

Wstęp

Sztuczną inteligencją po raz pierwszy zainteresowałem się mając... 16 lat pod koniec lat 80-tych ubiegłego wieku. Byłem wtedy szczęśliwym posiadaczem komputera marki Atari 800 XL (z 64 KB pamięci – co odpowiada mniej więcej 32 stronom maszynopisu bez jakiegokolwiek grafiki). Zastanawiałem się wtedy czy można by napisać oprogramowanie, które potrafiłoby komunikować się z człowiekiem w języku naturalnym za pomocą czata tekstowego. Pomysł narodził się z obserwacji jednej z gier komputerowych, gdzie gracz mógł wydawać polecenia sterowanej przez siebie postaci, za pomocą prostych poleceń tekstowych. Pomysłu tego nie udało mi się zrealizować ze względu na ograniczone wtedy możliwości techniczne komputera, którym dysponowałem oraz brakiem odpowiedniej wiedzy. Wiele lat później, mniej więcej na przełomie XX i XXI wieku, zobaczyłem w Internecie chatbota - to było olśnienie. Zobaczyłem, jak program potrafi prowadzić konwersację z użytkownikiem i to w języku naturalnym! Miał oczywiście wiele wad, często nie potrafił właściwie zareagować lub udzielał błędnych odpowiedzi. Wydarzenie to stało się przełomem w moim życiu zawodowym. Postanowiłem skierować swoją karierę w kierunku sztucznej inteligencji. Okazja pojawiła się w roku 2003, kiedy dla jednej z korporacji finansowych rozpocząłem, jako zewnętrzny konsultant, realizację projektu mającego optymalizować procesy w zarządzaniu działem handlowym. Jednym z problemów, z którym borykała się ta firma było zarządzanie kilkunastoma bazami potencjalnych klientów przedsiębiorstwa. W korporacji istniała bowiem zasada, iż zanim handlowiec będzie mógł zająć się danym klientem, musiał on zweryfikować czy już ktoś inny się tym klientem nie zajmuje, czy klient nie jest obsługiwany korporacyjnie lub też czy nie znajduje się tak zwanej „czarnej liście”. Firma nie posiadała wtedy centralnego systemu CRM w związku

z czym cały proces był realizowany ręcznie przez specjalnie do tego przeszkoloną osobę. W skrócie proces polegał na tym, że korzystając z funkcji „kopiuj” i „wklej” oraz „szukaj” były weryfikowane poszczególne kontakty (lead) wysyłane przez handlowców. Problem w tym, że dane które wysyłali handlowcy były niepełne, często nie zawierały żadnych danych identyfikacyjnych takich jak numer regon czy numer NIP, a nazwy były niepełne lub też zawierały błędy. Wyzwaniem stało się więc napisanie oprogramowania, które w jakiś sposób zautomatyzuje ten proces. Tak powstał pierwszy system oparty o przetwarzanie języka naturalnego, którego stałem się autorem. Rozwiązanie to umożliwiło wyszukiwanie podmiotów, które choć miały niepełne dane lub dane były zapisane w różny sposób, to potrafiło w dość precyzyjny sposób je ze sobą powiązać. Po uruchomieniu systemu okazało się, że udało nam się skrócić zaangażowanie czasowe osoby, która realizowała ten proces z 40 godzin w tygodniu do raptem... 4. Był to duży sukces i podjąłem wtedy decyzję, że chcę zajmować się sztuczną inteligencją na pełen etat. I tak, w 2007 roku, na wiele lat przed pojawieniem się na rynku słynnego już ChatGPT, zawiązałem spółkę Stanusch Technologies, której celem było tworzenie chatbotów. W ciągu 17 lat wziąłem udział w ponad 300 różnych projektach zarówno komercyjnych, badawczo rozwojowych jak i weryfikacji koncepcji (proof-of-concept). To było zebranie niesamowitego doświadczenia i weryfikacja słuszności pomysłu biznesowego. Dziś, kiedy sztuczna inteligencja stała się niemal wszechobecna, chciałbym się z Tobą, Drogi Czytelniku, tą wiedzą podzielić. Dlaczego? Bo sztuczna inteligencja zmieni całkowicie świat biznesu. Zmiana będzie totalna. Firmy, które nie nauczą się wykorzystywać sztucznej inteligencji zostaną wyparte z rynku. Ten proces już się rozpoczął i zaczyna toczyć się coraz szybciej. Dziś, kiedy komputery są milion razy potężniejsze niż w latach 80tych¹, a w powiązaniu z nieograniczonymi zasobami mocy obliczeniowej

¹ Komputer, na którym piszę (a właściwie to dyktuję) ten tekst posiada 64 Gigabajty pamięci – jest więc dokładnie milion razy „pojemniejszy” od mojego pierwszego

w chmurze, zaczynają realizować coraz więcej zadań, które do tej pory były zarezerwowane tylko dla ludzi. Najlepszym przykładem ilustrującym potęgę sztucznej inteligencji jest realizacja tak intelektualnej czynności jak pisanie książki. Książka, którą trzymasz w ręku w dużej mierze powstała przy pomocy i współpracy ze sztuczną inteligencją. Zbieranie pomysłów, materiałów, analiza a częściowo nawet redakcja odbywała się z wykorzystaniem narzędzi sztucznej inteligencji. Oczywiście musiałem wiedzieć czego chcę, co ma znaleźć się w treści oraz potrafić zweryfikować otrzymane wyniki, ale cały proces odbył się co najmniej kilka razy szybciej niż gdybym chciał wykonać to zadanie od zera, manualnie. Pierwszy szkielec książki powstał raptem w kilka godzin a najwięcej czasu zajęła redakcja (ludzka) ostatecznej wersji tekstu. Cały proces – od pomysłu, do wysłania książki do drukarni zajął ok. 120 godzin...

