Dryf, czyli kiedy sztucznej inteligencji odjeżdża peron

Bartłomiej W. Papież, Assoc. Prof. PhD MSc
Big Data Institute, University of Oxford, Wielka Brytania

Skróty: AI (*artificial intelligence*) – sztuczna inteligencja; TK – tomografia komputerowa

Słowa kluczowe: sztuczna inteligencja

Do napisania tego tekstu skłoniła mnie moja ostatnia wizyta u lekarza, którego dla niepoznaki nazywamy stomatologiem. Osobiście uważam, że „praktyk sadysta" byłoby nazwą bardziej intuicyjną, ale kwestie definicji zostawmy Radzie Lekarskiej lub Radzie Języka Polskiego. Jak to zwykle bywa, już po pierwszym „proszę otworzyć szerzej" zrozumiałem, że ta wizyta nie skończy się szybko. Zanim zdążyłem powiedzieć coś więcej niż „mmhmm", stomatolog, dowiedziawszy się, że zajmuję się sztuczną inteligencją (AI) w medycynie, postanowił podzielić się własnymi przemyśleniami na temat przyszłości swojego zawodu. Oczywiście postarałem się, aby człowiek, który akurat trzyma wiertło w moich ustach, a więc patrzy na mnie z pozycji niezaprzeczalnej przewagi argumentacyjnej, nie miał wątpliwości, że moja twarz wyraża głębokie przekonanie o absolutnej niemożności wyeliminowania jego zawodu przez AI. Przemiły stomatolog zaczął opowiadać o tym, jak trudna jest jego specjalizacja, ile decyzji wymaga doświadczenia, wyczucia i „ręki", której żaden, choćby najinteligentniejszy, algorytm nie zastąpi. I muszę przyznać (nawet bez presji wiertła), że trudno się z nim nie zgodzić – stomatologia jest w końcu sztuką łączącą chirurgię, medycynę ogólną, a przede wszystkim psychologię, bo trzeba wiedzieć, jak podejść do pacjenta, który właśnie próbuje nie umrzeć ze strachu. Inna sprawa, że nie byłem mu w stanie zaprzeczyć w sposób werbalny, bo narzędzia w moich ustach przypominały średniowieczny mechanizm do wyciągania informacji od osób posądzonych o czary. Wydałem



z siebie coś pomiędzy chrząknięciem a aktem kapitulacji, co lekarz potraktował jako zachętę do kontynuowania. Nie mogłem mówić, więc opracowaliśmy własny system komunikacji binarnej: jedno moje „mmhmm" znaczyło „tak", drugie „mrrhm" – „nie". Tym sposobem odbyliśmy całkiem głęboką, jak na moje ograniczone możliwości fonetyczne, dyskusję o przyszłości medycyny i o tym, które specjalizacje są „niezastąpione".

W pewnym momencie, z niepokojącym spokojem kogoś, kto naprawdę ma w ręku narzędzie, które i ja pamiętam z dzieciństwa (czyli wiertarkę z zestawu małego budowlańca), stomatolog powiedział coś w stylu: „W sumie, jak patrzę na niektórych kolegów i koleżanki innych specjalizacji, to sobie myślę, że może i dobrze, że ta cała sztuczna inteligencja ich w końcu zastąpi". Nie mogłem się wtedy odezwać, bo znowu miałem w ustach coś, co przypominało zestaw do demontażu satelity, ale myśl została: a może problem nie w tym, że AI ma zastąpić lekarzy, tylko w tym, że jakiś lekarz lub jakaś lekarka po pewnym czasie od zdania egzaminu specjalizacyjnego zaczyna dryfować w nieznane rejony medycyny? Skoro należy i jest szlachetne szukać rozwiązań nowych, jeszcze nieopisanych problemów klinicznych (oczywiście w granicach wyznaczonych przez etykę), to jak patrzeć na lekarza, który przez dziesięciolecia nie aktualizował swojej wiedzy? Opiera się na danych z przeszłości, ufa doświadczeniu („to zawsze działało"), ignorując, że stan wiedzy medycznej się zmienił. I może, bez świadomości, ale za to z pełnym przekonaniem, popełniać błędy, które kiedyś nie były błędami. To właśnie dryf: odklejenie się od rzeczywistości, które grozi nie tylko lekarzom, ale nam wszystkim bez wyjątku. I AI też.

