędziu, aby rozumieć jego typowe błędy. Wymaga również systemu wartości, ponieważ nie każda optymalizacja powinna być delegowana: to człowiek musi ustalić, jakie pytanie jest istotne i jaki rodzaj konsekwencji jest dopuszczalny.

W ten sposób edukacja przywraca nas do wcześniejszych części artykułu. Pamięć, predykcja, wartościowanie, podmiotowość i autonomia nie były osobnymi tematami – wszystkie zbiegają się w pytaniu o to, kto ostatecznie kieruje procesem poznawczym. Można zatem sformułować bardziej precyzyjną wersję tezy o AI jako rozszerzeniu biologii. AI rzeczywiście może stać się zewnętrznym systemem pamięci, generowania hipotez i spersonalizowanego feedbacku, rozszerzając poznawczy zasięg człowieka poza ograniczenia czasu, pamięci roboczej czy dostępności eksperta. Nie oznacza to jednak, że biologiczne uczenie staje się zbędne. Im potężniejsza jest inteligencja zewnętrzna, tym większego znaczenia nabiera wewnętrzna architektura zdolna ją kontrolować. Najbardziej wartościowa AI edukacyjna nie powinna prowadzić do sytuacji, w której człowiek wie coraz mniej, bo system wie coraz więcej. Powinna umożliwiać proces odwrotny: dzięki temu, że system dysponuje szerszą wiedzą i lepiej steruje sekwencją ćwiczeń, człowiek może budować bogatsze, bardziej uporządkowane i lepiej skalibrowane struktury poznawcze. Technologia staje się wtedy nie substytutem plastyczności biologicznej, lecz instrumentem organizującym warunki, w których ta plastyczność może zostać skuteczniej wykorzystana. Tak właśnie można odczytać osobistą metaforę fiszki z materiału źródłowego – narzędzie było proste, lecz zmieniło relację dziecka do zadania.

AI może być nieskończenie bardziej złożoną wersją takiego rusztowania. Jej wartość nie będzie jednak zależeć od liczby parametrów, lecz od tego, czy potrafi pozostawić uczniowi właściwy fragment problemu do samodzielnego wykonania. Dlatego edukacyjna przyszłość AI nie jest przyszłością bez wysiłku, lecz przyszłością lepiej dobranego wysiłku. System powinien usuwać trudności przypadkowe i administracyjne, pozbawione wartości rozwojowej, zachowując jednak wysiłek wydobywania, generowania, krytyki, transferu i samodzielnego formułowania sądów. Dobra AI nie powinna ani maksymalizować tarcia, ani go całkowicie likwidować; powinna uczyć się, gdzie tarcie stanowi kluczową informację dla rozwijającego się umysłu.

W tym miejscu emergencja powraca do swojego pedagogicznego początku. Nowa kompetencja nie zostaje wlana w człowieka w gotowej postaci, lecz powstaje z wielokrotnej interakcji wcześniejszej wiedzy, błędu, informacji zwrotnej, czasu i ponownej próby. Nauczyciel, książka, fiszka i AI są elementami środowiska, które tę dynamikę może wzmacniać lub hamować. Nie uczymy się dlatego, że odpowiedź istnieje, lecz wtedy, gdy kontakt z nią zmienia strukturę systemu, który później będzie musiał poradzić sobie bez niej. Ta konkluzja prowadzi do jeszcze szerszego problemu.

Jeżeli AI staje się stałym składnikiem pamięci, pracy, edukacji i twórczości, pytanie przestaje dotyczyć wyłącznie sposobu korzystania z narzędzia. Trzeba zacząć badać, jak stałe współmyślenie z

AI zmienia samą architekturę ludzkiej kognicji. Czy będziemy zapamiętywać mniej faktów, a więcej strategii dostępu? Czy zwiększy się nasza zdolność do abstrakcyjnego projektowania problemów, czy przeciwnie – osłabnie cierpliwość wobec poznawczego oporu? Czy część funkcji wykonawczych zostanie trwale przeniesiona na systemy zewnętrzne?

Czy człowiek korzystający przez dwadzieścia lat z osobistego AI będzie poznawczo tym samym podmiotem, co człowiek sprzed epoki modeli generatywnych? To stanie się przedmiotem kolejnego etapu analizy: nie świadomość AI, lecz zmiana ludzkiej świadomości wskutek stałej obecności technologii. Wcześniej pytaliśmy, czy sztuczny system może upodobnić się do człowieka. Teraz należy odwrócić perspektywę i zapytać, w jakim stopniu człowiek przebuduje własne strategie pamięci, uwagi, autorstwa i tożsamości pod wpływem głęboko zintegrowanej inteligencji zewnętrznej. Wtedy idea emergencji obejmie już nie dwa oddzielne systemy – biologiczny i cyfrowy – lecz trzeci poziom organizacji: hybrydową kognicję człowiek-AI, której właściwości mogą nie być prostą sumą zdolności żadnej ze stron.

Czy człowiek, który przez dekady współmyśli z osobistym systemem AI, pozostanie tym samym podmiotem poznawczym, co jego przodek sprzed ery modeli generatywnych? Być może nie stoimy przed prostą aktualizacją narzędzi, lecz przed narodzinami hybrydowej kognicji, w której granica między biologiczną pamięcią a cyfrowym rozszerzeniem ulegnie całkowitemu zatarciu. Pytanie brzmi: czy w tym procesie zyskamy nową formę intelektualnej wolności, czy staniemy się jedynie sprawnymi operatorami systemów, których wewnętrznej logiki przestaliśmy rozumieć?