Książkę tę napisałem po to, żeby podzielić się moimi doświadczeniami i zainspirować do rozpoczęcia procesu decyzyjnego na temat tego co można zrobić w niemal każdym przedsiębiorstwie, gdzie sztuczna inteligencja mogłaby pomóc, przyspieszyć, zoptymalizować lub po prostu ograniczyć koszty.

Zapraszam do lektury!

komputera nie licząc 2 terabajtów pamięci na twardych dyskach (w porównaniu z kasetą magnetofonową stanowiącą „pamięć masową” mojego Atari o pojemności ok. 130 KB).

Rozdział 1: Początki i ewolucja sztucznej inteligencji

1.1 Test Turinga i marzenie o inteligentnych maszynach

Pamiętacie film „Gra tajemnic” (tytuł oryginału: *Imitation Game*) w reżyserii Mortena Tyldum’a z Benedictem Cumberbatch’em w roli głównej z 2014 roku? Film opowiada tragiczną historię genialnego brytyjskiego matematyka Alana Turinga – jednego z głównych członków zespołu łamiącego niemiecką maszynę szyfrującą Enigmę². Co ma więc wspólnego tytuł „Imitation Game” z rozszyfrowywaniem Enigmy i rolą Alana Turinga w tym procesie? Prace nad złamaniem kodu Enigmy oraz maszynami deszyfrującymi były objęte najwyższym poziomem bezpieczeństwa i absolutną tajemnicą wojskową. Proces odtajniania dokumentów oraz roli jaką miał Alan Turing w tych pracach rozpoczął się dopiero w 1982 roku. A jednak Alan Turing w świecie matematyki i informatyki jest niemal postacią kultową — dzięki niemu mamy

² Kod Enigmy tak naprawdę został złamany przez polskich matematyków: Mariana Rejewskiego, Henryka Zygalskiego oraz Jerzego Różyckiego już w roku 1932(!). Opracowali oni również metodę i maszynę, dzięki której można byłoby złamać szyfr – tzw. „bomby” – niestety budżet Biura Szyfrów Wojska Polskiego nie pozwalał na rozbudowę projektu i ostatecznie plany „bomby” oraz samą maszynę szyfrującą zdobyłą przez polski wywiad przekazano wywiadowi brytyjskiemu. W dniach 25-26 lipca 1939 roku w Pyrach pod Warszawą odbyła się konferencja polskich, brytyjskich i francuskich kryptologów, podczas której polscy matematycy wytłumaczyli działanie Enigmy i maszyn deszyfrujących oraz zaprezentowali swoje umiejętności kryptograficzne. Informacje te zostały wykorzystane do stworzenia maszyny deszyfrującej tzw. „bomby Turinga” – to właśnie ta maszyna została zaprezentowana we wspomnianym filmie.

współczesny komputer, a swoją sławę zawdzięcza właśnie wspomnianej „Imitation Game” – ale po kolei.

Komputery i pytanie: „czy mogą one myśleć?”

Turing jako matematyk był już znany w latach trzydziestych ubiegłego wieku. W 1936 roku, mając zaledwie 24 lata, napisał swoją najważniejszą pracę z dziedziny matematyki „On Computable Numbers, With an Application to the Entscheidungsproblem”, w której zaproponował abstrakcyjną koncepcję maszyny obliczeniowej wyposażonej w program – ciąg instrukcji osadzonych w pamięci – przy czym rolę pamięci miała pełnić taśma z zapisanymi instrukcjami oraz parametrami programu. Dziś koncepcję tę znamy jako tzw. „uniwersalna maszyna Turinga” i według niej zbudowane są wszystkie współczesne komputery (z wyjątkiem komputerów kwantowych). W czasach, kiedy Turing pisał swój artykuł, nie istniały techniczne możliwości zbudowania takiej maszyny obliczeniowej. Jednak wybuch II Wojny Światowej przyspieszył prace nad tworzeniem maszyn, które w pewnym sensie automatyzowały obliczenia oraz tzw. przekształcenia symboli (niezbędne do łamania kodów Enigmy). Urządzenia te były oparte na przekaźnikach elektromagnetycznych. Testowano również użycie lamp próżniowych. Prace te ostatecznie doprowadziły do powstania w połowie lat 40. XX wieku pierwszych komputerów opartych o wskazane przez Turinga założenia.


Powstanie komputerów – maszyn, które znacznie przewyższały zdolności człowieka w obszarze arytmetyki – doprowadziło do coraz częściej zadawanego pytania: „Czy maszyna może myśleć?”. Czy kiedyś komputer będzie myślał jak człowiek, rozwiązywał problemy, grał w szachy lub czy stanie się kreatywny? W październiku 1950 roku, Turing w czasopiśmie „Mind” opublikował swój bodajże najsłynniejszy artykuł „Computing Machinery and Intelligence”. To właśnie dzięki niemu Turing jest dziś tak znany. Postanowił on raz na zawsze „rozwiązać” problem myślących maszyn.

Na wstępie artykułu Turing zawarł tezę, że postawione pytanie „Czy maszyny mogą myśleć?” jest w istocie pozbawione sensu – gdyż komputery nigdy, wg autora, nie będą myśleć w sposób znany człowiekowi, ponieważ działanie komputera oparte jest na innych zasadach³. Czy jednak będą one myśleć w ogóle? W jaki sposób się o tym przekonać? Jak sprawdzić, czy maszyna myśli? Matematyk doszedł do wniosku, że jedyną metodą będzie obserwacja „zachowania” takiej maszyny - jeżeli uznamy, że nie będziemy w stanie odróżnić jej zachowania od zachowania człowieka, to taką maszynę będziemy mogli uznać za myślącą⁴. I tu zbliżamy się do wyjaśnienia tytułu wspomnianego filmu - Turing wpadł na genialny w swojej prostocie pomysł. Przed II wojną światową, w Wielkiej Brytanii, grano w bardzo popularną grę towarzyską – „Imitation game”.

