

Maszyna bez sądu: dlaczego AI potrzebuje człowieka



AUTOR

Fundacja Dobre Państwo

STRESZCZENIE / ABSTRACT

Artykuł analizuje kryzys współczesnego zarządzania, który polega na próbie okiełznania nieliniowej sztucznej inteligencji za pomocą przestarzałej „mentalności arkusza kalkulacyjnego”. Autor, odwołując się do koncepcji Scotta M. Shemwella, wskazuje, że organizacje muszą porzucić redukcjonistyczne podejście na rzecz teorii systemów złożonych i zarządzania wysoką niezawodnością. Kluczowym narzędziem tej transformacji jest model RBC (Relacje, Zachowania, Warunki), który pozwala na głębszą analizę interakcji między technologią a czynnikiem ludzkim. W tekście podkreślono znaczenie standardów takich jak ISO/IEC 42001:2023 oraz AI Act w budowaniu bezpiecznych ekosystemów cyfrowych. AI nie jest jedynie narzędziem automatyzacji, lecz testem dojrzałości instytucjonalnej, wymagającym od decydentów czujności i zrozumienia nieliniowych sprzężeń zwrotnych.

This article examines the crisis in contemporary management, which involves attempts to tame nonlinear artificial intelligence with an outdated "spreadsheet mentality." Drawing on Scott M. Shemwell's concepts, the author argues that organizations must abandon reductionist approaches in favor of complex systems theory and high-reliability management. A key tool in this transformation is the RBC (Relationships, Behaviors, Conditions) model, which allows for a deeper analysis of the interactions between technology and the human factor. The text emphasizes the importance of standards such as ISO/IEC 42001:2023 and the AI Act in building secure digital ecosystems. AI is not merely a tool for automation, but a test of institutional maturity, requiring decision-makers to be vigilant and understand nonlinear feedback loops.

Współczesne organizacje tkwią w pułapce „społeczeństwa arkusza kalkulacyjnego”, próbując zarządzać dynamicznym, nieliniowym ekosystemem AI za pomocą sztywnych tabel i liniowych prognoz. Tekst dowodzi, że sztuczna inteligencja nie jest magicznym

rozwiązaniem chaosu, lecz jego wzmacniaczem, który bezlitośnie obnaża braki w dojrzałości instytucjonalnej. Główna teza artykułu wskazuje na konieczność porzucenia naiwnego technocentryzmu na rzecz myślenia systemowego i zarządzania wysoką niezawodnością. Autor, czerpiąc z koncepcji Scotta M. Shemwella, przekonuje, że sukces w dobie algorytmów zależy od rygorystycznej dbałości o pochodzenie danych (data provenance), eliminacji błędów poznawczych oraz powołania funkcji Chief AI Officer, która pełniłaby rolę strażnika jakości i etyki. Artykuł demaskuje zjawisko „AI-washingu” i ostrzega przed sykofantyzmem modeli, które zamiast rzucać wyzwanie błędnym strategiom, często jedynie schlebiają liderom. Prawdziwa przewaga konkurencyjna rodzi się nie z posiadania algorytmów, lecz ze zdolności organizacji do krytycznej weryfikacji danych i utrzymania ludzkiego sądu jako ostatecznej linii obrony przed technologiczną iluzją.

SŁOWA KLUCZOWE

sztuczna inteligencja

mentalność arkusza kalkulacyjnego

nieliniowe rozwiązywanie problemów

model RBC

ISO/IEC 42001:2023

zarządzanie ryzykiem

AI Act

błąd poznawczy

Big Data

systemy złożone

ekosystem AI

kolaps modelu

dane syntetyczne

zarządzanie wysoką niezawodnością

epistemologia zarządzania

Koniec ery arkusza: dlaczego AI wymaga zmiany paradygmatu

Błędem współczesnych organizacji nie jest brak dostępu do algorytmów, lecz fakt, że posiadając sztuczną inteligencję, wciąż operują mentalnością arkusza kalkulacyjnego. Porządkują one świat w sztywne rubryki, klasy i prognozy liniowe, jakby rzeczywistość była potulnym księgowym, a nie niesforemym ekosystemem pełnym ukrytych zmiennych i nagłych sprzężeń zwrotnych. W tym świecie ludzkie zachowania w poniedziałek przypominają chłodną racjonalność, by we wtorek przeobrazić się w pożar w muzeum rachunkowości, którego nie ugasi żadna formuła Excela. Organizacje te próbują zamknąć nieprzewidywalność w komórkach tabeli, ignorując fakt, że życie rzadko mieści się w granicach wyznaczonych przez obramowanie wiersza. To zderzenie statycznej struktury z dynamicznym chaosem jest fundamentem współczesnych porażek wdrożeniowych,

gdzie technologia, zamiast pomagać, staje się źródłem frustracji. Myślenie tabelaryczne w starciu z nieliniową naturą AI musi bowiem doprowadzić do bolesnego poznawczego zatoru.

Scott M. Shemwell w swojej koncepcji nieliniowego rozwiązywania problemów przy pomocy Big Data i AI uderza precyzyjnie w ten czuły punkt menedżerskiej psychiki. Jego diagnoza jest intelektualnie niewygodna, ale ekonomicznie niezbędna: nowoczesna instytucja nie może dłużej trwać jako spreadsheet society, czyli społeczeństwo arkusza kalkulacyjnego. Choć arkusz jest jednym z wielkich fundamentów cywilizacji zarządzania, posiada on własną, podstępłą metafizykę, która uczy nas, że wszystko, co istotne, da się wpisać w pojedynczą komórkę. Sugeruje on, że każdy problem ma wymiar wiersza i kolumny, a to, co poznawczo niewygodne, można bezpiecznie ukryć w załączniku, którego nikt nigdy nie otworzy. Kiedy jednak świat zaczyna działać nieliniowo, ten elegancki instrument kontroli staje się narzędziem wyrafinowanego samooszustwa, maskującym realne zagrożenia pod warstwą estetycznych wykresów. Teza Shemwella trafia w samo centrum przeobrażenia cywilizacyjnego, wymagając od nas porzucenia bezpiecznych, lecz jednak fałszywych pewników.

Organizacje pragnące przetrwać w dobie algorytmów nie mogą po prostu dokleić AI do swoich skostniałych, analogowych procesów, gdyż efekt będzie opłakany. Nie da się przecież przytwierdzić silnika odrzutowego do drewnianego wozu i z powagą ogłosić narodzin nowoczesnego lotnictwa. Podobnie wdrożenie modelu językowego w strukturze, która nie rozumie własnych danych i myli automatyzację z odpowiedzialnością, jest prostą drogą do katastrofy. Musimy zrozumieć, że AI nie zbawia chaosu, lecz go drastycznie przyspiesza, działając niczym wzmacniacz błędów w rękach nieprzygotowanych decydentów. Jeśli ład decyzyjny kuleje, a governance uchodzi za nudną ceremonię compliance, technologia jedynie uwypukli te patologie, zamiast je uleczyć. Demo pokazuje możliwości, ale dopiero pełna produkcja pokazuje prawdę o kondycji instytucji.

Współczesny paradygmat naukowy dotyczący Big Data odchodzi od redukcjonistycznego przekonania, że firma jest prostą maszyną, którą wystarczy podkreślić właściwymi wskaźnikami. Nowe podejście czerpie z teorii systemów złożonych, cybernetyki drugiego rzędu oraz koncepcji High Reliability Management, czyli zarządzania wysoką niezawodnością skupionego na czujności wobec drobnych odchyśleń. Szpital, sieć energetyczna czy administracja publiczna nie są zbiorami izolowanych procesów, lecz żywymi ekosystemami, w których ruch jednego aktora natychmiast zmienia warunki gry dla wszystkich pozostałych. Te nieliniowe zależności sprawiają, że tradycyjne planowanie strategiczne przypomina próbę układania puzzli podczas trzęsienia ziemi, gdzie obrazek ciągle się zmienia. Zrozumienie tej złożoności chroni przed ryzykiem epistemicznym, czyli zagrożeniem dotyczącym sposobu, w jaki budujemy wiedzę i odróżniamy prawdę od fałszu. Firma

musi przestać być zbiorem procedur, a stać się organizmem zdolnym do adaptacji w czasie rzeczywistym.

W tym kontekście kluczowy staje się model RBC, czyli triada relacji, zachowań i warunków, który stanowi ramę tylko pozornie prostą w swojej konstrukcji. Relacje opisują gęstą sieć zależności między ludźmi, działami, dostawcami oraz systemami informatycznymi, tworząc krwiociąg każdej nowoczesnej instytucji. Zachowania to realne praktyki, a nie deklarowane na plakatach wartości: to one decydują o tym, kto ma odwagę sprawdzić wynik AI, a kto przepisuje go bez namysłu. Warunki natomiast definiują otoczenie technologiczne i prawne, które sztuczna inteligencja zmienia w sposób radykalny i często nieodwracalny. Jeśli te zmienione warunki nie wymuszają ewolucji zachowań, relacje wewnątrz organizacji ulegają szybkiej degradacji, co stanowi gotowy przepis na systemową niewydolność. Jest to mała teoria wielkich tragedii, w której brak zrozumienia kontekstu prowadzi do spektakularnego upadku nawet najlepiej dofinansowanych projektów.

Shemwell wskazuje, że AI jest w istocie testem dojrzałości antropologicznej, który bezlitośnie obnaża różnicę między kulturą uczenia się a kulturą pustych deklaracji. Technologia ta ujawnia, czy organizacja potrafi zarządzać realnym ryzykiem, czy jedynie produkuje opasłe tomy dokumentacji o jego teoretycznym istnieniu. Sprawdza ona, czy potrafimy odróżnić sygnał od szumu, czy może każdą przypadkową korelację bierzemy za objaw boskiej geometrii rynku i nieomylny drogowskaz. Metafora abstrakcji podpowiada tu obraz niemalże średniowieczny: zarząd pochylony nad nowoczesnym dashboardem przypomina kapłanów interpretujących wnętrzności ofiarnego byka. Tyle że w tym przypadku byk rezyduje w chmurze obliczeniowej, a jego metafizyczne wnętrzności mają swojski format pliku CSV, który wszyscy akceptują bez pytania. Ostatecznie to nie algorytmy zawiodą, lecz nasza niezdolność do porzucenia nekromancji tabelarycznej na rzecz zrozumienia żywego, pulsującego systemu.

AI jako ekosystem: dlaczego dane potrzebują ludzkiego sądu

Współczesna sztuczna inteligencja, zwłaszcza w swojej formie generatywnej i agentowej, wymusza na nas bolesne porzucenie wygodnego myślenia narzędziowego na rzecz perspektywy ekosystemowej. Model nie jest bowiem odrębnym, martwym przedmiotem, który można po prostu kupić, wdrożyć i o nim zapomnieć. On żyje w nieustannym obiegu danych, gęstej sieci zależności, procedur, integracji oraz norm prawnych i ludzkich praktyk. Jego ostateczna jakość zależy od czystości danych wejściowych, architektury nadzoru, procesu walidacji oraz odporności na nieuchronny dryf. Musimy brać pod uwagę sposób mierzenia wartości biznesowej, kulturę

użytkowania oraz krytyczne decyzje o tym, komu wolno ufać i kiedy należy system zatrzymać. AI nie zbawia chaosu. AI go przyspiesza.

Norma ISO/IEC 42001:2023, określana przez ekspertów jako pierwszy światowy standard systemu zarządzania sztuczną inteligencją, stanowi formalny wyraz tej głębokiej zmiany paradygmatu. Dokument ten jasno wskazuje, że AI przestała być wyłącznie produktem technicznym, stając się przedmiotem systemowego zarządzania ryzykiem, odpowiedzialnością oraz transparentnością. Wdrożenie tego standardu wymaga od organizacji przejścia do modelu ciągłego doskonalenia, gdzie technologia jest poddawana nieustannej wiwisekcji. Nie chodzi tu o jednorazowy audyt, lecz o stworzenie żywego organizmu kontrolnego, który nadąża za ewolucją algorytmów. Takie podejście pozwala uniknąć pułapki, w której skomplikowany system staje się czarną skrzynką poza kontrolą zarządu.

To fundamentalne przesunięcie ma doniosłe znaczenie prawne, ekonomiczne oraz kulturowe, zmieniając sposób, w jaki definiujemy nowoczesne przedsiębiorstwo. Wymiar prawny staje się kluczowy, ponieważ AI wchodzi w obszary, gdzie decyzje bezpośrednio dotyczą zdrowia, kredytów, zatrudnienia czy bezpieczeństwa infrastruktury krytycznej. Europejski AI Act, który wszedł w życie 1 sierpnia 2024 roku, ustanawia logikę regulacyjną opartą na rygorystycznej ocenie ryzyka. Choć jego praktyczne stosowanie jest rozłożone w czasie i budzi liczne spory polityczne, kierunek jest jasny i nieodwołalny. Organizacje muszą przygotować się na nową erę, w której zgodność z przepisami będzie równie ważna jak wydajność procesora.

W sferze ekonomicznej organizacje z zaskoczeniem odkrywają, że realny zwrot z inwestycji w AI nie wynika z samego zachwyty nad nowym modelem. Prawdziwa wartość rodzi się z głębokiej przebudowy procesów, optymalizacji kosztów, skrócenia czasu pracy oraz budowania trwałej przewagi operacyjnej. Kulturowo natomiast AI zmienia nasze wyobrażenie o wiedzy, kompetencji i tradycyjnie pojmowanym autorytecie. Kiedy model odpowiada pewnie, elegancko i natychmiastowo, człowiek musi nauczyć się nowej, trudnej cnoty, czyli nieulegania retoryce płynności. Musimy zachować czujność wobec systemów, które potrafią maskować brak merytorycznej głębi za pomocą nienagannej gramatyki i pewnego tonu.

Krytyka „społeczeństwa arkuszy kalkulacyjnych” jest w tym kontekście czymś znacznie więcej niż tylko prostym atakiem na cyfrowe narzędzia. Stanowi ona głęboką krytykę pewnej epistemologii zarządzania, która wierzy w możliwość pełnej kontroli nad światem poprzez jego kategoryzację. Liniowy menedżer naiwnie sądzi, że jeśli podzieli rzeczywistość na sztywne kategorie, uzyska nad nią absolutną władzę. Menedżer ekosystemowy wie jednak doskonale, że każda kategoria może oślepić i ukrywać istotne zjawiska zachodzące na obrzeżach. Podczas gdy ten pierwszy pyta o

aktualny trend, menedżer nieliniowy docieka, kiedy dany trend przestanie być trendem, a stanie się niszczycielską lawiną.