Zawsze jest dryf

Każdy lekarz zna to uczucie, kiedy coś „nie gra". Pacjent niby ten sam, objawy znajome, wyniki podobne, a intuicja mówi: „to nie jest to, co myślisz". Tymczasem AI jest pozbawiona takiego instynktu i w takich sytuacjach pojawia się zazwyczaj problem. W świecie AI takie mało romantyczne zjawisko nazywa się dryfem (*data drift*, *model drift*), czyli powolnym odklejaniem się modelu od rzeczywistości, którą miał opisywać[1]. Dryf to zjawisko polegające na stopniowym pogarszaniu się skuteczności modelu AI wskutek zmian w zakresie danych, na których został zbudowany. Innymi słowy: model AI wytrenowany w określonym momencie historycznym traci zgodność z rzeczywistością (zaczyna „żyć w przeszłości" – jakby dotknięty cyfrowym alzheimerem), ponieważ zmienia się rozkład danych lub relacja między danymi a wynikami. W praktyce oznacza to, że system podejmuje coraz mniej trafne decyzje, mimo że formalnie działa „poprawnie". Najpopularniejsze obecnie modele AI opierają się na głębokich sztucznych sieciach neuronowych z bilionami parametrów[2], trudno zatem bezpośrednio powiązać dane wejściowe modelu z jego odpowiedzią. W konsekwencji w kontekście takich modeli AI często pojawia się termin „czarna skrzynka" (*black box*), który odzwierciedla fakt, że wewnętrzne procesy decyzyjne są trudne albo nawet niemożliwe do zrozumienia lub wyjaśnienia[3]. Stwarza to poważne niebezpieczeństwo, bo zazwyczaj dryf nie przychodzi nagle i nie jest jak awaria komputera, który nagle wyświetla niebieski ekran z alertami przypominającymi magiczne zaklęcia. Model nadal działa, nie zgłasza błędów, ale jego użytkownik nie wie, że decyzje AI coraz mniej pasują do świata, który się zmienił.

Ten sam pacjent, obraz inny, czyli o dryfie danych wejściowych

Dryf danych wejściowych (*input data drift*), zwany też w literaturze *covariate shift*, to sytuacja, w której zmieniają się właściwości danych trafiających do modelu AI[1,4-6]. W praktyce oznacza to, że model nadal działa, ale jego „świat" wygląda inaczej niż ten, na którym był trenowany. Najczęściej winni są nowi ludzie (jak zwykle ludzie – najsłabsze ogniwo AI), nowe urządzenia (czyli ludzie, którzy je tworzą), nowe zasady organizacji pracy w jednostce albo aktualizacja wytycznych (jedne i drugie oczywiście aktualizowane przez ludzi).

Zacznijmy od sprzętu. Wystarczy spojrzeć na tomografię komputerową (TK): każdy producent ma własny model urządzenia, własny protokół akwizycji oraz unikatowy sposób rekonstrukcji i przetwarzania obrazu. Doświadczeni radiolodzy bez problemu potrafią rozpoznać, z którego tomografu (a czasami nawet z którego szpitala) pochodzi zdjęcie, bo dwa obrazy tej samej klatki piersiowej wykonane w różnych jednostkach mogą się różnić kontrastem, rozdzielczością czy poziomem szumu. A jeśli algorytm był uczony tylko na sprzęcie jednego rodzaju albo w ograniczonym zestawie protokołów, to np. po aktualizacji oprogramowania model może mieć mniejszą skuteczność, a w skrajnych przypadkach przestać działać. Nie dlatego, że się „zepsuł", tylko dlatego,