W grze brały udział trzy osoby: kobieta, mężczyzna oraz „sędzia”, którym mogła być dowolna inna osoba (rys. 1). Kobieta i mężczyzna zamykali się w oddzielnych pokojach, w taki sposób, aby sędzia nie wiedział, w którym pokoju znajduje się kobieta, a w którym mężczyzna. Zabawa polegała na tym, że sędzia mógł zadawać każdej osobie dowolne pytania, które przekazywał w formie pisanej na karteczkach podawanych pod drzwiami. Kobieta i mężczyzna odpowiadali na te pytania, również w formie pisemnej. Zadanie „sędziego” polegało na tym, by odgadnąć, kto jest kobietą, a kto mężczyzną.


³ Kiedy Turing pisał artykuł nie istniały jeszcze sztuczne sieci neuronowe, których działanie przypomina działanie ludzkiego mózgu. Pierwszą sztuczną siecią neuronową był Perceptron opracowany Franka Rosenblatta w roku 1958 (patrz rozdział 1.2). Dziś pewne zadania poznawcze realizowane przez komputery, jak rozpoznawanie mowy, obrazów czy wzorców zachowań opiera się właśnie na symulacji działania neuronów i tzw. uczenie maszynowe.

⁴ Lata pięćdziesiąte były czasem triumfów psychologii behawioralnej, która przede wszystkim badała zewnętrzne czynniki procesów umysłowych – czyli zachowania. Wydaje się, że nurt ten mocno wpłynął na poglądy Turinga i jego ostateczny pomysł, jak zweryfikować, czy maszyna może myśleć.



Rys. 1. Oryginalna koncepcja gry w naśladownictwo
 źródło: https://en.wikipedia.org/wiki/Turing_test

Turing wpadł na pomysł, aby jedną z osób zastąpić komputerem. Zadanie sędziego polegałoby na tym, aby zidentyfikować, kto jest człowiekiem, a co jest maszyną (rys. 2).



Rys. 2. Gra w naśladownictwo z komputerem w roli jednej z osób
https://en.wikipedia.org/wiki/Turing_test

Turing zaproponował, aby komunikacja odbywała się za pomocą tzw. dalekopisu zamiast ręcznie pisanych pytań i odpowiedzi (wtedy nie było

Internetu!). Zasugerował nawet uproszczenie „testu”, eliminując człowieka jako drugiego gracza. W takim przypadku sędzia miałby za zadanie jedyne zidentyfikowanie czy komputer po drugiej stronie jest na tyle przekonujący, iż jego odpowiedzi (zachowania / reakcje) są nieodróżnialne od odpowiedzi (zachowań / reakcji) człowieka. Gdyby komputer stał się nie do odróżnienia od człowieka w ocenie innego człowieka, to moglibyśmy uznać, że taki komputer na swój sposób myśli.

Test Turinga wyznaczył pierwszy krok na drodze do stworzenia maszyn potrafiących prowadzić rozmowy, odpowiadać na pytania, a nawet uczyć się na podstawie zebranych danych. Stanowił ideowe podłoże dla późniejszych badań w dziedzinie przetwarzania języka naturalnego (ang. Natural Language Processing, NLP), które dziś umożliwia chatbotom i voicebotom przeprowadzanie złożonych interakcji z użytkownikami.

Od czasów Turinga marzenie o stworzeniu maszyn zdolnych do myślenia, uczenia się i działania w sposób inteligentny przenika całą dziedzinę sztucznej inteligencji (ang. Artificial Intelligence, AI). Idea inteligentnych maszyn początkowo wydawała się ograniczać do literatury science fiction, ale wraz z postępem technologicznym stała się realnym celem naukowców i inżynierów na całym świecie.

W latach 50. i 60. XX wieku, naukowcy zaczęli eksperymentować z algorytmami zdolnymi do wykonywania określonych zadań, takich jak gra w szachy czy rozwiązywanie problemów logicznych. Choć pierwsze „inteligentne” programy były bardzo proste, to jednak pokazały, że maszyny mogą wykonywać zadania, które wcześniej uznawano za zarezerwowane wyłącznie dla ludzi.

Marzenie Turinga o maszynach, które mogą komunikować się na równi z ludźmi, współcześnie wciąż napędza badania nad AI. Dzisiejsze systemy, takie jak chatboty i voiceboty, choć nie są jeszcze w pełni „inteligentne” w ludzkim rozumieniu, potrafią symulować wiele aspektów ludzkiego dialogu. Dzięki zaawansowanym algorytmom uczenia maszynowego i przetwarzania języka naturalnego, są one zdolne do rozumienia kontekstu, intencji i emocji zawartych w wypowiedziach użytkowników.

Dziś Test Turinga nadal stanowi inspirację i punkt odniesienia w dyskusjach na temat sztucznej inteligencji. W dobie zaawansowanych modeli językowych, takich jak ChatGPT, Google Gemini czy Claude.ai, które mogą generować odpowiedzi na wiele różnych tematów, pytanie o to, czy maszyna może „myśleć” jak człowiek, staje się bardziej skomplikowane. Chociaż obecne systemy AI potrafią prowadzić złożone konwersacje, wciąż istnieją wyzwania związane z prawdziwym rozumieniem i kreatywnością, które odróżniają ludzką inteligencję od maszynowej symulacji.


Test Turinga, choć może nie być już ostatecznym miernikiem inteligencji maszyn, wciąż inspiruje badaczy do rozwijania systemów zdolnych do bardziej naturalnych i intuicyjnych interakcji z ludźmi. Marzenie Turinga o inteligentnych maszynach nie tylko zapoczątkowało erę sztucznej inteligencji, ale również wyznaczyło kierunek, w którym podążają współczesne badania nad AI.

1.2 Wczesna sztuczna inteligencja: Sieci neuronowe, perceptrony i sztuczna inteligencja symboliczna

Początki sztucznej inteligencji były kształtowane przez dwa główne nurty: sieci neuronowe i sztuczną inteligencję symboliczną (operacje na symbolach). Każdy z tych kierunków reprezentował inne podejście do tego, jak można zbudować systemy zdolne do „myślenia” i rozwiązywania problemów w sposób przypominający ludzki.