Inspiracje

[1] "Emergence" Bob Burgin

Bob Burgin to amerykański przedsiębiorca, innowator w dziedzinie oprogramowania i naukowiec zajmujący się uczeniem się, mieszkający w Boulder w stanie Kolorado. Najbardziej znany jest jako założyciel, prezes i dyrektor generalny Amplifire, adaptacyjnej platformy technologii edukacyjnych opartej na kognitywistyce i neuronauce. W ciągu ponad trzydziestoletniej kariery Burgin skupiał się na przekładaniu laboratoryjnych badań kognitywnych na praktyczne oprogramowanie, aby usprawnić proces uczenia się, zmniejszyć ryzyko organizacyjne i korygować dezinformację w środowiskach wysokiego ryzyka, takich jak opieka zdrowotna. Współpracując ściśle z wybitnymi psychologami poznawczymi i neurobiologami – w tym z Robertem Björkiem, Danielem Schacterem i Henrym Roedigerem III – Burgin badał, w jaki sposób ludzka architektura neuronalna koduje, konsoliduje i odzyskuje wiedzę. Jego badania i publikacje zgłębiają, w jaki sposób ograniczenia i mechanizmy biologiczne w ludzkim mózgu dostarczają fundamentalnych informacji na temat systemów uczenia maszynowego i sztucznej inteligencji.

Bob Burgin is an American entrepreneur, software innovator, and learning scientist based in Boulder, Colorado. He is best known as the founder, Chairman, and Chief Executive Officer of Amplifire, an adaptive educational technology platform grounded in cognitive science and neuroscience. Over a career spanning more than three decades, Burgin has focused on translating laboratory cognitive research into practical software to improve human learning, reduce organizational risk, and correct misinformation in high-stakes environments such as healthcare. Working in close collaboration with prominent cognitive psychologists and neuroscientists—including Robert Bjork, Daniel Schacter, and Henry Roediger III—Burgin investigated how human neural architecture encodes, consolidates, and retrieves knowledge. His research and writing explore how constraints and biological mechanisms in the human brain provide foundational insights into machine learning and artificial intelligence systems.

Amplifire

Literatura uzupełniająca

Książki

Literatura pokrewna (Google Scholar):

[1] "In Search of Memory"

Eric Kandel


[2] "Cellular basis of behavior : an introduction to behavioral neurobiology / Eric R. Kandel. - 1976"

Eric Kandel

W.H. Freeman | ISBN: 9780716705239

[3] "The age of the unconscious"

Eric Kandel



[4] "Thought and Language"

Lew Vygotski

MIT Press | ISBN: 9780262720106



[5] "Los Angeles Magazine"

2003

Artykuły naukowe

Autorzy przywoływani:

[1] "A Computer Network Model of Human Transactive Memory"

Daniel M. Wegner

1995 | Social Cognition | DOI: 10.1521/soco.1995.13.3.319

[Google Scholar](#)

[2] "Unsupervised Machine Learning on a Hybrid Quantum Computer"

Johannes Otterbach, Riccardo Manenti, Nima Alidoust, Andrew J. Bestwick, Maxwell Block, Benjamin Bloom

2017 | arXiv (Cornell University) | DOI: 10.48550/arxiv.1712.05771

[Google Scholar](#)

[3] "The Molecular Biology of Memory Storage: A Dialogue Between Genes and Synapses"

Eric R. Kandel

2001 | Science | DOI: 10.1126/science.1067020

[Google Scholar](#)

[4] "Molecular Biology of Learning: Modulation of Transmitter Release"

Eric R. Kandel, James H. Schwartz

1982 | Science | DOI: 10.1126/science.6289442

[Google Scholar](#)

[5] "Cognitive Neuroscience and the Study of Memory"

Brenda Atkinson Milner, Larry R. Squire, Eric R. Kandel

1998 | Neuron | DOI: 10.1016/s0896-6273(00)80987-3

[Google Scholar](#)

[6] "Impaired Long-Term Potentiation, Spatial Learning, and Hippocampal Development in fyn Mutant Mice"

Seth G. N. Grant, Thomas J. O'Dell, Kevin A. Karl, Paul L. Stein, Philippe M. Soriano, Eric R. Kandel

1992 | Science | DOI: 10.1126/science.1361685

[Google Scholar](#)

[7] "Electricity demand loads modeling using AutoRegressive Moving Average (ARMA) models"

Stylianos Sp. Pappas, Lambros Ekonomou, Dimitrios Ch. Karamousantas, George E. Chatzarakis, Sokratis K. Katsikas

2008 | Energy | DOI: 10.1016/j.energy.2008.05.008

[Google Scholar](#)

[8] "Electricity demand load forecasting of the Hellenic power system using an ARMA model"

Stylianos Sp. Pappas, Lambros Ekonomou, Panagiotis Karampelas, Dimitrios Ch. Karamousantas, Sokratis K. Katsikas

2009 | Electric Power Systems Research | DOI: 10.1016/j.epsr.2009.09.006

[Google Scholar](#)

[9] "Health care management and information systems security: awareness, training or education?"

Sokratis K. Katsikas

2000 | International Journal of Medical Informatics | DOI: 10.1016/s1386-5056(00)00112-x

[Google Scholar](#)

[10] "Managing Cyber Security Risks of the Cyber-Enabled Ship"

Georgios Kavallieratos, Sokratis K. Katsikas

2020 | Journal of Marine Science and Engineering | DOI: 10.3390/jmse8100768

[Google Scholar](#)

 Treść tworzy Fundacja Dobre Państwo.

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

APA ONE Publishing System

Fundacja Dobre Państwo © 2026

Article ID: 764c56d9-c369-42cd-a999-23b7a5ae9bbf