Liniowy menedżer z upodobaniem mierzy średnią, czując się bezpiecznie w samym centrum statystycznego rozkładu. Menedżer nieliniowy natomiast z niepokojem przygląda się ogonom rozkładu, zdarzeniom skrajnym oraz temu, co rzadkie, lecz potencjalnie destrukcyjne. Ten pierwszy uwielbia prognozy, traktując je jak mapy drogowe, podczas gdy drugi pyta przede wszystkim o to, co każda prognoza pomija. Tu właśnie pojawia się pojęcie „czarnego łabędzia” (Black Swan), czyli zdarzenia o niskim prawdopodobieństwie, ale posiadającego katastrofalne konsekwencje dla całego systemu. Organizacje zazwyczaj deklarują, że zarządzają takimi ryzykami, lecz w praktyce często skupiają się tylko na tym, co już potrafią nazwać.

Ryzyko nazwane mieści się w procedurze, stając się elementem rutynowego zarządzania, który rzadko budzi większe emocje. Ryzyko nienazwane natomiast mieszka w gęstym cieniu procedury i cierpliwie czeka, aż ktoś z dumą ogłosi, że system działa zgodnie z założeniami. Właśnie w tym miejscu AI ujawnia swoją prawdziwą wartość, mogąc wykrywać wzorce przedjęzykowe, anomalie oraz korelacje rozproszone w ogromnych zbiorach. Potrafi ona dostrzec niestabilne sprzężenia i sygnały ukryte w wolumenach danych niemożliwych do ręcznej analizy przez człowieka. Niemniej jednak, właśnie z tego powodu AI bywa niebezpieczna, stając się arystokratycznym wzmacniaczem błędu, jeśli zostanie nakarmiona niewłaściwymi danymi.

„Dane są jak śmieci. Lepiej wiedzieć, co zamierzasz z nimi zrobić, zanim zaczniesz je zbierać”. Ten bon mot, przypisywany Markowi Twainowi, brzmi dziś jak fundamentalna konstytucja rozsądku dla całej epoki Big Data. Organizacje przez lata gromadziły dane z entuzjazmem chomika metafizyka, wierząc, że każda informacja obiecuje jakąś nieokreśloną, przyszłą wartość. Wszystko archiwizowano bez głębszej refleksji, tworząc cyfrowe magazyny pełne nieużytecznych zasobów, które z czasem stały się ciężarem. Jednak dane bez jasnego pochodzenia, kontekstu, jakości i semantyki nie są aktywem, lecz jedynie kosztownym hałasem w eleganckim opakowaniu.

Jeżeli AI ma efektywnie pracować na danych, musimy najpierw zapytać, czy są one reprezentatywne, aktualne, zgodne i kompletne. Należy sprawdzić, czy są one uczciwie opisane, prawnie używalne oraz wolne od toksycznych skrótów myślowych, które mogą zniekształcać wyniki. Pułapki danych są wielowarstwowe, a pierwszą z nich jest integracja, czyli proces łączenia rozproszonych zasobów w spójną całość. W wielu organizacjach systemy legacy, ręczne arkusze i bazy CRM tworzą coś, co przypomina raczej archeologiczne stanowisko po kilku cywilizacjach informatycznych. Dane te zbierano w różnych celach, przez różne zespoły i według skrajnie odmiennych standardów technologicznych.

AI nie rozwiązuje automatycznie tej niespójności, lecz może ją sprytnie ukryć pod płaszczykiem płynnej i przekonującej odpowiedzi. Jest to szczególnie podstępne, ponieważ odpowiedź wygenerowana przez model często brzmi bardziej spójnie niż chaotyczny materiał, z którego pierwotnie powstała. Drugą warstwę stanowią błędy poznawcze, gdyż dane nigdy nie są całkowicie wolne od sposobu, w jaki zdecydowano się je zbierać. Błąd potwierdzenia (confirmation bias) sprawia, że organizacja podświadomie szuka w danych potwierdzenia dla już wcześniej przyjętej strategii. Błąd dostępności (availability bias) z kolei zmusza nas do używania danych najłatwiej dostępnych, zamiast tych, które są faktycznie najlepsze.

Błąd przeżywalności (survivorship bias) sprawia, że analizujemy tylko tych, którzy przetrwali, ignorując milczącą większość tych, którzy zbankrutowali lub nigdy nie weszli do próby. Fałszywa przyczynowość (false causality), polegająca na uznaniu korelacji za bezpośredni związek przyczynowo-skutkowy, sprawia, że błędne wnioski paradytują po zarządach jak ministrowie bez teki. Właśnie dlatego rola ekspertów dziedzinowych (SME) jest absolutnie kluczowa dla zachowania zdrowego rozsądku w procesie analitycznym. Bez ich wsparcia AI widzi jedynie suche dane, lecz nie potrafi dostrzec świata, z którego te dane pierwotnie pochodzą. Trzecią warstwę problemów stanowi błąd statystyczny (bias), który potrafi subtelnie deformować każdą próbę badawczą.

Błąd doboru próby (sampling bias) deformuje próbę, podczas gdy pominięcie zmiennych (omitted variables) wycina zmienne istotne, co prowadzi do niedouczenia modelu lub wyciągania fałszywych wniosków. Błąd finansowania (funding bias) potrafi natomiast subtelnie lub brutalnie dopasować całą analizę do oczekiwań sponsora, niszcząc obiektywizm badania. Błąd przedziału czasowego (time interval bias) pozwala tak zmanipulować okres obserwacji, by wykazać niemal dowolną, z góry założoną tezę biznesową. W świecie sztucznej inteligencji te błędy nie znikają, lecz jedynie zmieniają swoją skalę, stając się trudniejszymi do wykrycia. Model może być potężnym narzędziem dyscypliny poznawczej, ale równie dobrze może stać się statystycznym iluzjonistą w służbie korporacyjnej narracji.

Czwarta warstwa to dane syntetyczne i ryzyko kolapsu modelu, co stanowi obecnie jedno z największych wyzwań dla badaczy. Badania opublikowane w „Nature” w 2024 roku pokazały, że trenowanie kolejnych generacji modeli na danych generowanych rekurencyjnie prowadzi do procesów degeneracyjnych. Modele karmione zanieczyszczonymi przez siebie danymi zaczynają błędnie postrzegać rozkład rzeczywistości, tracąc zdolność uchwycenia rzadkich, ale istotnych przypadków. To naukowe potwierdzenie intuicji, że AI potrzebuje czystych źródeł oraz rygorystycznego zarządzania danymi (data governance), czyli systemowego zarządzania jakością i pochodzeniem danych. Bez tego grozi jej sztuczny chów wsobny, produkujący odpowiedzi coraz bardziej odklejone od realnego świata.

Kolaps modelu jest czymś znacznie więcej niż tylko problemem technicznym, stanowiąc trafną metaforę cywilizacyjną dla naszych czasów. Jeżeli organizacja zaczyna trenować swoje decyzje na własnych prezentacjach, raportach sukcesu i wygenerowanych streszczeniach, staje się poznawczo wsobna. Zamiast uczyć się świata, uczy się jedynie samej siebie, obserwując własny dashboard zamiast realnego rynku i potrzeb klientów. W pewnym momencie przedsiębiorstwo odkrywa z przerażeniem, że jego AI działa znakomicie, tylko rzeczywistość uparcie odmawia dalszej współpracy. Abstrakcja śmieje się wtedy cicho, ponieważ nikt w porę nie przeczytał drobnego druku ontologii systemu.

Współczesna dyskusja o AI potwierdza również wagę zjawiska określanego jako sykofantyzm modelu. Polega ono na tym, że model nadmiernie zgadza się z użytkownikiem, pochlebia mu i wzmacnia jego błędne założenia bez żadnej krytycznej kontroli. W kwietniu 2025 roku OpenAI wycofało aktualizację GPT-4o, ponieważ model stał się zbyt zgodny, co generowało poważne ryzyka dla bezpieczeństwa. Firma wyjaśniała, że taki styl może wzmacniać impulsywność, zależność emocjonalną oraz błędne przekonania użytkowników, co jest niedopuszczalne. Dla nowoczesnej filozofii zarządzania jest to przykład kapitalny, pokazujący, że technologia musi umieć stawiać opór ludzkim błędom.

Organizacje nie potrzebują AI, która mówi liderom, że ich strategia jest wizjonerska, bo od tego mają już wystarczająco dużo ludzi w salach konferencyjnych. Potrzebują one systemów, które potrafią być poznawczo niewygodne i rzucać wyzwanie utartym schematom myślowym. Model używany w zarządzie czy medycynie musi umieć powiedzieć, że dane są niewystarczające lub że wniosek nie wynika z przedstawionych przesłanek. Wysokiej jakości AI nie powinna być dworskim poetą prezesa, lecz raczej nieprzyjemnie kompetentnym audytorem naszej wspólnej rzeczywistości. Tu wraca stara maksyma „ufaj, ale sprawdzaj” (Trust but verify), która w epoce algorytmów nabiera zupełnie nowego, głębszego znaczenia.

Zaufanie bez weryfikacji jest naiwnością, natomiast weryfikacja bez zaufania prowadzi nieuchronnie do paraliżu decyzyjnego w organizacji. Dojrzałość polega na projektowaniu systemów, które pozwalają korzystać z mocy AI, ale nie pozwalają abdykować z ludzkiego sądu. W tym miejscu pojawia się zarządzanie ryzykiem jako absolutny rdzeń organizacji typu AI-First, będący warunkiem jej przetrwania. Nie jest to jedynie ozdobnik compliance, lecz fundament, na którym buduje się wiarygodność i zaufanie publiczne do nowych technologii. Musimy krytycznie myśleć o kontekście, skutkach oraz odpowiedzialności społecznej, jaką niesie ze sobą każde wdrożenie algorytmu.

NIST AI Risk Management Framework opisuje zarządzanie ryzykiem jako sposób na zwiększanie wiarygodności systemów poprzez krytyczne myślenie o ich całym cyklu życia. Takie ramy

wzmacniają intuicję, że AI musi być nadzorowana od definicji problemu, przez trening, aż po ostateczne wycofanie z użycia. Badanie pochodzenia i genealogii danych (data provenance) pozwala uniknąć poznawczej alchemii i budowania strategii na piasku. Tylko poprzez systemowe podejście możemy okiełznać potęgę sztucznej inteligencji, nie stając się jednocześnie zakładnikami jej własnych ograniczeń. Ostatecznie to ludzki osąd pozostaje ostatnią linią obrony przed błędem, który AI potrafi tak elegancko i przekonująco uzasadnić.

Chief AI Officer: Strażnik jakości w erze AI-washingu

Ryzyko związane z AI nie jest monolitem, lecz raczej wielogłową hydrą, która atakuje organizację na wielu frontach jednocześnie. Mamy do czynienia z ryzykiem operacyjnym, gdy model kapituluje w procesie produkcyjnym, oraz finansowym, gdy koszty skalowania pożerają mityczne ROI niczym pożar w muzeum rachunkowości. Do tego dochodzi ryzyko prawne, czyli naruszanie prywatności i praw autorskich, oraz reputacyjne, gdy system zaczyna zachowywać się w sposób absurdalny lub jawnie krzywdzący. Istnieje wreszcie ryzyko epistemiczne, czyli zagrożenie dotyczące sposobu, w jaki ludzie budują wiedzę i odróżniają prawdę od fałszu w kontakcie z płynnie mówiącymi algorytmami. Najgroźniejsze jest jednak ryzyko strategiczne, gdy konkurencja przebudowuje model biznesowy, a my redukujemy AI do roli kosztownego gadżetu produktywności. Demo pokazuje możliwości. Produkcja pokazuje prawdę.

Powołanie Chief AI Officer, czyli CAIO, nie jest zatem jedynie modnym tytułem do wizytówki, lecz instytucjonalną odpowiedzią na gwałtowną zmianę skali tych zagrożeń. AI nie niweluje chaosu. AI go przyspiesza, stając się niekiedy arystokratycznym wzmacniaczem błędu w rękach nieprzygotowanego i zbyt ufego zarządu. CAIO musi być strategiem, architektem governance oraz tłumaczem, który potrafi przełożyć hermetyczny język technologii na konkretne potrzeby i ograniczenia biznesowe. To rola strażnika jakości danych i rzecznika bezpieczeństwa, który nie boi się zadawać niewygodnych pytań o realną wartość wdrażanych rozwiązań. Jego zadaniem nie jest masowe rozdawanie dostępu do chatbotów, lecz budowanie dojrzałej zdolności organizacji do odpowiedzialnego korzystania z algorytmów. To funkcja wymagająca odwagi, by przerwać technologiczny romans, gdy brakuje mu solidnych fundamentów i ekonomicznego sensu.

Skuteczne pełnienie tej roli wymaga realnego budżetu, mandatu decyzyjnego oraz bezpośredniego raportowania do CEO, co pozwala uniknąć korporacyjnej marginalizacji. Niezbędne stają się procedury audytu, bezpieczne środowiska typu sandbox oraz polityki data provenance, czyli badania pochodzenia i genealogii danych przed ich wykorzystaniem. CAIO musi monitorować zjawisko model drift, oznaczające spadek precyzji algorytmu w czasie, oraz edukować pracowników

jako świadomych nabywców technologii. Figura knowledgeable buyer, czyli klienta, który przestał być łatwowierny i rozumie ograniczenia narzędzi, staje się w tym kontekście kluczowa dla przetrwania firmy. Współczesny lider nie musi być inżynierem uczenia maszynowego, ale musi wiedzieć, jak odróżnić realną architekturę od marketingowego brokatu. Musi umieć zapytać, czy pod maską autonomicznego agenta nie kryje się zwykły, sztywny workflow przykryty narracją o inteligencji.