Zainspirowane budową ludzkiego mózgu sieci neuronowe były jednymi z pierwszych modeli zaprojektowanych do symulacji procesu uczenia się. W 1958 roku Frank Rosenblatt opracował perceptron - jednowarstwową sieć neuronową zdolną do uczenia się na podstawie danych wejściowych. Perceptron składał się z warstwy wejściowej, która przyjmowała dane, oraz

warstwy wyjściowej, która generowała decyzję – podobnie jak neurony w mózgu przetwarzają informacje (rys. 3).



Rys.3. Schemat działania sztucznego neuronu, który stał się podstawą do zbudowania Perceptronu

Źródło: <https://pl.wikipedia.org/wiki/Perceptron>

Pierwotne zastosowania perceptronu były dość proste, takie jak rozpoznawanie wzorców, np. klasyfikowanie kształtów czy znaków na podstawie ich cech. Perceptron mógł nauczyć się rozpoznawać te wzorce poprzez dostosowywanie wag przypisanych do wejść w oparciu o błędy popełnione w trakcie nauki. To właśnie ta zdolność do „uczenia się na błędach” stała się fundamentem dla późniejszych modeli uczenia maszynowego.

Jednak w latach 60. perceptrony i sieci neuronowe napotkały na ograniczenia. Mimo że były zdolne do rozwiązywania prostych problemów, miały trudności z przetwarzaniem bardziej złożonych, nieliniowych danych. W 1969 roku Marvin Minsky i Seymour Papert opublikowali książkę „Perceptrons: an Introduction to Computational Geometry”, w której opisali te ograniczenia, podkreślając, że perceptrony nie są w stanie rozwiązywać problemów złożonych. Ta krytyka zahamowała na kilka lat

badania nad sieciami neuronowymi, ale stała się też bodźcem do poszukiwania innych metod.

Podczas gdy sieci neuronowe próbowały naśladować procesy biologiczne, sztuczna inteligencja symboliczna (inaczej zwana AI opartą na regułach) bazowała na założeniu, że inteligencję można modelować poprzez manipulację symbolami i logiką. W tym podejściu tworzone systemy zdolne do rozwiązywania problemów poprzez stosowanie reguł i logiki, które były w nich zakodowane.

Jednym z pierwszych sukcesów AI symbolicznej były systemy eksperckie, które zawierały zestaw reguł eksperckich do podejmowania decyzji w określonym obszarze, na przykład w medycynie czy finansach. Przykładem może być system MYCIN⁵ stworzony w latach 70. XX wieku do diagnozowania infekcji bakteryjnych i rekomendowania odpowiednich antybiotyków. System ten działał na podstawie reguł opracowanych przez ekspertów medycznych i był w stanie analizować symptomy pacjenta, aby sugerować diagnozę.

Sztuczna inteligencja symboliczna pozwalała na tworzenie systemów bardzo precyzyjnych w wąskich dziedzinach. Jej siłą była zdolność do podejmowania decyzji w sposób transparentny – każda decyzja była wynikiem zestawu jasnych reguł i wniosków. Jednak ten rodzaj AI miał także swoje ograniczenia. Przede wszystkim wymagał ręcznego zakodowania ogromnej liczby reguł, co w praktyce było czasochłonne i nie pozwalało na łatwe skalowanie. Dodatkowo, systemy te były słabo przystosowane do zmieniających się warunków lub niepełnych informacji, ponieważ działały wyłącznie w ramach wcześniej ustalonych zasad.

Wczesne podejścia do AI – zarówno sieci neuronowe, jak i sztuczna inteligencja symboliczna – położyły podwaliny pod rozwój współczesnych technologii. Sieci neuronowe zainspirowały przyszłe badania nad głębokim uczeniem (ang. Deep Learning, DL), a perceptrony stały się prototypami dla bardziej złożonych sieci neuronowych używanych obecnie w zadaniach

⁵ <https://pl.wikipedia.org/wiki/Mycin>

takich jak rozpoznawanie obrazów czy przetwarzanie języka naturalnego. Z kolei AI symboliczna przyczyniła się do rozwoju systemów eksperckich i wpłynęła na rozwój dziedzin takich jak planowanie, reprezentacja wiedzy czy logika wnioskowania. Współczesne systemy AI często łączą podejście symboliczne z uczeniem maszynowym, tworząc tzw. hybrydowe modele AI, które są zdolne zarówno do analizowania danych, jak i stosowania logicznego rozumowania.

Dzisiejsze zastosowania AI, od chatbotów po systemy rekomendacji, czerpią z dziedzictwa obu tych nurtów, tworząc rozwiązania zdolne do rozumienia kontekstu, uczenia się i podejmowania decyzji w dynamicznych środowiskach biznesowych.

1.3 Wzrost znaczenia uczenia maszynowego

Uczenie maszynowe (ang. Machine Learning, ML) jest dziś jednym z najszybciej rozwijających się obszarów sztucznej inteligencji i ma kluczowe znaczenie dla nowoczesnych zastosowań technologicznych. W odróżnieniu od bardziej klasycznych podejść do AI, gdzie systemy działały na podstawie zestawu reguł stworzonych przez człowieka (AI symboliczna), uczenie maszynowe polega na tworzeniu modeli, które uczą się na podstawie danych. To fundamentalna zmiana w podejściu do rozwiązywania problemów, która zrewolucjonizowała wiele dziedzin, takich jak analiza danych, przewidywania rynkowe, rozpoznawanie obrazów, tłumaczenia językowe i wiele innych.