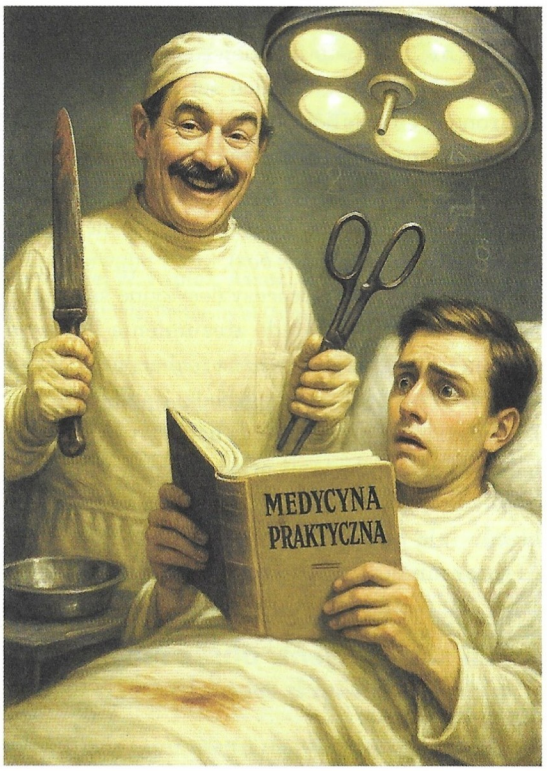

że rzeczywistość, którą ogląda, ma inny odcień szarości na ekranie. Innym źródłem dryfu jest zmiana populacji pacjentów. Załóżmy, że grupa badawcza z pewnego znanego uniwersytetu stworzyła rewelacyjny model AI, a do jego zbudowania wykorzystała dane z zaprzyjaźnionego szpitala uniwersyteckiego albo specjalistycznej kliniki w sąsiednim hrabstwie. Model został opracowany zgodnie ze sztuką budowania modeli AI, wyniki zaprezentowano na międzynarodowych konferencjach w odległych krajach, opublikowano w prestiżowych czasopismach z rzetelnym procesem recenzji (tak, istnieją jeszcze takie), a zespół badawczy otrzymał bezproblemowo finansowanie na wdrożenie rozwiązania w praktyce. Dzięki mitycznej współpracy uczelni z przemysłem model trafia do codziennego użytku w szpitalach w całym kraju. I wtedy pojawia się zgrzyt – pacjenci szpitala powiatowego wyglądają inaczej: są nieco starsi od tych z wielkiego miasta, częściej mają choroby współistniejące, inaczej opisują objawy itd. Model, wytrenowany na danych „wielkomiejskich", zaczyna się gubić. Jego bezradność wywołuje radość i sarkastyczne komentarze obsługującego go personelu: „Taki był ładny, amerykański, szkoda, he, he, he...". Każdy model AI ma tendencję do powielania wzorców, których się nauczył z danych użytych do jego stworzenia[3]. Jeśli więc zbudowano go z niewystarczająco różnorodnych danych, nie będzie potrafił poprawnie analizować przypadków, w których zmieniły się właściwości wejściowe.

Co ciekawe, nawet populacja pacjentów w tej samej placówce potrafi się zmienić[1]. Wystarczy, że szpital miejski połączy się z kilkoma przychodniami w okolicy, i nagle zmienia się demografia całego systemu. Albo otwarcie nowego połączenia lotniczego do lokalnego kurortu sprawia, że do izby przyjęć trafiają turyści o zupełnie innej charakterystyce zdrowotnej. W takich sytuacjach zmieniają się dane wejściowe, czyli pacjenci. Różnią się pod względem wieku, płci czy pochodzenia etnicznego od osób, na których wytrenowano model. Dla algorytmu to niby wciąż „pacjent", ale dla statystyki to już zupełnie inna populacja – i właśnie wtedy zaczyna się powolny dryf modelu.

Jeszcze większy chaos może wprowadzić to, czego nikt nie potrafi przewidzieć, np. nowe wytyczne refundacyjne ministra zdrowia, który właśnie odkrył w budżecie „niewykorzystane środki" (albo raczej ich brak) i otworzył zapisy do kolejki na badania przesiewowe na rok 2038. W efekcie pewna grupa chorych zamiast pojawić się w gabinecie lekarza niezwłocznie, spędza czas w bibliotece, wertując zapiski średniowiecznych mnichów w sekcji „choroby nie do wyleczenia, ale ciekawe". Tak zmienia się populacja pacjentów, którą widzi model AI.

Problem dryfu danych wejściowych może wywołać nawet zwykła aktualizacja oprogramowania po wizycie introwertycznych informatyków, którzy z dobrego serca „ulepszyli system". Zmiana wersji zapisu danych elektronicznych, nowa jednostka miary, każda drobna modyfikacja sprawia, że dane wejściowe zaczynają wyglądać inaczej. Model widzi liczby[7], nie kontekst, więc z jego perspektywy „zepsuł mu się świat, coś jest z nim nie tak"[8].