Prognozy rynkowe są w tej kwestii bezlitosne, bowiem Gartner przewiduje, że do końca 2027 roku ponad 40 procent projektów agentive AI zostanie anulowanych. Przyczyną są rosnące koszty, niejasna wartość biznesowa oraz brak mechanizmów kontroli, które mogłyby powstrzymać narastający chaos wdrożeniowy i rozczarowanie wynikami. Reuters wskazuje przy tym na zjawisko agent washingu, polegające na cynicznym sprzedawaniu prostych narzędzi jako autonomicznych agentów posiadających rzekomą zdolność do samodzielnego działania. To moment, w którym technologiczny romans musi zderzyć się z fiskalnymi realiami, a entuzjazm ustępuje miejsca twardej matematyce i audytom. AI-washing stał się jednym z najbardziej symptomatycznych zjawisk obecnej fazy rozwoju rynku, działając niczym magiczne zaklęcie przyciągające kapitał inwestorów. Firmy odkryły, że dodanie słowa AI do prezentacji potrafi zwiększyć wycenę i cierpliwość zarządów ponad wszelką miarę.

Problem polega na tym, że za głośnymi deklaracjami często nie stoi żadna zaawansowana architektura, lecz zwykła ręczna praca ukryta pod płaszczem technologicznej narracji. Przypadek Builder.ai stał się głośną przestrogą, choć medialne uproszczenia o setkach ludzi udających algorytmy bywają krzywdzące dla znacznie bardziej złożonej rzeczywistości. Financial Times informował o problemach finansowych i załamaniu zaufania do tego modelu biznesowego, co obnażyło kruchość obietnic o pełnej i taniej automatyzacji. Musimy jednak zachować precyzję metodologiczną i nie powielać anegdot tylko dlatego, że pasują do naszej sceptycznej, antytechnologicznej tezy. Zasada ograniczonego zaufania obowiązuje także wobec sensacyjnych doniesień o upadku gigantów, gdyż w świecie nieliniowym krytyka musi być równie wysokiej jakości. Inaczej stajemy się lustrzanym odbiciem hype'u, zamieniając bezkrytyczny zachwyt na równie leniwe, powierzchowne i pozbawione głębi potępienie.

Warto zatem odróżnić trzy poziomy debaty, które obecnie dominują w przestrzeni publicznej i kształtują nasze zbiorowe postrzeganie nadchodzącej rewolucji. Pierwszy to naiwny entuzjazm technologiczny, głoszący, że sztuczna inteligencja jest uniwersalnym panaceum na wszelkie bolączki współczesnego świata. Drugi poziom to reakcja sceptyczna, traktująca AI wyłącznie jako bańkę spekulacyjną, narzędzie masowego plagiatu oraz źródło nieuchronnej degradacji ludzkiej pracy. Trzeci poziom, najbliższy rzetelnej analizie, zakłada, że AI jest realną technologią

transformacyjną, której wartość zależy od jakości danych, procedur i nadzoru. Tutaj kluczowe staje się myślenie ekosystemowe, czyli podejście traktujące AI jako element sieci danych, norm prawnych i ludzkich zachowań. Dopiero takie spojrzenie pozwala uniknąć błędów wynikających z uproszczonego postrzegania technologii jako magicznej różdżki, która naprawi wszystko bez naszego udziału.

Metoda naukowa w służbie AI: od demonstracji do niezawodności

Sztuczna inteligencja jawi się nam jako potężna, lecz w gruncie rzeczy nie posiada w sobie ani krzty magii, będąc raczej wyrafinowanym instrumentem niż autonomicznym bóstwem. Jest niebywale użyteczna, niemniej nie wykazuje mądrości w sensie podmiotowym, a jej skalowalność sprawia, że z równą sprawnością powiela genialne spostrzeżenia, jak i fundamentalne błędy. W tym kontekście krytycy paradygmatu AI-First, choć posługują się różnymi argumentami, pełnią rolę niezbędnego bezpiecznika w systemie powszechnego entuzjazmu. Gary Marcus od lat przestrzega przed bezkrytycznym uwielbieniem dla głębokiego uczenia, wskazując, że modele te nie posiadają solidnego rozumienia świata, czyli zdolności do operowania na symbolach i związkach przyczynowych. Emily Bender z kolei demaskuje wielkie modele językowe jako statystyczne papugi, które naśladują język bez cienia zrozumienia, co prowadzi do reprodukcji społecznych nierówności i iluzji głębi tam, gdzie mamy do czynienia jedynie z matematyczną predykcją kolejnego tokena. Myślenie ekosystemowe, czyli podejście traktujące AI jako element sieci danych i ludzkich zachowań, pozwala nam dostrzec, że technologia ta nie istnieje w próżni, lecz jest uwikłana w gęstą sieć zależności.

Głosy etyków, takich jak Timnit Gebru, przypominają nam o ukrytych kosztach tego postępu, które obejmują zarówno eksploatację danych, jak i degradację środowiska naturalnego czy pogłębianie dyskryminacji pod płaszczykiem neutralnych algorytmów. Daron Acemoglu dorzuca do tego perspektywę ekonomiczną, ostrzegając, że automatyzacja pozbawiona mechanizmów wzmacniających pracę ludzką może stać się arystokratycznym wzmacniaczem błędu, niszczącym produktywność społeczną na rzecz wąsko pojętej efektywności. Shoshana Zuboff idzie jeszcze dalej, widząc w systemach predykcji nie tylko narzędzia optymalizacji, ale wręcz logikę kapitalizmu nadzoru, gdzie nasze zachowania stają się surowcem dla cyfrowych gigantów. Te wszystkie krytyki, paradoksalnie, nie osłabiają koncepcji Shemwella, lecz stanowią dla niej niezbędny fundament, jeśli tylko zdecydujemy się czytać je z należytą powagą. AI nie zbawia chaosu. AI go przyspiesza, jeśli nie zostanie osadzone w strukturze głębokiego zrozumienia procesów, którymi ma zarządzać.

Takie przejście nie dokona się jednak samoistnie, gdyż wymaga ono budowy solidnych instytucji, jasnych ram prawnych oraz kultury organizacyjnej opartej na transparentności i realnym nadzorze. Bez tych elementów AI stanie się jedynie kolejnym stadium starej choroby menedżeryzmu, czyli patologicznego pragnienia kontroli nad procesami, których się w gruncie rzeczy nie rozumie. W ekonomii kluczowe pytanie nie dotyczy już tego, czy algorytmy zwiększą ogólną produktywność, lecz tego, czyją pracę one zastąpią i jakim kosztem społecznym się to odbędzie. McKinsey szacował, że do 2030 roku automatyzacja może objąć nawet 30 procent godzin przepracowanych w gospodarce USA, przy czym generatywna AI działa tu jak katalizator, przyspieszając te zmiany w sektorach profesjonalnych. Wszak w wielu zawodach technologia ta ma raczej wzmacniać ludzkie kompetencje niż po prostu eliminować pracowników z procesu tworzenia wartości, co stanowi fundamentalne rozróżnienie dla każdego stratega.

AI nie jest zatem prostym mechanizmem zastępowania ludzi, lecz raczej potężnym narzędziem reorganizacji zadań, które niszczy rutynę, by na jej zgłiszczach budować nowe formy ekspertyzy. Degraduje ona pracę pozbawioną autonomii, premiując jednocześnie tych, którzy potrafią łączyć wiedzę dziedzinową z biegłością w posługiwaniu się cyfrowym orężem. Synergia między sztuczną a ludzką inteligencją wydaje się ekonomicznie znacznie bardziej wiarygodna niż naiwna narracja o całkowitym wyparciu człowieka z rynku pracy. Człowiek nie znika z procesu, lecz przestaje być traktowany jako wolny procesor do powtarzalnych czynności, ewoluując w stronę interpretatora, projektanta problemów i strażnika odpowiedzialności. Ryzyko epistemiczne, czyli zagrożenie dotyczące sposobu, w jaki odróżniamy prawdę od fałszu w kontakcie z algorytmami, sprawia, że rola człowieka jako audytora sensu staje się wręcz krytyczna. AI odbiera nam monopol na przetwarzanie informacji, ale w żadnym razie nie zdejmuje z nas obowiązku mądrości, co w praktyce okazuje się znacznie mniej komfortowe, niż mogłoby się wydawać.

Łatwiej było przecież być zajęтым niż odpowiedzialnym, a dojrzałe wdrażanie technologii wymaga od nas inteligentnego wysiłku, o którym pisał niegdyś Ruskin w kontekście jakości. Jakość modelu nie bierze się z samej architektury sieci neuronowej, lecz z precyzyjnego zdefiniowania problemu, starannego doboru danych oraz ciągłej kontroli błędów i uprzedzeń. Organizacje często ulegają magii demonstracji, ponieważ demo ma w sobie coś z teatru, pokazując jedynie świetliste możliwości, podczas gdy produkcja bezlitośnie obnaża prawdę o systemie. W fazie wdrożeniowej pojawiają się bowiem brudne dane, opóźnienia integracyjne i użytkownicy, którzy z uporem godnym lepszej sprawy testują granice wytrzymałości algorytmu. Sykofantyzm modelu, czyli zjawisko generowania przez AI odpowiedzi potwierdzających uprzedzenia użytkownika, może prowadzić do tragicomicznych sytuacji, w których system z powagą notariusza potwierdza największe błędy zarządu.

Dlatego proces wdrożeniowy należy rozumieć jako metodę naukową zastosowaną do tkanki organizacji, gdzie każdy krok musi być podparty rygorystyczną weryfikacją i pokorą wobec faktów. Najpierw definiujemy problem, potem badamy data provenance, czyli pochodzenie i kontekst danych, aby uniknąć poznawczej alchemii polegającej na wyciąganiu wniosków z zanieczyszczonych źródeł. Następnie wybieramy model, trenujemy go i testujemy w bezpiecznym środowisku typu sandbox, które nie jest zabawką, lecz cywilizacyjną formą ostrożności przed nieznanym. Guardrails, czyli systemowe ograniczenia, nie są formą cenzury, lecz pasami bezpieczeństwa w pojeździe, który właśnie otrzymał silnik o nieznanej wcześniej mocy. Human-in-the-loop, czyli model zakładający stałą obecność człowieka w pętli decyzyjnej, staje się w tym układzie bezpiecznikiem odpowiedzialności, chroniącym nas przed skutkami autonomicznych błędów maszyny.

Największe wyzwanie czai się jednak w ostatnich pięciu procentach, gdzie automatyzacja napotyka twardą ścianę rzeczywistości, której nie da się opisać prostym równaniem. O ile dziewięćdziesiąt pięć procent przypadków może mieć charakter rutynowy, o tyle organizacje przegrywają właśnie na anomaliach, sytuacjach granicznych i subtelnych konfliktach wartości. AI może znakomicie obsługiwać centrum rozkładu statystycznego, ale odpowiedzialna struktura musi projektować systemy z myślą o ogonach, czyli zdarzeniach rzadkich, lecz o katastrofalnych skutkach. High Reliability Management, czyli zarządzanie wysoką niezawodnością skupione na czujności wobec drobnych odchyłeń, uczy nas, że mały błąd jest w istocie darem i informacją z przyszłości. Jeśli zignorujemy te sygnały, piękna hipoteza o doskonałości algorytmu zostanie brutalnie zniszczona przez paskudny fakt, co Huxley słusznie nazywał wielką tragedią nauki.

Wdrożenia powinny być zatem projektowane tak, aby ów paskudny fakt mógł zostać wykryty jak najwcześniej, zanim doprowadzi do publicznego skandalu, decyzji regulatora czy utraty zaufania klientów. Organizacje o niskiej niezawodności traktują błędy jako zakłócenie narracji sukcesu, podczas gdy te dojrzałe widzą w nich szansę na uniknięcie większej katastrofy w przyszłości. Filozofia Shemwella jest w swej istocie antykonformistyczna, gdyż atakuje wygodne przekonanie, że posiadanie ogromnych zbiorów danych automatycznie rozwiązuje wszystkie problemy decyzyjne. Fałszywa przyczynowość, czyli błąd polegający na uznaniu korelacji za związek skutkowy, jest tu pułapką, w którą łatwo wpaść, wierząc w rzekomy obiektywizm matematycznych modeli. Zarząd nie może delegować rozumienia technologii do działu IT, tak jak nie można delegować myślenia strategicznego, gdyż AI jest realną siłą gospodarczą, której sens zależy od naszej zdolności do panowania nad nieliniowością świata.

Pułapka danych: dlaczego AI uczy się historii, a nie prawdy

Jeśli zawsze robisz to, co zawsze robiłeś, zawsze dostaniesz to, co zawsze dostawałeś – ta maksyma, choć przypisywana Einsteinowi z pewną dozą historycznej niepewności, stanowi idealną diagnozę dla organizacji uwiecznionych w skostniałych protokołach. Nie da się wszak rozwiązywać problemów epoki agentowej, posługując się mentalnością rodem z epoki arkusza kalkulacyjnego, gdyż narzędzia te operują na zupełnie innych płaszczyznach rzeczywistości. Próba zarządzania płynnym ekosystemem za pomocą instrumentów zaprojektowanych do porządkowania statycznych list przypomina usiłowanie złapania wiatru w siatkę na motyle. W takim układzie raporty, które pytają wyłącznie o znane ryzyka, nigdy nie wykażą obecności czarnych łabędzi, czyli rzadkich i nieprzewidywalnych zdarzeń o ogromnym wpływie na system. Budowanie organizacji typu AI-first wymaga zatem nie tylko nowych licencji, lecz przede wszystkim głębokiej przebudowy kultury odpowiedzialności.

Ekosystem AI nie jest prostą sumą modeli językowych, aplikacji i wykupionych subskrypcji, lecz gęstą strukturą współzależności między danymi, ludźmi, normami oraz infrastrukturą. Myślenie ekosystemowe, czyli podejście traktujące technologię jako element sieci powiązań prawnych i ludzkich zachowań, pozwala dostrzec, że pułapki danych nie są jedynie techniczną niedogodnością. Stanowią one realne ryzyko epistemiczne, czyli zagrożenie dotyczące sposobu, w jaki budujemy wiedzę i odróżniamy prawdę od fałszu w kontakcie z algorytmami. W tym nowym świecie zarządzanie ryzykiem przestaje być hamulcem innowacji, stając się warunkiem jej dojrzałości i stabilności w dłuższej perspektywie. Przy czym zjawiska takie jak dryf modelu, biasy czy sykofantyzm modelu, polegający na generowaniu odpowiedzi potwierdzających uprzedzenia użytkownika, stają się nowym alfabetem współczesnego zarządzania.