Uczenie maszynowe to dziedzina, która rozwija algorytmy pozwalające komputerom samodzielnie uczyć się i poprawiać swoje działanie na podstawie doświadczeń. Kluczową koncepcją jest to, że modele uczenia maszynowego nie są programowane ręcznie do wykonywania zadań, lecz „są trenowane” na podstawie danych. Dzięki temu mogą one odnajdywać

wzorce i zależności, których człowiek mógłby nie zauważyć, i zastosować je do nowych, nieznanych danych.

Przez ostatnie dwie dekady uczenie maszynowe znalazło szerokie zastosowanie w wielu sektorach gospodarki. Firmy z różnych branż coraz częściej korzystają z uczenia maszynowego, np.:

- **Finanse i bankowość:** Algorytmy uczenia maszynowego są wykorzystywane do analizy ryzyka kredytowego, wykrywania oszustw oraz automatycznego doradztwa. Banki, na przykład, korzystają z modeli predykcyjnych, aby przewidywać, którzy klienci mogą mieć trudności ze spłatą kredytów oraz automatyzować monitorowanie transakcji pod kątem podejrzanych aktywności.
- **Handel detaliczny i e-commerce:** Algorytmy personalizacji, takie jak rekomendacje produktów, są kluczowe dla poprawy doświadczeń klientów w sklepach internetowych. Uczenie maszynowe umożliwia firmom takim jak Amazon czy Netflix rekomendowanie produktów lub filmów na podstawie wcześniejszych zachowań klientów, co skutecznie zwiększa sprzedaż.
- **Ochrona zdrowia:** W medycynie uczenie maszynowe może być używane do analizy danych z badań diagnostycznych, takich jak obrazy rentgenowskie oraz przewidywania przebiegu choroby na podstawie danych pacjentów. Systemy oparte na ML mogą również pomóc lekarzom w wyborze najlepszych metod leczenia, analizując dane z tysięcy przypadków.
- **Przemysł i produkcja:** W fabrykach i na liniach produkcyjnych uczenie maszynowe może optymalizować procesy produkcyjne, przewidując awarie sprzętu (ang. predictive maintenance) oraz pomagać w automatyzacji kontroli jakości produktów. Dzięki analizie danych z maszyn, systemy uczenia maszynowego mogą przewidywać momenty, w których sprzęt wymaga konserwacji, co pozwala na unikanie kosztownych przestoju.

- Marketing i analiza rynku: Dzięki możliwości analizowania ogromnych ilości danych, uczenie maszynowe może pomóc firmom zrozumieć potrzeby i preferencje klientów. Algorytmy ML są używane do segmentacji klientów, analizy nastrojów w mediach społecznościowych oraz automatyzacji kampanii marketingowych, co pozwala na precyzyjne dopasowanie przekazu marketingowego do odpowiednich grup docelowych.

Pomimo imponujących osiągnięć, uczenie maszynowe wciąż jednak napotyka na wyzwania. Można do nich zaliczyć trudności takie jak: zależność od jakości danych (modele uczenia maszynowego są tak dobre, jak dane, na których zostały wytrenowane). Problemy z niekompletnymi, zniekształconymi lub niewystarczającymi danymi mogą prowadzić do błędnych wyników.⁶ Innym wyzwaniem jest brak „wyjaśnialności” modeli (ang. explainability): Wiele nowoczesnych modeli ML, zwłaszcza głębokie sieci neuronowe, działa jak „czarne skrzynki”, co oznacza, że trudno jest zrozumieć, jak dokładnie podejmują decyzje. „Wyjaśnialna AI” (ang. Explainable Artificial Intelligence, XAI) jest dziedziną badań, która stara się uczynić wyniki tych modeli bardziej transparentnymi i zrozumiałymi. I „last but not least” - bezpieczeństwo i etyka: Uczenie maszynowe wiąże się z etycznymi dylematami, zwłaszcza w kontekście prywatności danych, dyskryminacji algorytmicznej oraz odpowiedzialności za decyzje podejmowane przez AI.

Więcej na temat uczenia maszynowego przeczytasz w Rozdziale 3.

⁶ Problem ten dotyczy również systemów AI opartych na regułach – ich jakość zależy od jakości bazy wiedzy, a często trudno jest zbudować, w oparciu o rozproszone informacje, wiarygodną podstawę do zasilenia systemu AI (np. chatbota).

1.4 Zastosowania AI w biznesie

W ostatnich dekadach sztuczna inteligencja przeszła długą drogę od teoretycznych koncepcji i laboratoryjnych eksperymentów do realnych, szeroko stosowanych rozwiązań biznesowych. Podczas gdy początki AI były zdominowane przez badania akademickie i eksperymentalne zastosowania, rozwój technologii komputerowych, algorytmów oraz dostępność dużych zbiorów danych sprawiły, że AI stała się integralną częścią nowoczesnych strategii biznesowych. Firmy na całym świecie zaczęły dostrzegać potencjał AI do automatyzacji procesów, poprawy efektywności operacyjnej oraz optymalizacji interakcji z klientami, co przyspieszyło przejście do zastosowań AI w realnym świecie biznesu.

Jednym z kluczowych czynników, który umożliwił wdrożenie AI do biznesu, była dostępność tzw. big data – czyli olbrzymich zbiorów danych gromadzonych przez firmy. Dane stały się paliwem dla algorytmów uczenia maszynowego, które mogły analizować te dane i wyciągać z nich cenną wiedzę. Uczenie maszynowe – szczególnie w formie uczenia nadzorowanego – pozwala firmom automatycznie przewidywać szerokie spektrum wyników na podstawie wcześniej zgromadzonych danych. Na przykład w dziedzinie handlu elektronicznego firmy zaczęły korzystać z algorytmów rekomendacji opartych na AI, które analizują historię zakupów i preferencje klientów, aby sugerować im nowe produkty. Tego typu personalizacja stała się kluczowym elementem strategii marketingowych, poprawiając sprzedaż i satysfakcję klientów.