W skrócie: dryf danych wejściowych to sytuacja, w której model wciąż widzi pacjentów, ale już ich nie rozpoznaje. To trochę jak lekarz, który wraca z długiego urlopu i orientuje się, że pacjenci mówią w nowym dialekcie, laboratorium zmieniło spo-

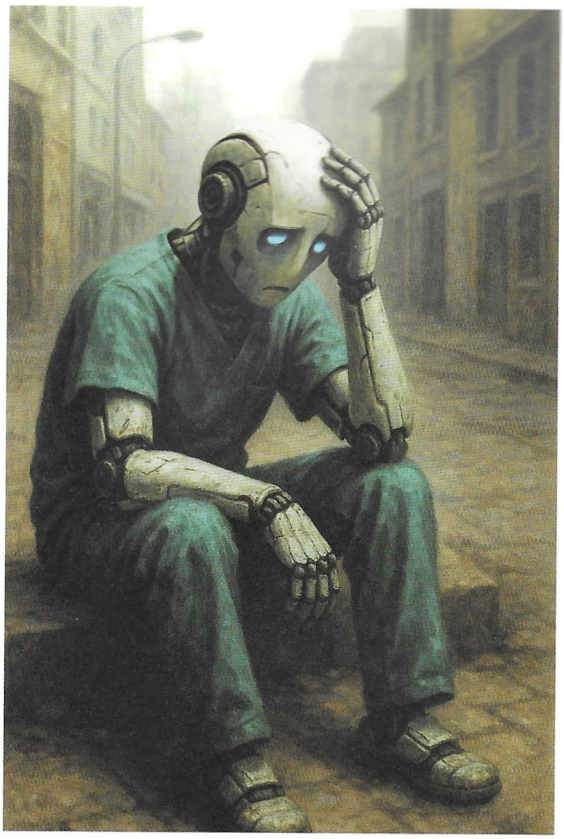

sób zapisu wyników, a nowy sprzęt diagnostyczny ma inny rozkład przycisków i dodatkowo nie są one podpisane po polsku, a producent zapomniał przygotować stosowną instrukcję. Na pozór gabinet i wszystko wokół wygląda znajomo, w istocie jednak nic już nie działa tak samo.

Kryzys tożsamości, czyli o dryfie danych wyjściowych

Label drift (czyli dryf opisu, dryf danych wyjściowych) występuje wtedy, gdy zmienia się definicja tego, co model ma przewidywać. Innymi słowy – to nie dane wejściowe (pacjenci) „wariują", ale sam sens opisu (np. to, co dolega pacjentom), czyli pojęcia stanowiące dla modelu punkt odniesienia[4,9]. Dla człowieka przypomina to sytuację, w której komisja maturalna zmienia pytania egzaminacyjne, a abiturient, którego zamiast myślenia nauczono tylko jednej odpowiedzi na pamięć, odpowiada wciąż według starego klucza („bo wielkim poetą był") z przekonaniem, że idzie mu świetnie.

W medycynie źródła tego zjawiska są zaskakująco proste i, niestety, bardzo częste, bo definicje chorób, wytyczne i systemy klasyfikacji (i refundacji) nieustannie ewoluują. Zmieniają się definicje wyników klinicznych, np. to, co wczoraj uznawano za „ponowną hospitalizację", dziś może być klasyfikowane inaczej, bo nowe wytyczne uwzględniają inne kryteria czasu lub przyczyny przyjęcia. Zmieniają się też same kryteria diagnostyczne chorób: graniczne wartości dla cukrzycy, nadciśnienia tętniczego czy otyłości bywają aktualizowane częściej, niż niektórzy lekarze logują się do portalu edukacyjnego albo przeglądają „Medycynę Praktyczną". Czasem wystarczy jedna zmiana w normach laboratoryjnych lub sposób zaokrąglenia wyniku, by próg decyzyjny, który rozstrzyga, czy pacjent jest chory, czy zdrowy, przesunął się o kilka punktów. W efekcie model, który był trenowany na dawnych definicjach, zaczyna prognozować coś zupełnie innego, choć z pełnym przekonaniem, że robi to dobrze.