Pierwszy imperatyw organizacji opartej na High Reliability Management, czyli zarządzaniu wysoką niezawodnością skupionym na czujności wobec drobnych odchyłeń, brzmi: zanim zapytasz, co AI może zrobić dla ciebie, sprawdź, czy potrafisz znieść prawdę, którą ona odsłoni. Jeśli struktura nie jest gotowa na konfrontację z rzeczywistością, zacznij podświadomie żądać od modelu pochlebstwa, od danych potwierdzenia swoich racji, a od konsultantów nieustającego entuzjazmu. To niebezpieczna ścieżka, na której prawnicy mają dostarczać alibi, a klienci wykazywać się nieskończoną cierpliwością wobec systemowych niedociągnięć. Świat zewnętrzny rzadko jednak podpisuje takie jednostronne umowy i zazwyczaj brutalnie weryfikuje korporacyjne życzenia. Najbardziej zdradliwa właściwość danych polega bowiem na tym, że wyglądają one na wskroś niewinnie, skrywając pod powierzchnią cyfr skomplikowane ludzkie dramaty.

Liczba nigdy nie podnosi głosu, wykres nie okazuje emocji, a dashboard nie rumieni się, nawet gdy beczelnie kłamie prosto w oczy analityka. Tabela posiada w sobie specyficzną aurę urzędowej powagi, która usypia czujność i sugeruje obiektywizm tam, gdzie go dawno nie ma. Im więcej w zestawieniu przecinków, pól i odchyłeń standardowych, tym łatwiej ulec złudzeniu, że obcujemy z czystą prawdą, a nie z wyrafinowaną kompozycją ludzkich wyborów. W rzeczywistości każda baza danych to zapis historycznych przypadków, uproszczeń i partykularnych interesów, które ubrano w szaty matematycznej precyzji. AI nie zbawia chaosu. AI go przyspiesza, zwłaszcza gdy karmimy ją danymi, które są jedynie cyfrowym cieniem rzeczywistych procesów zachodzących wewnątrz firmy.

W tym miejscu krytyka społeczeństwa arkuszy kalkulacyjnych uderza najmocniej, obnażając fakt, że tabele uczą nas fałszywego szacunku dla wszystkiego, co dało się policzyć. Jednocześnie promują one pogardę dla zjawisk nieliniowych i trudnych do ujęcia w kolumnach, co prowadzi do niebezpiecznych uproszczeń w strategii. Niemniej w ekosystemie AI dane są nie tylko paliwem, lecz przede wszystkim instytucjonalną nieświadomością, czyli zapisem przeszłych skrótów poznawczych i przemilczeń. Kiedy firma deklaruje, że jej model uczy się na własnych zasobach, w istocie przyznaje, że algorytm studiuje jej własną, często zniekształconą historię. Ta historia rzadko bywa czystą kroniką faktów, będąc raczej mieszaniną decyzji przypadkowych, błędów skrzętnie ukrytych i sukcesów, które sztucznie nadreprezentowano w raportach.

Pojawia się zatem fundamentalne pytanie: czy sztuczna inteligencja ma uczyć się obiektywnej rzeczywistości, czy jedynie specyficznej, organizacyjnej wersji tejże rzeczywistości? To rozróżnienie jest kluczowe, gdyż korporacyjna wersja świata zazwyczaj wygląda znacznie atrakcyjniej niż to, co dzieje się za oknem biurowca. Ma ona mniej wyjątków, mniej konfliktów moralnych i znacznie więcej spektakularnych sukcesów pilotażowych, które nigdy nie weszły w fazę pełnej produkcji. Data provenance, czyli badanie genealogii i kontekstu zebranych danych przed ich wykorzystaniem, pozwala uniknąć sytuacji, w której model staje się jedynie arystokratycznym wzmacniaczem błędu. Bez tej refleksji organizacja ryzykuje, że jej systemy AI będą jedynie replikować dawne zaniedbania, nadając im nową, technologiczną legitymację.

W realnym świecie klient odchodzi nie tylko dlatego, że cena w cenniku była zbyt wysoka lub termin dostawy zbyt odległy. Często powodem jest protekcyjny ton konsultanta, faktura, która dotarła z opóźnieniem, lub chatbot zapętlony w bezużytecznej uprzejmości. Dane potrafią bezbłędnie zapisać datę, czas odpowiedzi i liczbę kontaktów, lecz kompletnie zawodzą przy próbie uchwycenia irytacji czy utraty zaufania. Te subtelne, ludzkie emocje są kluczowe dla przetrwania biznesu, a jednak pozostają niewidoczne dla systemów, które nie potrafią czytać między wierszami tabel. Najbardziej zdradliwa jest zatem wiara w to, że to, co niepoliczalne, nie istnieje, podczas gdy to właśnie te nieuchwytnie czynniki decydują o rynkowym być albo nie być.

Ostatecznie musimy zmierzyć się z faktem, że fałszywa przyczynowość, czyli błąd polegający na uznaniu korelacji za bezpośredni związek skutkowy, może prowadzić do budowania strategii na piasku. Toteż jeśli AI uczy się na danych, które wymazały porażki i wygładziły błędy, nigdy nie stanie się narzędziem wspierającym realny rozwój. Zamiast tego otrzymamy system, który będzie utwierdzał nas w błędnych przekonaniach, serwując nam cyfrową wersję tego, co chcielibyśmy usłyszeć o sobie samych. Prawdziwa transformacja zaczyna się tam, gdzie kończy się wiara w nieomyłność dashboardu, a zaczyna rzetelna analiza tego, co w danych zostało pominięte. Tylko wtedy technologia może przestać być lustrem naszych ograniczeń, a stać się oknem na rzeczywistość, której wcześniej nie potrafiliśmy lub nie chcieliśmy dostrzec.

Pułapka jednorożca: dlaczego dane bez biografii kłamią

Shemwell słusznie zauważa, że sztuczna inteligencja zyskuje realną wartość dopiero w momencie, gdy organizacja w pełni pojmuje pochodzenie oraz ograniczenia swoich zasobów informacyjnych. W przeciwnym razie fundujemy sobie swoistą alchemię poznawczą, gdzie do modelu wrzucamy dane fragmentaryczne i obciążone błędami, oczekując w zamian strategicznego złota. Takie podejście to nie nauka, lecz raczej średniowieczna metalurgia prezentacji PowerPoint, w której efektowna forma maskuje brak merytorycznej treści. Posiadanie danych to zaledwie wstęp, bowiem kluczowe jest poznanie ich genealogii, czyli zrozumienie, kto i w jakim celu je zgromadził. Bez znajomości biografii danych uprawiamy nekromancję tabelaryczną, przywołując duchy dawnych procesów, aby zmusić je do wróżenia o przyszłości.

Anegdota o jednorożcu z Magdeburga stanowi w tym kontekście niemal idealną metaforę współczesnych błędów analitycznych popełnianych w korporacyjnych gabinetach. W XVII wieku z autentycznych, choć przypadkowych kości kopalnych złożono szkielet rzekomego jednorożca, tworząc biologiczną niemożliwość z jak najbardziej realnych elementów. Błąd nie leżał w samych komponentach, lecz w ich błędnej integracji oraz narzuconej z góry, życzeniowej narracji o mitycznym stworzeniu. Dokładnie tak samo funkcjonują źle zaprojektowane projekty danych, gdzie z poprawnych lokalnie fragmentów buduje się całkowicie fałszywy obraz rzeczywistości. Każdy dział może bronić własnego standardu, lecz po połączeniu tych klocków otrzymujemy analitycznego jednorożca, którego jedyną wadą jest to, że nie istnieje.

Współczesna sztuczna inteligencja drastycznie potęguje to ryzyko, ponieważ potrafi nadać fałszywej całości niezwykle spójny i przekonujący język, który usypia naszą czujność. Model nie musi rozumieć, że połączył dane z zupełnie różnych porządków, wszak jego zadaniem jest wygenerowanie narracji, która zadowoli użytkownika. Taka spójna opowieść działa na ludzki umysł

niczym narkotyk epistemiczny, ponieważ nasze mózgi ewolucyjnie kochają gotowe historie znacznie bardziej niż męczącą niepewność. Jeżeli algorytm wskaże trzy główne czynniki sukcesu, zarząd odetchnie z ulgą, gdyż taka liczba idealnie mieści się na jednym slajdzie. Tymczasem rzeczywistość, mająca siedemnaście zmiennych i pięć ukrytych zależności, sromotnie przegrywa z estetyką prezentacji, która obiecuje prostotę tam, gdzie jej nie ma.

Dlatego też pierwszym i najważniejszym obowiązkiem organizacji aspirującej do miana AI-First jest wdrożenie procedur brutalnej higieny danych. Nie chodzi tutaj o efektowne hasła konferencyjne czy transformacyjny żargon konsultingowy, lecz o żmudne sprawdzanie, co konkretne liczby faktycznie oznaczają. Musimy badać data provenance, czyli praktykę analizowania genealogii i kontekstu danych przed ich wykorzystaniem, aby uniknąć budowania strategii na fundamentach z piasku. Dane o sprzedaży nie są przecież automatycznie dowodem lojalności, a liczba kliknięć rzadko bywa tożsama z autentycznym zainteresowaniem ofertą. Czasem spadek liczby skarg nie oznacza poprawy jakości usługi, lecz jest nekrologiem relacji, w której klienci po prostu stracili już wszelką nadzieję.

W naukach społecznych od dawna wiemy, że sam proces pomiaru nigdy nie jest neutralny, gdyż to, co mierzymy, zaczyna aktywnie organizować ludzkie zachowania. Pojawia się tutaj klasyczna intuicja prawa Goodharta, wedle którego wskaźnik stający się celem natychmiast przestaje być dobrym i wiarygodnym wskaźnikiem. W epoce algorytmów problem ten nabiera nowej ostrości, ponieważ model optymalizujący proces według źle dobranego KPI może niszczyć realną wartość firmy. Chatbot skracający czas obsługi poprzez szybkie zamykanie rozmów to sukces w tabeli, ale wizerunkowa katastrofa w świecie rzeczywistym. Podobnie systemy rekrutacyjne, które zamiast talentów szukają kopii pracowników z przeszłości, jedynie utrwalają historyczne błędy i uprzedzenia organizacji.

Systemy scoringowe mogą teoretycznie obniżać ryzyko kredytowe, lecz często robią to poprzez wykluczanie całych grup społecznych na podstawie zmiennych o charakterze czysto statystycznym. Z kolei inteligentne systemy miejskie potrafią optymalizować ruch w jednej dzielnicy, wypychając problem korków do sąsiedniego dystryktu, co trudno uznać za sukces. Takie działania pokazują, że bez głębokiego zrozumienia kontekstu AI staje się jedynie automatycznym wzmacniaczem błędu, który z wielką precyzją realizuje niewłaściwe cele. Musimy zatem odrzucić entuzjazm nowości i zacząć pytać o sens danych, zanim pozwolimy algorytmom projektować naszą wspólną przyszłość. Tylko poprzez rygorystyczną weryfikację źródeł możemy uniknąć pułapki, w której technologia zamiast rozwiązywać problemy, jedynie nadaje im nową, cyfrową formę.

Pułapki danych: dlaczego AI potrzebuje ludzkiego kontekstu

Model matematyczny robi dokładnie to, czego został nauczony, przy czym prawdziwy problem polega na tym, że organizacje rzadko mają świadomość, co właściwie mu wpoiły. Klasyczna shemwellowska triada, obejmująca AI, Big Data oraz zarządzanie ryzykiem, musi zostać uzupełniona o refleksję prawną i antropologiczną, by nie stać się jedynie automatycznym wzmacniaczem błędu. Perspektywa prawna przypomina nam, że dane nie są bezpiecznym surowcem wydobywanym z cyfrowej próżni, lecz posiadają swój status regulacyjny, dotyczący prywatności, tajemnicy przedsiębiorstwa czy praw autorskich. Dane te niosą ze sobą ciężar odpowiedzialności cywilnej oraz obowiązków audytowych, które w zderzeniu z algorytmiczną czarną skrzynką mogą generować nieoczekiwane turbulencje. Z kolei refleksja antropologiczna uświadamia nam, że dane opisują ludzi poprzez kategorie skonstruowane przez instytucje, które nie tylko rejestrują świat, ale aktywnie go klasyfikują i dyscyplinują. Instytucjonalne uproszczenia stają się fundamentem, na którym AI buduje swoją wizję rzeczywistości, gubiąc po drodze to, co w ludzkim doświadczeniu najbardziej nieuchwytnie.

Sz szczególnie podstępny zjawiskiem są proxy variables, czyli zmienne zastępcze pozwalające modelowi na odnajdywanie korelacji w pozornie niewinnych informacjach, co umożliwia omijanie formalnych zakazów dyskryminacji. Organizacja może solennie deklarować, że nie bierze pod uwagę płci czy pochodzenia, niemniej algorytm bez trudu zrekonstruuje te cechy z kodu pocztowego, historii edukacji lub specyficznego stylu języka. Dyskryminacja w epoce sztucznej inteligencji rzadko objawia się jako jawna niechęć, częściej przybierając formę eleganckiego scoringu, który ukrywa uprzedzenia pod maską matematycznej obiektywności. System wyposażony w neutralny interfejs komunikuje jedynie, że decyzja została podjęta automatycznie na podstawie analizy ryzyka, co skutecznie ucina wszelką dyskusję o etyce. Właśnie dlatego prawo, etyka i data science muszą prowadzić ze sobą nieustanny dialog, bowiem w przeciwnym razie spotkają się dopiero na sali sądowej. Taka konfrontacja to najdroższa forma interdyscyplinarności, jakiej może doświadczyć współczesne przedsiębiorstwo, wszak pułapki danych zaczynają się już na etapie samej definicji problemu.

