

AI w B+R: 10 sposobow na przyspieszenie badan w firmie

Konkretne wdrozenia, mierzalne efekty i podejścia dopasowane do skali - od startupu po korporację

Piotr Załuski · 17.09.2026

Zespół badawczy Pfizera skrócił etap wstępnej selekcji kandydatów na leki z 4-5 lat do niecałych 18 miesięcy. Nie dlatego, że zatrudnił trzy razy więcej naukowców. Dlatego, że wdrożył modele uczenia maszynowego do analizy bibliotek związków chemicznych. To nie jest historia z odległej przyszłości - to 2023 rok, a efekty są już dobrze udokumentowane w literaturze branżowej.

Obserwuję ten rynek od ponad dekady - najpierw jako analityk w funduszu VC, teraz jako współzałożyciel dwóch spółek technologicznych. I widzę wyraźnie: firmy, które traktują AI w badaniach i rozwoju jako ciekawostkę do pilotażu, zostają w tyle. Te, które wdrażają konkretne narzędzia w konkretnych miejscach procesu B+R, generują realną przewagę. Poniżej zebrałem 10 obszarów, gdzie sztuczna inteligencja robi największą różnicę - z przykładami, liczbami i wskazówkami, co ma sens dla firmy jakiej wielkości.

1. Przegląd literatury i analiza stanu wiedzy

Klasyczny przegląd literatury przed startem projektu badawczego potrafi zająć tygodnie. Researcher przeszukuje bazy PubMed, Scopus, Web of Science, czyta abstrakty, segreguje źródła, wyciąga wnioski. Przy 50 000 nowych publikacji naukowych tygodniowo w samej biomedycynie - to walka z wiatrakami.

Narzędzia takie jak Elicit, Consensus czy Semantic Scholar AI pozwalają zadać pytanie badawcze w języku naturalnym i w ciągu minut otrzymać syntezę kilkuset artykułów z oceną jakości metodologicznej. Elicit potrafi wyciągnąć z papieru konkretne dane: wielkość próby, zastosowaną metodę, wynik główny. Bez czytania każdego artykułu od deski do deski.

Dla startupu deeptech z Wrocławia czy Gdańska, który nie ma budżetu na rozbudowany dział badawczy, to zmiana fundamentalna. Jeden junior researcher z dostępem do Elicit (koszt: około 10-20 USD miesięcznie) robi robotę, która wcześniej wymagała trzech seniorów i miesiąca pracy.

2. Generowanie i weryfikacja hipotez badawczych

To jeden z bardziej kontrowersyjnych obszarów - bo dotyczy sedna pracy naukowej. Ale fakty są takie: modele językowe klasy GPT-4o czy Claude 3.5 Sonnet potrafią, przy odpowiednim promptowaniu i dostępie do danych dziedzinowych, generować hipotezy badawcze, które naukowcy oceniają jako nieoczywiste i wartościowe.

Firma Insilico Medicine używa własnego systemu AI do generowania hipotez dotyczących celów terapeutycznych w chorobach rzadkich. W 2024 roku ich kandydat na lek ISM001-055 wszedł w fazę II badań klinicznych - a cały proces od identyfikacji celu do kandydata zajął 30 miesięcy i kosztował ułamek standardowego budżetu.

AI nie zastępuje intuicji naukowej. Ale potrafi przeszukać przestrzeń możliwości w tempie, które człowiek osiągnie dopiero po kilku latach intensywnej pracy w danej dziedzinie.

Dla firm spoza farmacji - analogia jest prosta. Jeśli prowadzisz B+R w materiałoznawstwie, elektronice czy chemii przemysłowej, modele językowe wytrenowane na danych dziedzinowych mogą wskazywać kierunki, które warto eksplorować. Nie zamiast eksperta - obok eksperta.