Kolejnym źródłem *label drift* mogą być zmiany w systemach kodowania. Przejście z ICD-9 na ICD-10 pozbawiło wiele opisów (diagnoz) bezpośrednich odpowiedników. Dla człowieka to tylko inna rubryka w formularzu, ale dla modelu – kompletny kryzys tożsamości. Część kodów zniknęła, inne połączyły się w nowe kategorie, jeszcze inne rozdzielono na podtypy. Dla algorytmu, który nauczył się, że 250.00 to cukrzyca typu 2 w systemie ICD-9, nagłe pojawienie się kodów E11 w ICD-10 i podtypów E11.0–9 to nie drobiazg, to diagnostyczna apokalipsa. Do tego dochodzą innowacje w polityce zdrowotnej: nowe wskaźniki jakości, inne definicje sukcesu terapeutycznego, modyfikacje kryteriów refundacji i wszystkie inne zmiany, które powodują przyspieszone łysienie lub siwienie dyrektora(-ki) szpitala. Każda decyzja administracyjna sprawia, że model, który kiedyś działał perfekcyjnie, nagle przechodzi kolejny kryzys egzystencjalny, nie dlatego, że źle liczy, tylko dlatego, że ktoś zmienił reguły gry i nie wiadomo już, co jest kryterium wygranej. Wbrew pozorom nie jest to problem czysto techniczny, ale realne konsekwencje kliniczne *label drift*. Model przestaje rozumieć, co właściwie ma klasyfikować, więc jego wskazania coraz dalej odbiegają od oczekiwań lekarzy. Czasem system nadal podaje „popraw-

ne" liczby, ale ich interpretacja kliniczna staje się błędna. Lekarz ufa wynikom, bo przecież model ma 94% trafności, tylko że trafność oceniono według starej definicji. Tak rodzi się nowa forma błędu poznawczego: techniczna pewność w świecie zmiennych znaczeń.

W skrócie: *label drift* to moment, w którym model nadal przewiduje z całkowitą pewnością, tyle że coś innego, niż zakładamy. To trochę jak lekarz, który z powagą diagnozuje *plica polonica* (kołtun), mimo że świat medycyny już dawno odrzucił istnienie takiej jednostki chorobowej. Model ma więc rację – ale w świecie, który przestał istnieć. A najgorsze jest to, że on nawet nie wie, że nie nadąża.

Kiedy logika choruje, czyli o dryfie pojęciowym

Concept drift (czyli dryf pojęciowy) występuje wtedy, gdy zmienia się relacja między danymi wejściowymi (np. objawami klinicznymi) a danymi wyjściowymi, czyli znaczeniem klinicznym (diagnoza), a więc między tym, co model „widzi", a tym, co ma przewidzieć. Innymi słowy: świat nie tylko się starzeje, ale też zaczyna działać na innych zasadach i zgodnie z inną logiką. Można to porównać do sytuacji, w której wszystkie puzzle pozostały te same, ale ktoś podmienił obrazek na pudełku. Model, który kiedyś rozumiał świat doskonale, nagle zaczyna widzieć wszystko nie tak, jak trzeba.

W medycynie to zjawisko jest niemal nieuniknione, bo wiedza w tej dziedzinie zmienia się szybciej niż ministrowie zdrowia. Każde nowe odkrycie naukowe, każda publikacja, każda zmiana wytycznych wpływa na sposób, w jaki lekarze (a przynajmniej ci, którzy zrozumieli mechanizm choroby lub mechanizm działania leku, a nie tylko nauczyli się odpowiedzi na pytania egzaminacyjne) rozumieją relacje między objawami, badaniami a diagnozą. W świecie AI wystarczy jednak wprowadzić nowe standardy postępowania, a cała siatka logiczna, na której opierał się model AI, traci aktualność. Kiedyś zwiększone stężenie troponiny sercowej jednoznacznie wskazywało na zawał, dziś może oznaczać znacznie więcej – od ostrego zespołu wieńcowego po stres fizjologiczny po przebytym maratonie[10]. Dla lekarza to sygnał „pomyśl, patrz szerzej", dla modelu AI informacyjny szum,



w którym nie może się odnaleźć, bo nie rozumie (jeszcze?) mechanizmów. Innym przykładem są zmiany w leczeniu. Gdy pojawia się nowa terapia, zmieniają się efekty leczenia, a wraz z nimi relacja między danymi wejściowymi (np. wynikiem badania, profilem biochemicznym pacjenta) a prognozowanym wynikiem (rokowaniem). Model, który uczył się na danych sprzed dekady, może nie rozumieć, że pacjent po nowoczesnym leczeniu nie reaguje tak samo jak ten, który był leczony klasycznym sposobem.