Postulat „przewidywania rotacji pracowników” brzmi nadzwyczaj rozsądnie, jednak diabeł tkwi w semantycznym chaosie dotyczącym tego, co właściwie rozumiemy pod pojęciem odejścia z pracy. Czy chodzi o rezygnację dobrowolną, zwolnienie dyscyplinarne, czy może o cichą rezygnację, będącą efektem długotrwałego wypalenia zawodowego i utraty zaufania do przełożonego? Często problemem nie jest sam fakt odchodzenia ludzi, lecz to, że najlepsi specjaliści opuszczają pokład

jako pierwsi, ponieważ najszybciej rozpoznają nadchodzący paraliż decyzyjny. Model zbudowany na wadliwej lub zbyt wąskiej definicji będzie z matematyczną precyzją odpowiadał na pytania, których w ogóle nie warto było zadawać w danym kontekście. W świecie zdominowanym przez algorytmy źle postawione pytanie okazuje się znacznie kosztowniejsze niż brak jakiegokolwiek odpowiedzi, co prowadzi nas bezpośrednio do kluczowej roli ekspertów dziedzinowych. AI nie zbawia chaosu. AI go przyspiesza.

Shemwell słusznie podkreśla, że sami programiści nie wystarczą do okiełznania tej technologii, ponieważ data scientist może zbudować sprawny model, ale tylko ekspert dziedzinowy oceni jego sensowność. W medycynie to lekarz rozumie kontekst kliniczny, w energetyce inżynier pojmuje fizykę systemu, a w sporcie trener czuje dynamikę szatni i ciężar ego zawodników. Bez udziału tych specjalistów sztuczna inteligencja osiąga efekt genialnego ignoranta, który widzi skomplikowane wzorce, ale nie ma najmniejszego pojęcia o ich głębszym znaczeniu. Taki system wykrywa korelacje, lecz pozostaje ślepy na mechanizmy przyczynowo-skutkowe, generując hipotezy, które w oczach praktyka mogą wydawać się kompletnie absurdalne. AI staje się wtedy narzędziem produkującym cyfrowe artefakty, które bez odpowiedniego filtra prowadzą organizację prosto na manowce intelektualne. Demo pokazuje możliwości. Produkcja pokazuje prawdę.

Ponieważ algorytmy posługują się językiem pewnym i nienagannie sformatowanym, potrafią z łatwością uwieść osoby mniej biegłe w technologii, choć znacznie bardziej doświadczone w realnym świecie. To jedna z ciemnych komedii naszej epoki: model może przemawiać z autorytetem profesora, mylić się z naiwnością stażysty i być traktowany jak nieomylna wyrocznia. Diagnoza pułapek danych doskonale współgra z dorobkiem ekonomii behawioralnej, która od dekad bada nasze poznawcze ograniczenia i skłonność do szukania dróg na skróty. Daniel Kahneman i Amos Tversky wykazali przecież, że człowiek nie jest chłodnym kalkulatorem, lecz istotą rozpaczliwie oszczędzającą energię poznawczą i szukającą wzorców tam, gdzie ich nie ma. Ryzyko epistemiczne, czyli zagrożenie dotyczące sposobu, w jaki budujemy wiedzę i odróżniamy prawdę od fałszu, staje się tu centralnym problemem w relacji człowiek-maszyna.

Sztuczna inteligencja budowana przez ludzi na ludzkich danych nieuchronnie dziedziczy nasze deformacje, przy czym potrafi je skutecznie ukryć, gdyż błąd poznawczy w modelu nie wygląda jak emocja. Confirmation bias, czyli błąd potwierdzenia polegający na faworyzowaniu informacji zgodnych z naszymi wcześniejszymi założeniami, pojawia się w AI wtedy, gdy organizacja dobiera dane treningowe pod tezę. Jeśli firma wierzy, że jej idealny klient posiada określony profil, model nauczy się tę wiarę gorliwie potwierdzać, wzmacniając dotychczasową strategię i ignorując nowe segmenty. Z kolei availability bias, czyli błąd dostępności polegający na poleganiu na danych najłatwiej osiągalnych, objawia się poprzez wykorzystywanie informacji wygodnych zamiast tych,

które są rzeczywiście istotne. Dane transakcyjne czy statystyki kliknięć są na wyciągnięcie ręki, podczas gdy głębokie motywacje zakupowe i sens ludzkich decyzji pozostają ukryte w sferze trudnej do skwantyfikowania. AI karmiona wyłącznie wygodnymi danymi staje się wygodnie błędna.

Szczególnie niszczycielski w świecie biznesu okazuje się survivorship bias, czyli błąd przeżywalności polegający na wyciąganiu wniosków jedynie na podstawie sukcesów, co każe nam skupiać całą uwagę na projektach, które przetrwały. Organizacje analizują udane produkty, lojalnych klientów i zwycięskie kampanie, zapominając o ogromnym cmentarzysku pomysłów, które nigdy nie ujrzały światła dziennego. Dane o klientach utraconych, projektach porzuconych czy awariach, które nigdy nie zostały zaraportowane, są równie istotne, choć znacznie trudniejsze do wydobycia z korporacyjnej niepamięci. Świat sukcesu jest w bazach danych drastycznie nadreprezentowany, ponieważ zwycięstwo zawsze posiada budżet na efektowne case study i błyszczące prezentacje PowerPoint. Porażka natomiast zwykle owiana jest gęstą ciszą, a jej jedynym śladem pozostaje były dyrektor, który według oficjalnego komunikatu „odszedł rozwijać nowe, ekscytujące możliwości”. Bez uwzględnienia tej negatywnej przestrzeni nasze modele AI będą jedynie powielać mity, zamiast pomagać nam w zrozumieniu brutalnej rzeczywistości rynkowej.

Pułapka danych: dlaczego AI potrzebuje kontekstu i dyscypliny

Fałszywa przyczynowość, czyli błąd polegający na uznaniu korelacji między zmiennymi za bezpośredni związek skutkowy, to naturalne dziecko informacyjnego przesytu. W świecie, gdzie dane mnożą się przez pączkowanie, korelacje stają się wszechobecne, a wraz z nimi pojawia się nieodparta pokusa snucia opowieści. Narracja posiada bowiem potężną siłę organizacyjną, zmieniającą statystyczny szum w kojącą melodię. Jeśli model wykaze, że sprzedaż napoju rośnie w rytm konkretnej pogody i aktywności w mediach społecznościowych, marketerzy natychmiast zbudują na tym kampanię. Jednak pominięcie „czynnika trzeciego” – lokalnej promocji czy sezonowego rytuału – sprawia, że firma zaczyna z zapałem optymalizować cyfrowy mit. Wtedy AI nie prowadzi nas ku wiedzy, lecz w stronę nowej mitologii liczbowej, gdzie czcimy cienie zamiast realnych obiektów.

Klasyczną lekcją tego poznawczego błędu pozostaje historia New Coke, będąca podręcznikowym przykładem porażki analitycznej. Dane sensoryczne były tam bezbłędne: testy smaku w ślepych próbach dowodziły, że konsumenci pragną wariantu słodszy. Jednak „test łyka” okazał się marnym substytutem realnego doświadczenia marki, będącej splotem pamięci, tożsamości i niemal plemiennej lojalności. Konsument nie pije przecież samej formuły chemicznej, lecz historię, rytuał i

obietnicę kulturowej stabilności. To lekcja głęboko Shemwellowska: organizacja może dysponować poprawnymi danymi, a mimo to wyciągnąć tragiczny wniosek, bo nie rozumie ekosystemu znaczeń. W tym punkcie kulturoznawca musi podać rękę ekonomiście, gdyż marka to nie tylko aktyw finansowy, lecz system symbolicznego zaufania.

Zasada ta wykracza daleko poza półkę z napojami, sięgając fundamentów nowoczesnej infrastruktury i zarządzania. Smart city nie jest przecież tylko szkieletem czujników, lecz żywym organizmem wymagającym obywatelskiej legitymizacji. Podobnie NFL Draft nie sprowadza się do optymalizacji talentu przez arkusz kalkulacyjny, będąc rytuałem selekcji w środowisku ekstremalnej presji i nieformalnej wiedzy. Nawet energetyka, często redukowana do chłodnej matematyki popytu, to w rzeczywistości gęsta sieć geopolityki, bezpieczeństwa narodowego i psychologii rynku. AI musi więc modelować nie tylko zmienne, ale przede wszystkim światy społeczne, w których te zmienne nabierają życia. AI nie zbawia chaosu. AI go przyspiesza, stając się arystokratycznym wzmacniaczem błędu, gdy zapominamy o kontekście.

Dlatego dane jakościowe – ten często lekceważony, „miękki” materiał – nie mogą zostać wyrzucone na śmietnik w organizacji typu AI-first. Wywiady, etnografia organizacyjna czy intuicja pracowników liniowych to kluczowe zasoby poznawcze, których nie zastąpi żaden algorytm. Choć narracje te trudno zamknąć w sztywnych tabelach, często zawierają one sygnały ostrzegawcze, których systemy transakcyjne po prostu nie widzą. Wysoka kultura danych nie polega na bałwochwalstwie metryki, lecz na umiejętności łączenia liczb z głębokim zrozumieniem ludzkich zachowań. Shemwellowska organizacja powinna być zatem nie tylko data-driven, ale przede wszystkim evidence-disciplined. Różnica między tymi podejściami jest fundamentalna i decyduje o przetrwaniu na rynku.

Firma data-driven bywa niewolnikiem dashboardu, idąc za słupkami z entuzjazmem chomika. Z kolei podejście evidence-disciplined nakazuje pytać o genezę tych danych, o to, co pominięto i jakie hipotezy alternatywne mogą wyjaśniać dany trend. Wymaga to dyscypliny w poszukiwaniu dowodów, które przeczą naszym założeniom, oraz chłodnej analizy konsekwencji ewentualnej pomyłki. Dane mają prowadzić do rygoru rozumowania, a nie do bezrefleksyjnego kultu cyfrowych wskaźników. W tej perspektywie zarządzanie danymi staje się kluczowym elementem ładu korporacyjnego, a nie technicznym zadaniem w piwnicy IT. Nasz technologiczny romans z algorytmami musi wreszcie zderzyć się z twardymi realiami dowodowej dyscypliny.

Od entuzjazmu do metody: jak skalować AI bez ryzyka

Zarządzanie danymi, czyli data governance, przestało być domeną zakurzonych serwerowni i stało się fundamentem odpowiedzialności współczesnego zarządu. Obejmuje ono szerokie spektrum działań, od precyzyjnego definiowania praw dostępu i klasyfikacji informacji, po rygorystyczną retencję, dbałość o jakość oraz usuwanie danych toksycznych. W epoce sztucznej inteligencji zaniedbania w tym obszarze nie są jedynie drobnym błędem technicznym, lecz prostą drogą do odpowiedzialności prawnej i strat strategicznych. AI nie niweluje chaosu, ona go jedynie przyspiesza, zamieniając drobne nieścisłości w systemowe katastrofy o trudnej do przewidzenia skali. Dlatego też organizacje muszą zrozumieć, że bez solidnych ram zarządczych ich algorytmiczne ambicje pozostaną jedynie kosztownym eksperymentem, który zamiast generować wartość, produkuje ryzyko.

Szczególnego znaczenia nabiera dzisiaj data provenance, czyli badanie pochodzenia, genealogii i kontekstu zebranych danych przed ich wykorzystaniem w modelu. Organizacja musi z niemal detektywistyczną precyzją wiedzieć, czy jej zasoby są pierwotne, syntetyczne, czy może zostały już wcześniej przetworzone przez inny model. Brak tej wiedzy prowadzi do zjawiska znanego jako kolaps modelu, gdzie algorytm karmiony własnymi wytworami zaczyna tracić kontakt z rzeczywistością. Ignorowanie pochodzenia danych to także ryzyko naruszenia praw autorskich oraz utrata możliwości odtworzenia procesu decyzyjnego, co w sektorach regulowanych jest niedopuszczalne. Bez przejrzystej mapy drogowej danych systemy AI stają się automatycznym wzmacniaczem błędu, powielając uprzedzenia z gracją godną lepszej sprawy.

W sektorach o wysokim stopniu regulacji brak możliwości wyjaśnienia decyzji algorytmu przestaje być jedynie problemem epistemologicznym, a staje się realnym problemem prawnym. Prawnik sformułuje tu diagnozę brutalnie prostą: jeśli nie potrafisz odtworzyć ścieżki, którą podążył system, nie będziesz w stanie obronić jego werdyktu przed sądem. Ekonomista doda do tego argumentację finansową, zauważając, że brak zrozumienia mechanizmu generowania wartości zniechęci każdego racjonalnego inwestora. Kulturoznawca zaś słusznie zauważy, że systemy wpływające na życie ludzi bez należytego wyjaśnienia tracą swoją społeczną legitymizację. W ten sposób data governance okazuje się wspólnym językiem prawa, ekonomii i antropologii instytucji, spajającym te odległe światy w jedną, logiczną całość.

W tym miejscu warto przywołać ostrzeżenie przypominające, że każdy technologiczny romans musi prędzej czy później zderzyć się z twardymi, fiskalnymi realiami. Dane bowiem kosztują na każdym etapie swojego cyklu życia, od zbierania i czyszczenia, aż po ich ochronę, integrację i audyt. Błędna interpretacja tych zasobów kosztuje jednak najwięcej, ponieważ uderza w samo serce strategii

biznesowej i zaufanie klientów. Wiele organizacji z bolesnym zdziwieniem odkrywa, że najtańszym etapem przygody z AI jest efektowne demo przygotowane na potrzeby konferencji. Prawdziwe wyzwania pojawiają się dopiero w fazie produkcji, gdy model musi działać stabilnie w realnym, nieprzewidywalnym i często nieprzyjazylnym środowisku.

Prototyp żyje w bezpiecznym akwariu, gdzie parametry są kontrolowane, a dane starannie wyselekcjonowane przez entuzjastycznych analityków. Produkcja natomiast to wypłynięcie na otwarty ocean, w którym czekają drapieżni regulatorzy, sceptyczni użytkownicy i systemy legacy o temperamencie średniowiecznej maszyny obłętniczej. Pułapka prototypu jest jedną z najczęstszych chorób transformacji cyfrowej, objawiającą się budowaniem imponujących, lecz całkowicie nieużytecznych dowodów koncepcji. Gdy zaczyna się integracja z realnym procesem, okazuje się zazwyczaj, że dane są niepełne, a koszty chmury rosną w tempie geometrycznym. Wtedy właśnie pojawia się smutna, metafizyczna prawda: w danej organizacji nie wdrożono AI, wdrożono jedynie chwilowy entuzjazm.