3. Automatyzacja eksperymentów i laboratoria robotyczne

Automatyzacja laboratoriów to nie nowość - roboty pipetujące działają od lat. Nowością jest warstwa AI, która zamienia te roboty w systemy uczące się i adaptujące. Tzw. self-driving labs, czyli autonomiczne laboratoria, to jeden z gorętszych trendów w nauce stosowanej.

Projekt Chem Speed w Szwajcarii czy kanadyjski Acceleration Consortium przy University of Toronto pokazują, co to oznacza w praktyce: system AI projektuje eksperyment, robot go wykonuje, AI analizuje wyniki i projektuje kolejny eksperyment - bez udziału człowieka między iteracjami. W testach materiałów fotowoltaicznych taki system przebadal w ciągu tygodnia kombinacje, które tradycyjnie zajęłyby rok.

Dla polskich firm - ten poziom wymaga inwestycji rzędu kilku milionów złotych i ma sens głównie dla dużych graczy lub konsorcjów badawczych. Ale już prostsze wersje - automatyczne planowanie eksperymentów oparte na bayesowskiej optymalizacji (np. Ax od Meta lub Optuna) - są dostępne za darmo i dają realne korzyści w każdym laboratorium z choćby podstawową infrastrukturą danych.

4. Analiza danych eksperymentalnych w czasie rzeczywistym

Tradycyjny cykl: eksperyment ? zapis danych ? analiza ? wnioski ? kolejny eksperyment. Każdy etap rozciągnięty w czasie. AI skraca ten cykl do minimum.

Narzędzia do analizy danych takie jak DataRobot, H2O.ai czy nawet dobrze skonfigurowany Python z bibliotekami scikit-learn i PyTorch pozwalają analizować dane eksperymentalne na bieżąco - wykrywać anomalie, identyfikować wzorce, sygnalizować, kiedy eksperyment zmierza w złym kierunku zanim przepalisz kolejne 48 godzin pracy.

W firmie produkcyjnej z branży chemicznej, z którą współpracowałem w 2025 roku, wdrożenie prostego systemu monitoringu opartego na ML skróciło czas od eksperymentu do decyzji o kolejnym kroku z 3 dni do 4 godzin. Pozornie mała zmiana. W skali roku - kilkadziesiąt dodatkowych cykli badawczych.

5. Modelowanie i symulacje zamiast fizycznych prototypów

Każdy fizyczny prototyp kosztuje. Czas, materiały, praca inżynierów. AI-driven simulation pozwala przetestować setki wariantów projektowych zanim cokolwiek trafi na maszynę CNC czy do drukarki 3D.

Ansys Discovery z modulem AI, Autodesk Fusion z generatywnym projektowaniem, czy specjalistyczne narzędzia jak DeepMind's AlphaFold (dla białek) lub Schrödinger's Maestro (dla farmaceutyków) - to przykłady narzędzi, które zamieniają miesiące

fizycznych testów w dni symulacji komputerowych.

BMW Group podaje, że generatywne projektowanie wspomagane AI skróciło czas opracowania komponentów strukturalnych o 50%, jednocześnie redukując masę tych elementów o 10-15%. To nie jest marketing - to dane z raportów inżynierskich.

Dla polskich firm MSP z sektora produkcyjnego: licencje na Ansys czy Siemens NX to wydatek rzędu 50 000-200 000 zł rocznie. Ale istnieją tańsze alternatywy - SimScale (od 300 USD/miesiąc) czy OpenFOAM (open source) z nakładkami AI. Kluczowe pytanie: ile kosztuje jeden fizyczny prototyp, który można zastąpić symulacją?

6. Zarządzanie wiedzą i dokumentacja badawcza

Wiedza w działach B+R ginie. Odchodzi z pracownikiem, gubi się w Excelu, leży w PDF-ie, którego nikt nie może znaleźć. To jeden z największych marnotrawstw w organizacjach badawczych.

Systemy RAG (Retrieval-Augmented Generation) oparte na modelach językowych pozwalają zbudować wewnętrzny "mózg organizacji"