Jeszcze większy chaos wprowadzają nowe technologie, dokładniejsze obrazowanie, diagnostyka molekularna, sztuczne narządy, systemy ciągłego monitorowania chorób czy naszej aktywności. Dla modelu to zupełnie inny świat, bo mimo że liczby – jak to liczby – mogą wyglądać podobnie, ich znaczenie (a tym samym diagnoza, leczenie) może być zupełnie inne.

Concept drift nie dotyczy wyłącznie wiedzy i technologii, dotyka też samego człowieka. Zmienia się populacja pacjentów, ich styl życia, spo-



sób korzystania z systemu ochrony zdrowia i to, co kiedyś było objawem rzadkim, dziś staje się codziennością (np. depresja czy otyłość), a inne choroby niemal znikają z pola widzenia (wspomniany wcześniej kołtun). Model wytrenowany na danych sprzed kilku lat może się więc „spodziewać" chorób, które w populacji już nie występują, albo nie zauważać tych, które dopiero zaczynają dominować. To trochę jak stary internista, który wciąż mówi o durze brzusznym, ale nie może pojąć, skąd się biorą te wszystkie pacjentki z zespołem policystycznych jajników i smartwatchem na ręku.

Do *concept drift* prowadzi też rozwój diagnostyki i zmian w samym języku medycyny. Jeszcze dekadę temu „udar mózgu" był kategorią jednorodną, dziś dzieli się na liczne podtypy o różnych mechanizmach i zróżnicowanym leczeniu. Model uczony na prostych zależnościach „objaw–rozpoznanie–wynik" traci orientację w świecie, w którym granice między niektórymi jednostkami chorobowymi stają się płynne. Nie jest to jego wina – po prostu nauczył się świata, którego już nie ma.

Pojawienie się nowej choroby, której nie ma w zasobie danych modelu, to najbardziej dramatyczna forma *concept drift*. Świat się zmienia, ludzie zaczynają chorować „inaczej", a model wciąż patrzy na rzeczywistość przez okulary sprzed epoki. Brakuje mu nowej etykietki (*label*) nie dlatego, że ktoś zapomniał ją wpisać, tylko dlatego, że nikt jeszcze jej nie wymyślił. Tak było na początku pandemii COVID-19: algorytmy analizujące radiogramy i TK klatki piersiowej widziały zmiany zapalne, ale nie miały pojęcia, że oto pojawiła się nowa choroba. Dla nich to było po prostu „zapalenie płuc" jak każde inne. Z czasem, gdy nowa jednostka chorobowa dostała nazwę, kod i własne miejsce w systemie klasyfikacji, problem nie zniknął, tylko się zmienił. Teraz dane wejściowe wyglądały znajomo, ale etykieta była nowa. To już nie był *concept drift*, lecz klasyczny *label drift*: zmienił się słownik świata, a model wciąż mówił starym językiem. W efekcie AI diagnozowała z przekonaniem, ale niezgodnie z rzeczywistością. Można powiedzieć, że model „miał rację" – tyle tylko że w świecie, w którym COVID-19 jeszcze nie istniał.

W skrócie: *concept drift* to sytuacja, w której model nie tyle się „psuje", ile traci orientację w świecie, który przestał funkcjonować według dawnych zasad. To jak lekarz, który pamięta wszystkie podręcznikowe zależności, ale od dekady nie był na konferencji szkoleniowej i dziwi się, że nowy lek działa, mimo że „według starej farmakologii" nie powinien.

Panta rhei, czyli wszystko dryfuje – ale dokąd?