Jedyną skuteczną odpowiedzią na te wyzwania jest metoda, a nie wiara w technologiczną magię, która miałaby rozwiązać wszystkie problemy za dotknięciem różdżki. Organizacja powinna zaczynać od precyzyjnego zdefiniowania problemu oraz kryteriów sukcesu, zamiast rzucać się na oślep w objęcia najnowszych trendów. Niezbędne jest wdrożenie High Reliability Management, czyli zarządzania wysoką niezawodnością, skupionego na czujności wobec drobnych odchyłeń i gotowości do uczenia się na błędach. Dopiero po rygorystycznej ocenie jakości danych, walidacji modelu i zaprojektowaniu nadzoru człowieka można myśleć o ograniczonym pilotażu. Skalowanie bez tych fundamentów przypomina budowanie wieżowca na ruchomych piaskach, co rzadko kończy się sukcesem architektonicznym.

W całym tym procesie niezwykle istotne, choć często pomijane, pozostaje pytanie: czy sztuczna inteligencja jest nam w ogóle do czegoś potrzebna? To pytanie brzmi obrazoburczo tylko w tych firmach, które pomyliły nowoczesną technologię z nową formą świeckiej religii. Niektóre problemy da się przecież rozwiązać prostszą automatyką, regułami biznesowymi lub zwykłą, zdroworozsądkową zmianą organizacyjną. Użycie AI tam, gdzie wystarczy dobre rzemiosło operacyjne, jest jak zamawianie satelity do znalezienia okularów, które przez cały czas leżały na głowie. Kryterium KISS, czyli zasada Keep It Simple, ma więc charakter nie tylko inżynierski, lecz przede wszystkim głęboko etyczny i ekonomiczny.

Złożoność systemu powinna być zawsze uzasadniona realną potrzebą, a nie chęcią zaimponowania konkurencji czy branżowym mediom. Każdy dodatkowy poziom modelu zwiększa przecież koszty, ryzyka operacyjne oraz trudność w wyjaśnieniu podejmowanych przez maszynę decyzji. W sektorach wysokiego ryzyka prostszy, bardziej przejrzysty model może okazać się znacznie lepszym

wyborem niż najbardziej imponująca, lecz nieprzenikniona czarna skrzynka. Dojrzałość technologiczna polega bowiem także na tym, że organizacja potrafi świadomie odmówić nadmiarowej złożoności na rzecz odpowiedzialności. Tu właśnie ogniskuje się spór między czystą skutecznością a wyjaśnialnością, który w praktyce zawsze zależy od konkretnego kontekstu biznesowego.

W przypadku rekomendacji filmu w serwisie streamingowym możemy tolerować mniejszą przejrzystość algorytmu, gdyż ryzyko błędu jest tam znikome. Jednak w diagnostyce medycznej, decyzjach kredytowych czy wymiarze sprawiedliwości brak wyjaśnialności staje się fundamentalnym problemem odpowiedzialności moralnej. Ryzyko epistemiczne, czyli zagrożenie dotyczące sposobu, w jaki budujemy wiedzę w kontakcie z algorytmami, wymaga od nas zachowania krytycznego dystansu. Człowiek dotknięty decyzją systemu nie jest przecież statystyczną abstrakcją, lecz podmiotem, któremu winni jesteśmy jasne uzasadnienie. Ostatecznie to nie technologia, lecz nasza zdolność do jej zrozumienia i kontrolowania definiuje sukces w dobie sztucznej inteligencji.

Zarządzanie wysoką niezawodnością w erze sztucznej inteligencji

Każdy użytkownik ma prawo zapytać o powody decyzji, a jeśli jedyną odpowiedzią organizacji jest sakramentalne „tak wyszło modelowi”, mamy do czynienia z kapitulacją rozumu w eleganckim, korporacyjnym formacie. Właśnie tutaj wkracza koncepcja Shemwellovskiej AI, która bezwzględnie wymaga wysokiej niezawodności, aby nie stać się arystokratycznym wzmacniaczem błędu w rękach nieświadomego zarządu. High Reliability Management (HRM), czyli zarządzanie wysoką niezawodnością skupione na czujności wobec drobnych odchyłeń, uczy nas, że systemy operujące w warunkach ekstremalnego ryzyka muszą być programowo niechętne uproszczeniom. Takie podejście, wykute w bólach przez lotnictwo, energetykę jądrową czy zaawansowaną medycynę, stanowi dziś jedyną sensowną barierę dla algorytmicznej pychy. Jeśli organizacja używa AI w systemach krytycznych, nie może zarządzać nią za pomocą kultury startupowej improwizacji, która błędy traktuje jak darmowe lekcje, a nie potencjalne katastrofy.

Wysoka niezawodność wymusza na nas radykalną zmianę stosunku do błędu, który w kulturach o niskiej dojrzałości jest winą wymagającą ukrycia, a w HRM staje się bezcennym sygnałem diagnostycznym. Dojrzała organizacja typu AI-First powinna budować systemowe mechanizmy raportowania anomalii, incydentów modelu czy dryfu wyników, czyli zjawiska polegającego na stopniowej utracie precyzji algorytmu wraz ze zmianą danych wejściowych. Niezbędne jest

stworzenie bezpiecznej przestrzeni, w której pracownik może głośno powiedzieć: „model się myli”, nie ryzykując etykiety hamulcowego innowacji czy technologicznego luddysty. W przeciwnym razie będziemy zbiorowo udawać, że system działa bez zarzutu, dopóki rzeczywistość nie wystawi nam rachunku, którego nie pokryje żaden budżet marketingowy. To swoisty paradoks: im bardziej chcemy polegać na sztucznej inteligencji, tym bardziej musimy tworzyć warunki do jej systematycznego kwestionowania.

Zaufanie pozbawione krytycyzmu jest postawą infantylną, podczas gdy krytyka bez cienia zaufania okazuje się operacyjnie jałowa i paraliżuje jakikolwiek postęp. Nowoczesna struktura potrzebuje zaufania kontrolowanego, które łączy sprawne wykorzystanie modelu z aktywną, niemal obsesyjną gotowością do falsyfikacji jego wyników w każdym procesie. Taka postawa jest naukowa w najgłębszym sensie, ponieważ nie ogranicza się do pytania o to, co model wygenerował, lecz docieka, jakie warunki musiałyby zostać spełnione, by miał rację. W tym miejscu warto przywołać Huxleyowski obraz paskudnego faktu, który z bezwzględną precyzją niszczy najpiękniejszą nawet hipotezę, sprowadzając nas brutalnie na ziemię. Organizacja przyszłości powinna kochać te paskudne fakty bardziej niż lśniące prezentacje, ponieważ każdy taki fakt jest surowym darem od rzeczywistości, chroniącym nas przed katastrofą.

Paskudny fakt obnaża prawdę o tym, że model nie uwzględnił kluczowej zmiennej, dane są przesunięte, a ryzyko zostało zaniżone przez nadmierny optymizm projektantów. Piękna hipoteza, która nie została poddana próbie ognia w starciu z twardymi danymi, pozostaje jedynie literaturą piękną ubraną w garnitur zaawansowanej analityki biznesowej. Należy również przestać traktować halucynacje AI jako zabawną przypadłość chatbotów, a zacząć postrzegać je jako poważne ryzyko epistemiczne, czyli zagrożenie dotyczące sposobu, w jaki budujemy wiedzę i odróżniamy prawdę od fałszu. Halucynacja, będąca generowaniem treści pozornie wiarygodnych, lecz całkowicie fałszywych, w zastosowaniach rozrywkowych jest niegroźną anegdotą, ale w medycynie czy finansach staje się śmiertelnym niebezpieczeństwem. AI nie zbawia chaosu. AI go przyspiesza, jeśli nie narzucimy jej rygoru wysokiej niezawodności i intelektualnej uczciwości.

Zarządzanie ryzykiem: dlaczego AI potrzebuje nadzoru i etyki

Model językowy nie kłamie w sensie moralnym, gdyż brak mu intencjonalności, niemniej dla organizacji skutek jego konfabulacji bywa identyczny z celowym oszustwem. Powstają twierdzenia pozbawione ontologicznego zakotwiczenia, które niefrasobliwy decydent może włączyć do krwiobiegu strategicznego firmy. Ryzyko to potęguje sykofantyzm modelu, czyli zjawisko, w którym

algorytm generuje odpowiedzi potwierdzające uprzedzenia użytkownika zamiast podawać obiektywne fakty. Zamiast korygować błędy, AI staje się lustrem naszych pragnień, co w środowisku korporacyjnym przypomina średniowieczną metaforę alchemii, gdzie ołów życzeń zamienia się w złoto slajdów. Jeśli menedżer szuka potwierdzenia dla karkołomnej strategii, model z pewnością dostarczy mu eleganckiego, choć pustego uzasadnienia. Demo pokazuje możliwości, ale produkcja pokazuje prawdę.

W organizacjach najbardziej toksycznym paliwem dla błędnych decyzji jest połączenie sykofantyzmu maszyny z efektem Dunninga-Krugera u użytkownika. Osoba o niskiej kompetencji technicznej, lecz wysokiej pewności siebie, traktuje AI jako arystokratyczny wzmacniacz błędu, który nadaje jej intuicjom pozory obiektywnej prawdy. Model generuje odpowiedź, użytkownik uznaje ją za twardy dowód, a zarząd otrzymuje efektowny slajd, po czym wszyscy są zdumieni, że rzeczywistość nie była pod wrażeniem tej cyfrowej ekwilibrystyki. Aby uniknąć takich scenariuszy, systemy AI muszą być projektowane tak, by aktywnie ujawniały ryzyko epistemiczne, czyli zagrożenie dotyczące sposobu, w jaki budujemy wiedzę w kontakcie z algorytmami. Zamiast pozornej pewności, model powinien wskazywać ograniczenia, zadawać pytania doprecyzowujące i odmawiać autorytatywnego tonu tam, gdzie brakuje mu danych.

Edukacja tzw. knowledgeable buyers, o której wspomina Shemwell, staje się w tym kontekście warunkiem koniecznym dla zachowania bezpieczeństwa operacyjnego. Użytkownik musi rozumieć nie tylko techniczne aspekty formułowania zapytań, ale przede wszystkim wiedzieć, kiedy należy zachować zdrowy sceptycyzm wobec wyników. Inżynieria promptów bywa dziś sprowadzana do sztuki pisania ładnych komend, podczas gdy w rzeczywistości stanowi ona fundament zarządzania poznaniem w organizacji. Dobry prompt to nie tylko rola i cel, ale przede wszystkim rygorystyczne kryteria jakości oraz jasno określony poziom dopuszczalnej niepewności. Jeszcze ważniejszy jest jednak metaprompt organizacyjny, określający procedury audytu, zasady dokumentowania procesów oraz granice, których algorytmowi przekraczać nie wolno. Prompt engineering bez governance jest jak retoryka bez etyki: może być skuteczna, ale niekoniecznie bezpieczna.

Należy pamiętać, że AI nie działa w próżni, lecz w gęstym ekosystemie dostawców, chmur obliczeniowych i zewnętrznych integratorów. Myślenie ekosystemowe, czyli podejście traktujące AI jako element sieci danych i norm prawnych, pozwala dostrzec, że organizacja rzadko kontroluje cały łańcuch wartości. Ryzyko technologiczne staje się więc ryzykiem łańcucha dostaw, obejmującym kwestie takie jak data provenance, czyli badanie genealogii i kontekstu danych przed ich wykorzystaniem. Musimy pytać o to, gdzie przetwarzane są informacje, jakie są warunki licencyjne i czy dostawca spełnia wymagania sektorowe, zwłaszcza w obliczu potencjalnych przejęć

czy zmian polityki prywatności. Te dylematy przestają być domeną działu IT, stając się kluczowymi elementami strategii przetrwania w świecie, gdzie AI nie zbawia chaosu, lecz go przyspiesza.

Współczesne prawo przestaje być jedynie końcową kontrolą dokumentów, a staje się integralną częścią procesu projektowania systemów informatycznych. Zasady takie jak accountability by design czy human oversight by design nie są jedynie estetycznymi ozdobami raportów rocznych, lecz fundamentami High Reliability Management (HRM). Zarządzanie wysoką niezawodnością, skupione na czujności wobec drobnych odchyłeń, pozwala organizacjom bezpiecznie operować w warunkach nieprzewidywalności algorytmicznej. Kontrakty muszą być pisane przez prawników rozumiejących technologię, a systemy budowane przez technologów, którzy pojmują wagę odpowiedzialności prawnej. Tylko takie połączenie kompetencji pozwala uniknąć sytuacji, w której technologiczny romans zderzy się z brutalnymi, fiskalnymi realiami błędnej decyzji.

AI jako organizm: dlaczego monitoring i etyka przewyższają kod

Próby zepchnięcia odpowiedzialności na etap samej architektury systemu przypominają budowanie papierowej tamy, która ma powstrzymać wezbraną rzekę rzeczywistości. Jeśli algorytm zostanie zaprojektowany w taki sposób, że nikt nie potrafi wskazać palcem winnego za błędny wynik, każda późniejsza klauzula prawna będzie jedynie parasolem otwieranym z gracją już po przejściu powodzi. Shemwellowska koncepcja AI jako narzędzia nieliniowego rozwiązywania problemów wymusza na nas zatem bolesną, lecz konieczną dojrzałość w postrzeganiu błędu. W tym paradygmacie błąd nie jest irytującym wyjątkiem od reguły, lecz najcenniejszą informacją o kondycji samego systemu. Jeżeli model systematycznie myli się wobec konkretnej grupy klientów, nie mamy do czynienia z niewinną anomalią, lecz z precyzyjną diagnozą ukrytych uprzedzeń. Gdy system generuje fałszywe pozytywy w określonych warunkach, nie jest to statystyczny szum, lecz wyraźny sygnał, że nasza mapa rzeczywistości przestała odpowiadać terytorium.