Wprowadzenie chmur obliczeniowych (ang. cloud computing) w latach 2000. pozwoliło firmom na przetwarzanie dużych ilości danych bez konieczności inwestowania w kosztowną infrastrukturę. Dzięki temu dostęp do zaawansowanych narzędzi AI stał się możliwy nawet dla małych i średnich przedsiębiorstw, które wcześniej nie miały zasobów potrzebnych do wdrożenia takich rozwiązań.

Jednym z kluczowych obszarów, w którym AI znalazła szerokie zastosowanie, była automatyzacja procesów biznesowych (ang. Robotic Proces Automation, RPA). Sztuczna inteligencja umożliwia firmom automatyzację powtarzalnych i czasochłonnych zadań, co nie tylko redukuje koszty operacyjne, ale także minimalizuje błędy ludzkie. RPA, napędzane przez AI, pozwala na automatyzację zadań takich jak przetwarzanie faktur, wprowadzanie danych, czy analiza dużych zbiorów dokumentów. Przykładowo w sektorze finansowym, firmy ubezpieczeniowe i banki stosują AI w RPA do automatycznego przetwarzania wniosków o kredyt czy ubezpieczenia. Podobnie, systemy AI w RPA analizują wnioski klientów, sprawdzają zgodność z polityką firmy i generują decyzje w oparciu o zestawy danych, oszczędzając czas i zasoby. Zastosowania te nie ograniczają się jedynie do administracji. W logistyce i łańcuchach dostaw AI optymalizuje trasy transportowe, prognozuje popyt, a także monitoruje stany magazynowe w czasie rzeczywistym, co pozwala firmom na bardziej precyzyjne zarządzanie zapasami i redukcję strat.

Jednym z najważniejszych obszarów, w którym AI przyniosła znaczące korzyści, jest obsługa klienta. Chatboty i voiceboty, oparte na zaawansowanych algorytmach przetwarzania języka naturalnego, stały się powszechnym narzędziem w interakcjach z klientami. Systemy te są w stanie odpowiadać na pytania, rozwiązywać problemy i pomagać klientom w procesie zakupowym, co poprawia doświadczenie użytkownika i zmniejsza obciążenie ludzkich pracowników. Na przykład w branży telekomunikacyjnej AI jest używana do automatyzacji obsługi klienta, gdzie boty odpowiadają na pytania dotyczące faktur, oferty, czy statusu zamówień. Z kolei w branży bankowej wirtualni asystenci pomagają klientom zarządzać kontami, monitorować transakcje i uzyskiwać informacje o kredytach.

Nie tylko obsługa klienta zyskała na automatyzacji z użyciem sztucznej inteligencji. Firmy zaczęły również używać AI do analizy nastrojów

w mediach społecznościowych i automatycznej odpowiedzi na opinie klientów, co pozwala im na bardziej efektywne zarządzanie reputacją marki. Dzięki coraz lepszym algorytmom oraz większej dostępności danych, AI stała się nieocenionym narzędziem w analizie danych i wspomaganie decyzji strategicznych. Firmy technologiczne i finansowe wykorzystują modele uczenia maszynowego do prognozowania trendów rynkowych i analizowania historycznych danych transakcyjnych w celu identyfikacji wzorców, które mogą sugerować przyszłe zmiany na rynku. Takie przewidywania pomagają firmom podejmować lepsze decyzje dotyczące inwestycji, zarządzania ryzykiem i alokacji zasobów.

Przejęcie od teoretycznych algorytmów AI do ich realnych zastosowań w biznesie nastąpiło szybciej niż wielu przewidywało, a przyszłość tej technologii zapowiada się jeszcze bardziej ekscytująco. Rozwój sztucznej inteligencji nie ogranicza się już do automatyzacji prostych zadań. Można przypuszczać, że przyszłe zastosowania AI będą coraz bardziej złożone i zaawansowane, z większym naciskiem na personalizację, automatyczne podejmowanie decyzji, a także integrację z technologiami takimi jak Internet rzeczy (ang. Internet of Things, IoT) i blockchain.

Rozdział 2: Przetwarzanie języka naturalnego w biznesie

2.1 Czym jest NLP? Praktyczne wprowadzenie

Natural Language Processing (NLP), czyli przetwarzanie języka naturalnego, jest kolejnym, obok uczenia maszynowego, najważniejszym i najszybciej rozwijającym się obszarem sztucznej inteligencji. Przetwarzanie języka naturalnego zajmuje się interakcjami pomiędzy komputerami a językiem naturalnym używanym przez ludzi i umożliwia maszynom rozumienie, interpretowanie i generowanie ludzkiego języka. Dzięki NLP, komputery mogą analizować teksty pisane lub mówione, odczytywać ich znaczenie i reagować na nie w sposób zbliżony do przyjętych interakcji między ludźmi. NLP stanowi zatem ogromne osiągnięcie technologiczne, które znalazło szerokie zastosowanie w biznesie, od automatyzacji obsługi klienta, przez analizę danych, aż po tłumaczenia maszynowe.

Język naturalny – zarówno mówiony, jak i pisany – jest niezwykle skomplikowany. Obejmuje gramatykę, składnię, semantykę, pragmatykę, a także kontekst kulturowy. Wszystkie te aspekty muszą zostać wzięte pod uwagę podczas tworzenia systemów NLP, co czyni tę dziedzinę wyjątkowo wymagającą. Aby skutecznie przetwarzać język, komputery muszą radzić sobie z różnorodnością form językowych, niejednoznacznościami, metaforami, ironią, humorem, idiomami i wieloma innymi subtelnościami, które są naturalne dla ludzkiego języka, ale trudne do modelowania przez maszyny.

tych technologii, tak aby ich użycie przynosiło rzeczywistą wartość bez ryzyka nieprzewidzianych konsekwencji, jakimi mogą być np. halucynacje omówione w kolejnym podrozdziale.