Heraklit twierdził, że nie da się wejść dwa razy do tej samej rzeki. Gdyby żył dziś, pewnie dodałby, że nie da się też dwa razy uruchomić tego samego modelu AI, bo rzeka danych już dawno zmieniła nurt. Wszystko płynie, a AI płynie razem z nami, tylko często w zupełnie inną stronę. Dryf w medycynie może wynikać z rutyny, przekonania o własnej nieomylności albo, zwyczajnie, z braku czasu na naukę. W AI to zmiana rozkładu danych, nowych protokołów, nowych definicji chorób. W obu przypadkach efekt jest ten sam – decyzje, które kiedyś były słuszne, dziś prowadzą w złą stronę. Modele AI, nawet te najbardziej imponujące, rzadko psują się spektakularnie, nie wybuchają, nie dymią, nie wyrzucają błędu na ekranie kompute-

ra. One po prostu zaczynają dryfować. Najpierw delikatnie – a to trochę inne dane wejściowe, nieco odmienna populacja pacjentów, nowy aparat diagnostyczny i mamy dryf danych wejściowych. Jeśli zmieniają się definicje i normy, model wciąż coś przewiduje, tylko nie to, co myślimy, i mamy dryf danych wyjściowych. Wreszcie pojawia się nowa wiedza, nowa choroba, nowa terapia i stary model AI staje się jak lekarz, który nie zauważył, że świat wymyślił antybiotyki. *Concept drift* niesie najgorsze konsekwencje: kiedy zmienia się logika świata, model AI, choć w pełni sprawny, nadal próbuje diagnozować i leczyć w rzeczywistości, która już nie istnieje.

Ale może to nie tylko problem maszyn. Może my, ludzie, dryfujemy tak samo. Lekarze, którzy nie aktualizują wiedzy, instytucje, które nie nadążają za zmianą i podejmują decyzje na podstawie danych sprzed dekady – wszystko to ten sam proces dryfowania. Sztuczna inteligencja nie jest wyjątkiem, tylko lustrem, w którym odbija się nasza rzeczywistość. *Panta rhei* – wszystko dryfuje: dane, definicje, wytyczne, choroby i my sami. A skoro wszystko dryfuje, jedynym sposobem, by nie odpłynąć za daleko albo nie zostać na mieliźnie, jest ciągłe sprawdzanie, gdzie jesteśmy, żeby się nie obudzić pewnego dnia w miejscu, gdzie nic nie ma sensu. Dlatego właśnie zapraszamy do udziału online w konferencji „Artificial Intelligence in Medicine", która odbyła się w Krakowie 7–9 maja 2026 roku (https://piebm.org/events/artificial-intelligence-in-medicine-2026/), po to, aby sprawdzić, dokąd dryfuje medycyna, zanim naprawdę odjedzie nam peron.

PIŚMIENNICTWO

1. Finlayson S.G., Subbaswamy A., Singh K. i wsp.: The clinician and dataset shift in artificial intelligence. N. Engl. J. Med., 2021; 385: 283–286
2. Papież B.W.: Historia sztucznej inteligencji. Med. Prakt. Ginekol. Położ., 2025; 1: 101–111
3. Papież B.W.: Pokaż, kotku, co masz w środku, czyli co sztuczna inteligencja ma na myśli. Med. Prakt. Ginekol. Położ., 2025; 4: 99–105
4. Sahiner B., Chen W., Samala R.K., Petrick N.: Data drift in medical machine learning: implications and potential remedies. Br. J. Radiol., 2023; doi:10.1259/bjr.20220878
5. Kore A., Abbasi Bavil E., Subasri V. i wsp.: Empirical data drift detection experiments on real-world medical imaging data. Nat. Commun., 2024; doi:10.1038/s41467-024-46142-w
6. Wong A., Sussman J.B.: Understanding model drift and its impact on health care policy. JAMA Health Forum, 2025; doi:10.1001/jamahealthforum.2025.2724
7. Kukulska N.: Znieczulenie [do Preludium c-moll F. Chopina]. https://www.youtube.com/watch?v=spTTmH0Q4RY (dostęp: 26.10.2025)
8. Papież B.W.: Atencyjny kalkulator, czyli o tym, jak komputer nauczył się ściemniać. Med. Prakt., 2025; 10: 119–131
9. Lasko T.A., Strobl E.V., Stead W.W.: Why do probabilistic clinical models fail to transport between sites. NPJ Digit. Med., 2024; doi:10.1038/s41746-024-01037-4
10. Regwan S., Hulten E.A., Martinho S. i wsp.: Marathon running as a cause of troponin elevation: a systematic review and meta-analysis. J. Interv. Cardiol., 2010; 23: 443–450

Wszystkie ilustracje zostały wygenerowane za pomocą Microsoft Copilot.