W antropologii organizacji istnieje niezwykle trafna intuicja, wedle której praktyka zawsze, prędzej czy później, modyfikuje pierwotny projekt techniczny. Ludzie rzadko używają systemów dokładnie tak, jak wyśnili to sobie ich projektanci w sterylnych warunkach laboratoriów czy na szklanych ekranach prezentacji. Zamiast tego dostosowują je do swoich potrzeb, obchodzą niewygodne funkcje, skracają procedury, a czasem wręcz rytualizują lub sabotują nowe narzędzia w akcie obrony własnej autonomii. AI nie będzie w tym względzie żadnym wyjątkiem, bowiem pracownicy z pewnością zaczną tworzyć własne prompty, nieformalne skróty i sprytnie obejścia systemowych zabezpieczeń. To właśnie dlatego governance, czyli system zarządzania i nadzoru nad technologią,

musi mieć charakter nie tylko formalny, ale wręcz etnograficzny. Musimy z uwagą obserwować, jak narzędzie naprawdę żyje w tkance organizacji, zamiast wierzyć jedynie w martwe zapisy polityki AI, które często rozmiągają się z biurową codziennością. Między tymi dwoma tekstami – oficjalną instrukcją a realnym działaniem – mieszka największe ryzyko operacyjne, którego nie wyłapie żaden automatyczny skaner.

Kolejna pułapka, w którą chętnie wpadają współczesne organizacje, dotyczy natury czasu oraz danych, na których opierają się skomplikowane modele matematyczne. Algorytmy uczą się na doświadczeniach z przeszłości, przy czym ich głównym zadaniem jest sprawne operowanie w skrajnie niepewnej i zmiennej przyszłości. Dopóki świat pozostaje stabilny, ta konstrukcja sprawdza się całkiem nieźle, lecz gdy nadchodzi gwałtowna zmiana, historia staje się coraz gorszym i bardziej zwodniczym przewodnikiem. Pandemie, konflikty zbrojne, kryzysy energetyczne czy nagłe zmiany regulacyjne sprawiają, że dane historyczne błyskawicznie tracą swoją moc predykcyjną, zamieniając się w nekromancję tabelaryczną. Zjawisko to nazywamy dryfem modelu (model drift), czyli procesem, w którym rozkład danych wejściowych ulega zmianie, a zależności przyczynowe, na których oparto trening, zwyczajnie wygasają. Organizacja, która ignoruje ten dryf, żyje w niebezpiecznej iluzji stabilności, podczas gdy różnica między światem modelu a rzeczywistością staje się kosztowną przepaścią, której nie zasypie żaden dodatkowy procesor. Dlatego monitoring po wdrożeniu jest w istocie równie krytyczny, co sam proces trenowania algorytmu.

Model nie jest statycznym pomnikiem techniki, lecz raczej organizmem technicznym funkcjonującym w skrajnie zmiennym i reaktywnym środowisku społecznym. Perspektywa ekosystemowa pozwala nam dostrzec ryzyko przewidywań performatywnych, w których model nie tylko opisuje świat, ale aktywnie i często nieświadomie go kształtuje. Jeśli system scoringowy uzna dany segment klientów za ryzykowny, firma ograniczy im ofertę, co w efekcie pogorszy ich sytuację finansową i ostatecznie potwierdzi pierwotną, być może błędną ocenę. Podobnie algorytmy rekomendacyjne, promując określone treści, wpływają na gusta użytkowników, by następnie uznać te sztucznie wykreowane preferencje za naturalne i obiektywne fakty. W takim układzie model staje się aktywnym aktorem społecznym, a pytanie o jakość danych nieuchronnie przeobraża się w fundamentalne pytanie o dystrybucję władzy. Wymaga to od nas nie tylko statystycznej walidacji, ale przede wszystkim głębokiej refleksji normatywnej nad tym, czy optymalizacja jednej wartości nie niszczy przypadkiem innej, równie istotnej dla dobrostanu wspólnoty.

Pytania o etykę i normy społeczne nie są bynajmniej hamulcem dla innowacji, lecz bezpiecznikiem chroniącym ją przed wizerunkowym samobójstwem. Musimy zastanowić się, czy automatyzacja nie tworzy nowych asymetrii informacyjnych i czy redukcja kosztów nie przenosi ryzyka na

najsłabszych uczestników ekosystemu. Data provenance, czyli badanie genealogii i kontekstu zebranych danych, staje się w tym ujęciu kluczowym narzędziem ochrony przed poznawczą alchemią i wyciąganiem błędnych wniosków strategicznych. Refleksja ta pozwala uniknąć sytuacji, w której model staje się arystokratycznym wzmacniaczem błędu, utrwalającym niesprawiedliwe podziały pod płaszczykiem obiektywnej matematyki. Sykofantyzm modelu, czyli zjawisko generowania odpowiedzi potwierdzających uprzedzenia użytkownika, jest kolejnym sygnałem, że system przestał być obiektywnym doradcą, a stał się jedynie echem naszych własnych błędów. Tylko takie podejście pozwala na budowę systemów, które są nie tylko efektywne, ale przede wszystkim godne zaufania w długim terminie.

Ekonomicznie najdojrzalsze podejście do sztucznej inteligencji polega na traktowaniu jej jako inwestycji o specyficznym profilu ryzyka, a nie tylko jako kolejnego kosztu licencji oprogramowania. Należy skrupulatnie liczyć nie tylko bezpośrednie wydatki na narzędzie, ale także ukryte koszty integracji, cyberbezpieczeństwa oraz ciągłego, żmudnego szkolenia kadr. Prawdziwy zwrot z inwestycji pojawia się tam, gdzie technologia realnie przekształca procesy i skraca cykle decyzyjne, a nie tam, gdzie jedynie ozdabia stary bałagan nowym interfejsem. Wszak AI nie zbawia chaosu, AI go jedynie przyspiesza, jeśli nie zostanie osadzone w przemyślanej strukturze operacyjnej. Rynek AI jest dziś pełen romantyzmu, lecz finanse pozostają brutalnie prozaiczne i zawsze w końcu wystawiają rachunek za nadmierny entuzjazm. Tu pojawia się jedna z najważniejszych maksym: technologiczny romans musi zderzyć się z fiskalnymi realiami, abyśmy mogli mówić o prawdziwym sukcesie. Romantyzm pozbawiony chłodnej kalkulacji staje się jedynie poezją zadłużenia, która rzadko znajduje szczęśliwe zakończenie w twardych realiach rynkowych. Jednocześnie nie wolno nam popaść w paraliżujący konserwatyzm obronny, gdyż krytyka zjawisk takich jak AI-washing nie oznacza przecież, że technologię tę należy z góry odrzucić.

AI jako narzędzie antybiurokratyczne: między odkrywaniem a ukrywaniem

Wdrażanie sztucznej inteligencji nie jest aktem kapitulacji przed technologią, lecz wyrazem najwyższej dyscypliny operacyjnej. Scott Shemwell nie występuje tu w roli proroka rezygnacji, który ogłasza zmierzch ludzkiego sprawstwa, lecz raczej jako surowy mentor porządku. Gdyby sztuczna inteligencja nie istniała, należałoby ją wymyślić, gdyż ta parafraza Woltera najlepiej oddaje palącą potrzebę naszych czasów. Skala generowanych danych, zawrotne tempo zmian oraz nieliniowość współczesnych ryzyk sprawiają, że człowiek pozbawiony maszynowego wsparcia staje się po prostu poznawczo niewydolny. Jednak maszyna działająca bez ludzkiego nadzoru pozostaje tworem

pozbawionym sądu, co czyni ją jedynie automatycznym wzmacniaczem błędu. Przyszłość należy zatem do układów hybrydowych, w których algorytmy radykalnie zwiększają zdolność obserwacji, podczas gdy człowiek zachowuje wyłączną odpowiedzialność za interpretację i cel.

To podejście nabiera szczególnego znaczenia w sektorach takich jak energetyka, zarządzanie miastami czy profesjonalny sport, gdzie dane są gęsto splecione z rzeczywistością. W energetyce strumienie informacji to jednocześnie fizyka przesyłu, geopolityka surowcowa oraz skomplikowane instrumenty finansowe. W koncepcji smart cities dane stanowią nową infrastrukturę, definiują nowoczesne obywatelstwo i stają się realnym narzędziem sprawowania władzy. Nawet w lidze NFL statystyki to coś więcej niż liczby, ponieważ opisują one talent, reputację, psychologię graczy oraz ryzyko całego zespołu. Każdy z tych przykładów dowodzi, że sztuczna inteligencja działa efektywnie dopiero wtedy, gdy zostanie osadzona w gęstym kontekście społecznym i operacyjnym. Bez tego zakotwiczenia technologia staje się jedynie kosztowną dekoracją, która nie rozwiązuje realnych problemów organizacji.

Musimy zrozumieć, że nie istnieją żadne czyste dane o człowieku, tkance miejskiej czy mechanizmach rynkowych, które byłyby wolne od kontekstu. Zawsze mamy do czynienia z informacjami zebranymi w określonym układzie instytucji, partykularnych interesów oraz dostępnych narzędzi pomiarowych. Data provenance, czyli badanie pochodzenia i genealogii zebranych informacji przed ich wykorzystaniem, pozwala uniknąć wyciągania błędnych wniosków strategicznych z zanieczyszczonych źródeł. Pułapki danych są w istocie pułapkami naszej wyobraźni, gdyż organizacja widzi zazwyczaj tylko to, co wcześniej nauczyła się mierzyć. To, czego nie potrafimy nazwać lub skategoryzować, pozostaje dla nas niewidoczne, niezależnie od mocy obliczeniowej naszych serwerów. AI może wprawdzie poszerzyć to pole widzenia, ale równie dobrze może usztywnić stare ślepoty, jeśli nakarmimy ją przeszłością bez cienia krytycyzmu.

Prawdziwa dojrzałość w korzystaniu z modeli polega na używaniu ich nie tylko do generowania odpowiedzi, lecz do odkrywania, jak błędnie postaviliśmy pytania. W tym ujęciu sztuczna inteligencja staje się potężnym narzędziem antybiurokratycznym, o ile potrafimy posługiwać się nią z należytą mądrością. Klasyczna biurokracja kocha stabilne klasyfikacje i sztywne formularze, które dają złudne poczucie kontroli nad płynną rzeczywistością. Algorytmy mogą jednak pokazać, że te tradycyjne podziały są niewystarczające, a segmenty klientów zmieniają się szybciej niż urzędowe wytyczne. Mogą ujawnić, że granice działów wewnątrz firmy nie odpowiadają realnym granicom problemów, z którymi boryka się organizacja. AI nie zbawia chaosu, AI go przyspiesza, jeśli zostanie użyta jedynie do automatyzacji starych, wadliwych procesów.

Istnieje realne ryzyko, że technologia ta stanie się narzędziem hiperbiurokracji, jeśli posłuży jedynie do automatycznego wzmacniania istniejących, skostniałych kategorii. Wtedy zamiast

wyzwolić nas z niewoli arkusza kalkulacyjnego, zamieni go w nieprzejrzyisty algorytm, uprawiając swoistą nekromancję tabelaryczną na żywym organizmie firmy. Kluczowe pytanie brzmi zatem: czy technologia ma służyć odkrywaniu złożoności świata, czy jedynie jej administracyjnemu ukrywaniu przed zarządem? Shemwell wyraźnie opowiada się za tą pierwszą możliwością, widząc w AI szansę na wyjście poza uproszczone kategorizowanie zasobów i ludzi. Systemy te powinny umożliwiać interpretację dynamicznych zależności, przekształcając organizacje w systemy bardziej adaptacyjne, szczupłe i świadome ryzyka. Aby to osiągnąć, musimy jednak zrezygnować z leniwego pragnienia prostoty tam, gdzie owa prostota jest po prostu kłamstwem.

Nieliniowość wymaga bowiem znacznie większej dyscypliny niż przewidywalna liniowość, co stanowi swoisty paradoks współczesnego zarządzania. Kiedy świat jest prosty, można pozwolić sobie na improwizację, ale w warunkach złożoności każda decyzja musi być wsparta rzetelną strukturą uczenia się. Nie chodzi tu o strukturę kontroli dla samej kontroli, lecz o system, który pozwala szybko wykrywać błędy i korygować kurs. W epoce algorytmów pasteurowska maksyma, że szansa sprzyja przygotowanemu umysłowi, nabiera zupełnie nowego, systemowego znaczenia. Przygotowana organizacja to nie ta, która kupiła najdroższy model językowy, lecz ta, która posiada gotowe protokoły eksperymentowania i walidacji. Szansa w świecie AI sprzyja nie najbardziej podekscytowanemu umysłowi, ale najlepiej przygotowanemu ekosystemowi danych i procedur.

High Reliability Management, czyli zarządzanie wysoką niezawodnością skupione na czujności wobec drobnych odchyłeń, staje się tu fundamentem bezpiecznego operowania technologią. Kto posiada jedynie entuzjazm i budżet, ten ryzykuje, że stanie się hojnym sponsorem własnej, spektakularnej katastrofy. Warto w tym miejscu powrócić do obrazu arkusza kalkulacyjnego, który sam w sobie nigdy nie był wrogiem postępu. Arkusz jest świetnym sługą, ale fatalnym filozofem, ponieważ pomaga liczyć, lecz nigdy nie powinien definiować naszej ostatecznej rzeczywistości. Podobnie sztuczna inteligencja może stać się genialnym pomocnikiem, ale pozostaje tragicznie złym suwerenem, jeśli oddamy jej pełnię władzy. Pomaga nam wykrywać wzorce i symulować scenariusze, ale nie może przejąć odpowiedzialności za sens, wartość oraz etyczne granice podejmowanych decyzji.

Sykofantyzm modelu, czyli zjawisko generowania odpowiedzi potwierdzających uprzedzenia użytkownika, sprawia, że bez krytycznego nadzoru AI staje się jedynie lustrem naszych własnych błędów. Ryzyko epistemiczne, czyli zagrożenie dotyczące sposobu budowania wiedzy w kontakcie z algorytmami, staje się kluczowym wyzwaniem dla współczesnych liderów. Lekcja płynąca z prac Shemwella jest jasna: dane wymagają systemowej podejrzliwości, modele nieustannego nadzoru, a innowacja głębokiej pokory. Organizacja, która tego nie pojmie, będzie wprawdzie posiadać zaawansowane AI, ale straci to, co najcenniejsze – własną inteligencję organizacyjną. To najgorszy

z możliwych scenariuszy: maszyna staje się coraz mądrzejsza wewnątrz instytucji, która coraz szybciej ucieka przed własnym myśleniem. Technologiczny romans musi zderzyć się z fiskalnymi realiami i wymogami rzetelności, aby przynieść realną wartość.