3.6 Problem halucynacji w modelach językowych

Problem halucynacji w sztucznej inteligencji, zwłaszcza w kontekście modeli językowych i generatywnej AI, polega na tym, że systemy te czasami generują odpowiedzi, które na pierwszy rzut oka wydają się poprawne i brzmią logicznie, jednakże są całkowicie błędne i niezgodne z rzeczywistością. Halucynacje mogą przybierać różne formy: od błędnych faktów, przez zmyślane cytaty, po nieprawdziwe wyjaśnienia i informacje. Zjawisko to jest szczególnie palącym problemem w dziedzinach takich jak medycyna, prawo, finanse czy nauka, gdzie AI musi dostarczać dokładne, prawdziwe i rzetelne informacje.

Modele językowe, takie jak GPT (na którym m.in. opiera się aplikacja ChatGPT), są trenowane na ogromnych ilościach danych tekstowych. Zatem w procesie generowania odpowiedzi językowy model AI nie działa jak baza danych z faktami, ale raczej jako zaawansowany system predykcyjny, który na podstawie wzorców językowych przewiduje najbardziej prawdopodobną kontynuację tekstu. Chociaż modele te są doskonałe w rozumieniu struktury i logiki języka, nie mają niestety wbudowanej wiedzy na temat rzeczywistości, co prowadzi do sytuacji, w których mogą generować odpowiedzi brzmiące przekonująco, ale nie będące prawdziwymi.

Przyczynami halucynacji mogą być brak wysokiej jakości danych treningowych na wejściu, brak kontroli nad przytaczanymi faktami, predykcyjny charakter modeli AI oraz złożoność zadań, które te modele wykonują. Gdy modele nie mają dostępu do pełnych danych lub są

zmuszone uzupełniać luki informacyjne, mogą wprowadzać błędne dane, aby uzupełnić podawane informacje. Model AI nie ma także zdolności do weryfikacji faktów w czasie rzeczywistym, co może skutkować generowaniem fałszywych informacji na podstawie nieaktualnych lub od początku błędnych danych.

Przykłady halucynacji obejmują tworzenie nieistniejących cytatów, przypisywanie nieprawdziwych źródeł informacji, błędne tłumaczenia lub przytaczanie nieprawdziwych faktów. Na przykład model AI może stworzyć cytat, który brzmi autentycznie, ale nigdy nie został wypowiedziany przez przypisywaną osobę (a nawet może się okazać, że ta osoba też jest wymyślona). W kontekście tłumaczeń, językowy model AI może wprowadzać do tekstu nadmiarowe informacje, których nie było w oryginalnym źródle, a w analizie danych może generować zafałszowane wyniki dotyczące produktów czy usług.

Konsekwencje halucynacji mogą być bardzo poważne, we wszystkich branżach wymagających rzetelnej wiedzy i prawdziwych informacji. Halucynacje prowadzą do szerzenia dezinformacji, co może zaszkodzić reputacji firm, zniechęcić użytkowników do korzystania z systemów AI, a nawet prowadzić do problemów etycznych oraz prawnych. W medycynie czy prawie błędne decyzje podejmowane na podstawie nieprawdziwych informacji wygenerowanych przez modele AI mogą mieć katastrofalne skutki.

Aby rozwiązać problem halucynacji, wprowadza się różne podejścia. Jednym z nich jest implementacja mechanizmów weryfikacji faktów, które mogą sprawdzać odpowiedzi modeli AI pod kątem zgodności z rzeczywistością, na przykład poprzez integrację tych modeli z bazami danych zawierającymi sprawdzone informacje. Innym podejściem jest lepsze szkolenie modeli na zweryfikowanych danych, co może zmniejszyć ryzyko powstania halucynacji. Dostosowanie modeli do specyficznych kontekstów i zadań, w których są używane, także wspiera minimalizację błędnych odpowiedzi. Ważnym aspektem jest również rozważenie

interwencji człowieka, szczególnie w tych zastosowaniach, w których błędy i halucynacje mogą rodzić bardzo poważne konsekwencje.

Podsumowując, halucynacje w językowych modelach AI stanowią istotne wyzwanie, zwłaszcza w zastosowaniach wymagających wysokiej dokładności i niezawodności. Choć językowe modele AI mają ogromny potencjał, problem generowania fałszywych informacji musi być stale monitorowany i rozwiązywany poprzez rozwój lepszych algorytmów, ulepszone trenowanie modeli i zastosowanie w nich dodatkowych mechanizmów weryfikacyjnych.

tworzenia modeli predykcyjnych bez potrzeby zaawansowanej wiedzy technicznej w dziedzinie AI.

Kluczowe funkcje:

Automated Machine Learning (AutoML): Umożliwia automatyczne trenowanie i wdrażanie modeli uczenia maszynowego, co przyspiesza proces tworzenia predykcyjnych rozwiązań AI.

Model Interpretability: DataRobot zapewnia przejrzystość działania modeli, co pozwala na zrozumienie, jak algorytmy podejmują decyzje. To kluczowe dla firm, które potrzebują wyjaśnialnej AI (XAI).

Zastosowanie w biznesie: DataRobot jest szeroko stosowany w bankowości, ubezpieczeniach, sprzedaży detalicznej i produkcji. Firmy używają tej platformy do prognozowania wyników finansowych, zarządzania ryzykiem, personalizacji ofert oraz optymalizacji operacyjnej.

D.3 Przykładowe prompty dla implementacji AI w kontekście biznesowym

Implementacja sztucznej inteligencji w biznesie wymaga nie tylko narzędzi i platform, ale także odpowiednich poleceń i zapytań, które pomagają maksymalnie wykorzystać potencjał tej technologii. Prompty, czyli zapytania lub instrukcje podawane do systemów AI, są podstawowym elementem w procesie interakcji z algorytmami AI – zwłaszcza w kontekście przetwarzania języka naturalnego, analizy danych oraz automatyzacji zadań. Skutecznie zaprojektowane prompty mogą pomóc w uzyskaniu oczekiwanych wyników, rozwiązaniu konkretnych problemów biznesowych oraz zwiększeniu efektywności operacyjnej.