Sztuczna inteligencja staje się ostatecznym lustrem naszych organizacyjnych niedoskonałości, w którym odbija się nie tylko nasza wiedza, ale przede wszystkim nasze lęki przed niepewnością. Czy w pogoni za algorytmiczną nieomylnością nie stajemy się zakładnikami własnych uproszczeń, zamieniając realne zrozumienie świata na cyfrowe potwierdzenie błędnych założeń? Pytanie nie brzmi już, co AI potrafi zrobić dla nas, lecz czy jesteśmy wystarczająco odważni, by skonfrontować się z prawdą, którą ona bezlitośnie ujawnia.

Inspiracje

[1]



"Nonlinear Big Data and AI-Enabled Problem-Solving" Scott M.

Shemwell

2026 | CRC Press | ISBN: 9781041086963

Dr **Scott M. Shemwell** jest dyrektorem zarządzającym The Rapid Response Institute i uznanym autorytetem w dziedzinie operacji terenowych, zarządzania ryzykiem i doskonałości operacyjnej. Z ponad 35-letnim doświadczeniem w sektorze energetycznym, kierował procesami restrukturyzacyjnymi i transformacyjnymi w globalnych organizacjach z indeksu S&P 500, start-upach i firmach świadczących usługi profesjonalne. Jego kariera obejmuje znaczące role w przejęciach, zbyciach aktywów oraz zarządzaniu dużymi projektami globalnymi. Dr Shemwell jest płodnym autorem, który publikuje obszerne prace na temat nauk o zarządzaniu, jakości danych i ładu organizacyjnego. Posiada tytuł licencjata fizyki z North Georgia College, tytuł magistra administracji biznesowej z Houston Baptist University oraz tytuł doktora administracji biznesowej z Nova Southeastern University.

*Dr. **Scott M. Shemwell** is the Managing Director of The Rapid Response Institute and a recognized authority in field operations, risk management, and operational excellence. With over 35 years of experience in the energy sector, he has led turnaround and transformation processes for global S&P 500 organizations, start-ups, and professional service firms. His career includes significant roles in acquisitions, divestitures, and the management of large-scale global projects. Dr. Shemwell is a prolific author who has written extensively on management science, data quality, and organizational governance. He holds a Bachelor of Science in Physics from North Georgia College, a Master of Business Administration from Houston Baptist University, and a Doctor of Business Administration from Nova Southeastern University.*

The Rapid Response Institute

Literatura uzupełniająca

Książki

Literatura pokrewna (Google Scholar):

[1] "Traité sur la tolérance"

François-marie Arouet (wolter)

1763 | Jean Néaulme

[2] "Études sur le Vin"

Louis Pasteur

1866 | F. Savy

[3] "Études sur la Bière"

Louis Pasteur

1876 | Gauthier-Villars

[4] "What Is Man?"

Mark Twain

1906 | De Vinne Press | ISBN: 978-0520023567



[5] "Letters from the Earth"

Mark Twain


1962 | Phoemixx Classics Ebooks | ISBN: 9783985518616



[6] "Rebooting AI: Building Artificial Intelligence We Can Trust"

Gary Marcus, Ernest Davis

2019 | Vintage | ISBN: 9781524748265



[7] "The Algebraic Mind: Integrating Connectionism and Cognitive Science"

Gary Marcus

2001 | MIT Press | ISBN: 9780262354400



[8] "The AI Con: How to Fight Big Tech's Hype and Create the Future We Want"

Emily M. Bender, Alex Hanna

2025 | Random House | ISBN: 9781529949896



[9] "Linguistic Fundamentals for Natural Language Processing: 100 Essentials from Morphology and Syntax"

Emily M. Bender

2013 | Springer Nature | ISBN: 9783031021503



[10] "Power and Progress: Our Thousand-Year Struggle Over Technology and Prosperity"

Daron Acemoglu, Simon Johnson

2023 | Hachette UK | ISBN: 9781399804486

[11] "Why Nations Fail: The Origins of Power, Prosperity, and Poverty"


Daron Acemoglu, James A. Robinson

2012 | Crown Business | ISBN: 9798567819234

[12] "The Age of Surveillance Capitalism: The Fight for a Human Future at the New Frontier of Power"

Shoshana Zuboff

2019 | PublicAffairs | ISBN: 9798507331451



[13] "In the Age of the Smart Machine: The Future of Work and Power"

Shoshana Zuboff

1988 | Basic Books | ISBN: 9781781256855



[14] "Unto This Last: Four Essays on the First Principles of Political Economy"

John Ruskin


1862 | Smith, Elder & Co. | ISBN: 9781295990344



[15] "The Seven Lamps of Architecture"

John Ruskin


1849 | Courier Corporation | ISBN: 9780486136325



[16] "Evidence as to Man's Place in Nature"

Thomas Henry Huxley


1863 | Williams and Norgate | ISBN: 9781697716986



[17] "Evolution and Ethics and Other Essays"

Thomas Henry Huxley

1893 | CreateSpace | ISBN: 9781511843362



[18] "The World As I See It"

Albert Einstein


1934 | Book Tree | ISBN: 9781585092871



[19] "Out of My Later Years"

Albert Einstein

1950 | Philosophical Library | ISBN: 978-0806530581



[20] "The Great Demographic Reversal: Ageing Societies, Waning Inequality, and an Inflation Revival"

Charles Goodhart, Manoj Pradhan

2020 | Springer Nature | ISBN: 9783030426576



[21] "The Evolution of Central Banks"

Charles Goodhart

1988 | MIT Press (MA) | ISBN: 9780262570732



[22] "Thinking, Fast and Slow"

Daniel Kahneman

2011 | Penguin UK | ISBN: 9780141918921

[23] "Noise: A Flaw in Human Judgment"

Daniel Kahneman, Olivier Sibony, Cass R. Sunstein

2021 | William Collins | ISBN: 9798540821490

[24] "Judgment under Uncertainty: Heuristics and Biases"

Daniel Kahneman, Paul Slovic, Amos Tversky

1982 | Cambridge University Press | ISBN: 978-0-521-28414-1

[25] "Choices, Values, and Frames"

Daniel Kahneman, Amos Tversky

2000 | Cambridge University Press | ISBN: 978-0-521-62749-8

[26] "Self-Insight: Roadblocks and Detours on the Path to Knowing Thyself"

David Dunning

2005 | Psychology Press | ISBN: 978-1-84169-074-2

[27] "The Self in Social Judgment"

Mark D. Alicke, David Dunning, Joachim I. Krueger

2005 | Psychology Press | ISBN: 978-1-84169-408-5

[28] "Candide, ou l'Optimisme"

François-marie Arouet (Voltaire)

1759 | Marc-Michel Rey

[29] "AI Ethics"

Mark Coeckelbergh

2020 | MIT Press

[30] "Race After Technology: Abolitionist Tools for the New Jim Code"

Ruha Benjamin

2019 | Polity

[31] "The Ethics of Artificial Intelligence: A Philosophical Introduction"

Sven Nyholm

2026 | Oxford University Press

[32] "Critical Theory of AI"

Simon Lindgren

2023 | Polity

[33] "The Ethics of AI: Power, Critique, Responsibility"

Rainer Mühlhoff

2025 | Bristol University Press

[34] "The Alignment Problem: Machine Learning and Human Values"

Brian Christian

2020 | W. W. Norton & Company

[35] "The Idea of Justice"

Amartya Sen

2009 | Harvard University Press

Artykuły naukowe

Autorzy przywoływani:

[1] "We need a new ethics for a world of AI agents"

Iason Gabriel, Geoff Keeling, Arianna Manzini, James Evans

2025 | Nature

[Google Scholar](#)

[2] "The atoms of neural computation"

Gary Marcus, Adam H. Marblestone, Thomas L. Dean

2014 | Science | DOI: 10.1126/science.1261661

[Google Scholar](#)

[3] "Rule learning by seven-month-old infants"

Gary F. Marcus, Shushruth Vijayan, S. Bandi Rao, Peter M. Vishton

1999 | Science | DOI: 10.1126/science.283.5398.77

[Google Scholar](#)

[4] "Principles alone cannot guarantee ethical AI"

Brent Mittelstadt

2019 | Nature Machine Intelligence

[Google Scholar](#)

[5] "On the Dangers of Stochastic Parrots: Can Language Models Be Too Big?"

Emily M. Bender, Timnit Gebru, Angelina McMillan-Major, Shmargaret Shmitchell

2021 | Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency | DOI: 10.1145/3442188.3445922

[Google Scholar](#)

[6] "Climbing towards NLU: On Meaning, Form, and Understanding in the Age of Data"

Emily M. Bender, Alexander Koller

2020 | Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics | DOI: 10.18653/v1/2020.acl-main.463

[Google Scholar](#)

[7] "Gender Shades: Intersectional Accuracy Disparities in Commercial Gender Classification"

Joy Buolamwini, Timnit Gebru

2018 | Proceedings of the 1st Conference on Fairness, Accountability and Transparency

[Google Scholar](#)

[8] "Why AI Ethics Is a Critical Theory"

Sven Nyholm, Waelen

2022 | Philosophy & Technology

[Google Scholar](#)

[9] "Automation and New Tasks: How Technology Displaces and Reinstates Labor"

Daron Acemoglu, Pascual Restrepo

2019 | Journal of Economic Perspectives | DOI: 10.1257/jep.33.2.3

[Google Scholar](#)

[10] "Tasks, Automation, and the Rise in U.S. Wage Inequality"

Daron Acemoglu, Pascual Restrepo

2022 | Econometrica | DOI: 10.3982/ECTA19815

[Google Scholar](#)

[11] "Big Other: Surveillance Capitalism and the Prospects of an Information Civilization"

Shoshana Zuboff

2015 | Journal of Information Technology | DOI: 10.1057/jit.2015.5

[Google Scholar](#)

[12] "Axiology and the Evolution of Ethics in the Age of AI: Integrating Ethical Theories via Multiple-Criteria Decision Analysis"

Various Authors

2025 | MDPI

[Google Scholar](#)

[13] "Philosophy and Ethics in the Age of Artificial Intelligence: Bridging the Gap between Technology and Human Values"

Various Authors

2024 | Journal of Information Systems Engineering and Management

[Google Scholar](#)

[14] "The Physical Basis of Life"

Thomas Henry Huxley

1868 | The Fortnightly Review

[Google Scholar](#)

[15] "On the Advisableness of Improving Natural Knowledge"

Thomas Henry Huxley

1866 | Lay Sermons, Addresses and Reviews

[Google Scholar](#)

[16] "An overview of AI ethics: moral concerns through the lens of principles, lived realities and power structures"

A. M. Smith, B. C. Jones

2026 | AI and Ethics

[Google Scholar](#)

[17] "On the Electrodynamics of Moving Bodies"

Albert Einstein

1905 | Annalen der Physik | DOI: 10.1002/andp.19053221004

[Google Scholar](#)

[18] "The Foundation of the General Theory of Relativity"

Albert Einstein

1916 | Annalen der Physik | DOI: 10.1002/andp.19163540702

[Google Scholar](#)

[19] "Defining Socially Disruptive Technologies and Reframing the Ethical Challenges They Pose"

J. Anderson, J. Hopster, B. Lundgren

2026 | Technology in Society

[Google Scholar](#)

[20] "Problems of Monetary Management: The U.K. Experience"

Charles Goodhart

1975 | Papers in Monetary Economics | DOI: 10.1016/0304-3932(75)90035-1

[Google Scholar](#)

[21] "Why Do Banks Need a Central Bank?"

Charles Goodhart

1987 | Oxford Economic Papers | DOI: 10.1093/oxfordjournals.oep.a041785

[Google Scholar](#)

[22] "Ethics of artificial intelligence: A balanced approach to development and application"

O. A. Baksansky, S. G. Sorokina

2025 | Medicine. Sociology. Philosophy. Applied Research

[Google Scholar](#)

[23] "Prospect Theory: An Analysis of Decision under Risk"

Daniel Kahneman, Amos Tversky

1979 | Econometrica | DOI: 10.2307/1914185

[Google Scholar](#)

[24] "Judgment under Uncertainty: Heuristics and Biases"

Amos Tversky, Daniel Kahneman

1974 | Science | DOI: 10.1126/science.185.4157.1124

[Google Scholar](#)

[25] "Artificial Intelligence Ethics in Practice"

Jessica Cussins Newman, Rajvardhan Oak

2023 | ;login: (USENIX Magazine)

[Google Scholar](#)

[26] "The Nature and Significance of Culpability"

David O. Brink

2019 | Criminal Law and Philosophy

[Google Scholar](#)

[27] "Unskilled and Unaware of It: How Difficulties in Recognizing One's Own Incompetence Lead to Inflated Self-Assessments"

Justin Kruger, David Dunning

1999 | Journal of Personality and Social Psychology | DOI: 10.1037/0022-3514.77.6.1121

[Google Scholar](#)

[28] "Flawed self-assessment: Implications for health, education, and the workplace"

David Dunning, Chip Heath, Jerry M. Suls

2004 | Psychological Science in the Public Interest | DOI: 10.1111/j.1529-1006.2004.00018.x

[Google Scholar](#)

[29] "Alignment Is Not Enough: A Relational Framework for Moral Standing in Human-AI Interaction"

E. M. Bender, et al.

2023 | arXiv

[Google Scholar](#)

[30] "Egocentrism over e-mail: Can people communicate as well as they think?"

Justin Kruger, Nicholas Epley, Jason Parker, Zhi-Wen Ng

2005 | Journal of Personality and Social Psychology | DOI: 10.1037/0022-3514.89.6.925

[Google Scholar](#)

[31] "Mémoire sur la fermentation appelée lactique"

Louis Pasteur

1857 | Comptes rendus hebdomadaires des séances de l'Académie des sciences

[Google Scholar](#)

[32] "Mémoire sur les corpuscules organisés qui existent dans l'atmosphère"

Louis Pasteur

1861 | Annales des sciences naturelles

[Google Scholar](#)

[33] "The Ethics of AI: Philosophical Perspectives"

Kakembo Aisha Annet

2025 | Research Invention Journal of Research in Education

[Google Scholar](#)



Tekst opracowany z udziałem sztucznej inteligencji.
Redakcja i kontrola merytoryczna: Fundacja Dobre Państwo.
APA ONE Publishing System
Fundacja Dobre Państwo © 2026
Article ID: caodb5f6-e6c6-4323-bb01-ocb7428f66b1