W tym dodatku zaprezentowano przykładowe prompty, które mogą być wykorzystane w różnych obszarach biznesowych, takich jak analiza danych,

automatyzacja procesów, obsługa klienta, marketing oraz zarządzanie finansami.

Prompty do analizy danych

AI jest szeroko stosowana do analizy dużych ilości danych, a odpowiednie prompty mogą pomóc w szybkim wyciąganiu najważniejszych wniosków. Poniższe przykłady promptów są skierowane do systemów AI w celu analizy wyników sprzedaży, identyfikacji wzorców w zachowaniach klientów i prognozowania trendów rynkowych.

„Przeanalizuj dane sprzedażowe za ostatni rok i wskaż produkty o największym wzroście sprzedaży w porównaniu do poprzedniego roku.”

„Użyj dostępnych danych o zakupach, aby zidentyfikować, które segmenty klientów są najbardziej podatne na zakup nowych produktów.”

„Na podstawie danych sprzedażowych i trendów rynkowych, stwórz prognozę sprzedaży na następny kwartał.”

„Zidentyfikuj okresy, w których wzrosła liczba zwrotów produktów, i wyjaśnij, jakie czynniki mogły to spowodować.”

W odpowiedzi na te prompty AI analizuje dostępne dane i generuje raporty lub wizualizacje, które pomagają menedżerom lepiej zrozumieć dynamikę sprzedaży, zmiany w preferencjach klientów oraz sezonowe wahania.

Prompty do automatyzacji procesów biznesowych

Automatyzacja rutynowych zadań to jedno z najczęstszych zastosowań AI w biznesie. Odpowiednie prompty mogą pomóc w optymalizacji procesów, eliminacji błędów oraz oszczędności czasu. Poniższe prompty mogą być wykorzystane w procesie automatyzacji zadań, takich jak przetwarzanie zamówień, obsługa dokumentów czy zarządzanie zasobami.

„Zautomatyzuj proces przetwarzania faktur poprzez identyfikację i klasyfikację dokumentów, a następnie zaksięguj je w odpowiednich kategoriach.”

„Zidentyfikuj powtarzające się zadania w procesie zarządzania zapasami i zaproponuj ich automatyzację z użyciem RPA.”

„Na podstawie harmonogramu dostaw i zamówień klientów, zoptymalizuj trasy transportowe w celu minimalizacji kosztów logistycznych.”

„Zautomatyzuj proces przypisywania nowych zgłoszeń klientów do odpowiednich zespołów na podstawie typu zgłoszenia i jego priorytetu.”

Przytoczone prompty umożliwiają firmom automatyzację powtarzalnych zadań, co nie tylko zmniejsza obciążenie pracowników, ale również zwiększa efektywność operacyjną.

Prompty do obsługi klienta

Chatboty i voiceboty wspierane przez AI odgrywają coraz większą rolę w automatyzacji obsługi klienta. Odpowiednie prompty pozwalają chatbotom na udzielanie poprawnych odpowiedzi, rozwiązywanie problemów klientów i prowadzenie interaktywnych rozmów. Poniżej znajdują się przykładowe prompty do zastosowania w obsłudze klienta.

„Stwórz interaktywny skrypt konwersacyjny, który pomoże klientom w samodzielnym rozwiązywaniu problemów technicznych z produktem.”

„Opracuj sekwencję pytań dla chatbota, aby zidentyfikować potrzeby klientów i zasugerować im odpowiednie produkty.”

„Stwórz voicebota, który automatycznie odbiera połączenia od klientów i pomaga im w śledzeniu zamówień lub złożeniu reklamacji.”

„Zidentyfikuj najczęstsze problemy klientów na podstawie historii interakcji z chatbotem i zaproponuj poprawki do skryptu konwersacyjnego.”

Tak skonstruowane prompty pomagają firmom w optymalizacji doświadczeń klientów, skracają czas odpowiedzi oraz zwiększają satysfakcję klienta z obsługi.

Prompty do marketingu

AI odgrywa istotną rolę w marketingu, pomagając w personalizacji kampanii, analizie efektywności reklam i prognozowaniu zachowań konsumentów. Przykłady promptów skierowanych do AI w kontekście marketingu mogą obejmować generowanie analiz kampanii marketingowych, segmentację klientów czy personalizację komunikacji.

„Przeanalizuj wyniki ostatniej kampanii e-mail marketingowej i wskaż, które segmenty klientów miały najwyższy wskaźnik otwarcia wiadomości.”

„Stwórz spersonalizowane rekomendacje produktowe dla klientów na podstawie ich wcześniejszych zakupów i preferencji.”

„Na podstawie analizy danych o interakcjach klientów z reklamami, zaproponuj zmiany w strategii reklamowej na mediach społecznościowych.”

„Wykorzystaj analizę sentymentu, aby zrozumieć, jak klienci postrzegają nowy produkt na podstawie ich opinii w mediach społecznościowych.”

Powyższe prompty pozwalają na dostosowanie strategii marketingowych do zachowań konsumentów, co może prowadzić do zwiększenia zaangażowania klientów oraz efektywności kampanii.

Prompty do zarządzania finansami

AI jest coraz częściej wykorzystywana w zarządzaniu finansami, wspierając prognozowanie przychodów, monitorowanie wydatków oraz analizę ryzyka. Przykłady promptów w tym kontekście mogą obejmować generowanie raportów finansowych, prognozy dotyczące przepływów pieniężnych lub identyfikację oszczędności.

„Przeanalizuj miesięczne dane finansowe i wygeneruj raport z rekomendacjami dotyczącymi oszczędności kosztów operacyjnych.”

„Stwórz prognozę przepływów pieniężnych na następne sześć miesięcy na podstawie bieżących danych sprzedażowych i wydatków.”

„Wykryj nietypowe wydatki w budżecie na podstawie analizy danych historycznych i zasugeruj działania zapobiegawcze.”