W opowiadaniu Fredrica Browna z 1954 r. „Odpowiedź” wszystkie komputery na 96 miliardach planet we wszechświecie zostały połączone w jedną super maszynę. Następnie zapytano: „Czy istnieje Bóg?” na co odpowiedział: „Tak, teraz jest Bóg”. Bez wątpienia historia Browna była z pewnością sprytna – a także nieco komiczna i mrożąca krew w żyłach! Science fiction jest dla nas sposobem na zrozumienie implikacji nowych technologii, a sztuczna inteligencja (AI) jest głównym tematem. Niektóre z najbardziej zapadających w pamięć postaci w science fiction obejmują androidy lub komputery, które stają się samoświadome, takie jak Terminator, Łowca androidów, 2001: Odyseja kosmiczna, a nawet Frankenstein. Jednak w dzisiejszych czasach niesłabnące tempo nowych technologii i innowacji sprawia, że science fiction staje się rzeczywistością. Teraz możemy rozmawiać ze smartfonami i uzyskiwać odpowiedzi; nasze konta w mediach społecznościowych dostarczają nam treści, które nas interesują; nasze aplikacje bankowe dostarczają nam przypomnień; i tak dalej. To tworzenie spersonalizowanych treści wydaje się niemal magiczne, ale szybko staje się normalne w naszym codziennym życiu. Aby zrozumieć sztuczną inteligencję, ważne jest, aby zakorzenić się w jej bogatej historii. Zobaczysz, jak rozwój tej branży był pełen przełomów i niepowodzeń. Jest też obsada genialnych badaczy i naukowców, takich jak Alan Turing, John McCarthy, Marvin Minsky i Geoffrey Hinton, którzy przesuwali granice technologii. Ale przez to wszystko był ciągły postęp.

**Zacznijmy.**

**Alan Turing i test Turinga**

Alan Turing to wybitna postać w dziedzinie informatyki i sztucznej inteligencji. Często nazywany jest „ojcem sztucznej inteligencji”. W 1936 napisał artykuł „O liczbach obliczalnych”. W nim przedstawił podstawowe koncepcje komputera, który stał się znany jako maszyna Turinga. Należy pamiętać, że prawdziwe komputery zostaną opracowane dopiero ponad dekadę później. Jednak to jego artykuł zatytułowany „Maszyny komputerowe i inteligencja” stał się historyczny dla AI. Skupił się na koncepcji inteligentnej maszyny. Ale żeby to zrobić, musiał być sposób na zmierzenie tego. Czym jest inteligencja -przynajmniej dla maszyny? To tutaj wymyślił słynny „Test Turinga”. Zasadniczo jest to gra z trzema graczami: dwoma ludźmi i jednym komputerem. Oceniający, człowiek, zadaje dwóm pozostałym (jednemu człowiekowi, jednemu komputerowi) pytania otwarte w celu ustalenia, który z nich jest człowiekiem. Jeśli oceniający nie może dokonać oceny, zakłada się, że komputer jest inteligentny. Rysunek przedstawia podstawowy przebieg testu Turinga.

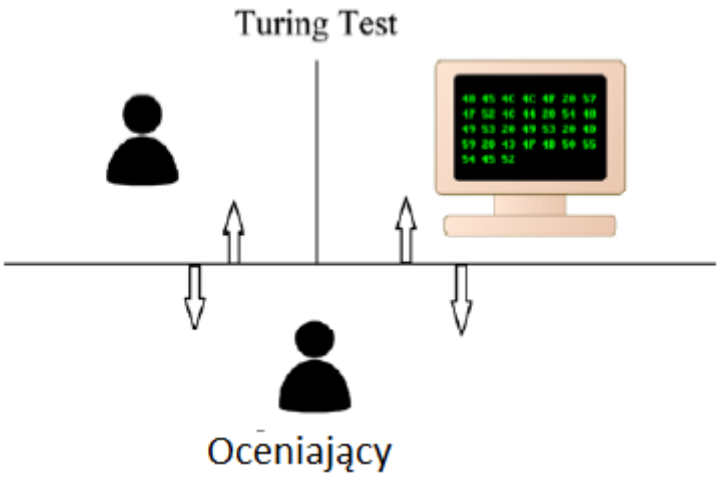


Geniusz tej koncepcji polega na tym, że nie ma potrzeby sprawdzania, czy maszyna rzeczywiście coś wie, jest samoświadoma, a nawet czy jest poprawna. Test Turinga wskazuje raczej, że maszyna może przetwarzać duże ilości informacji, interpretować mowę i komunikować się z ludźmi. Turing wierzył, że

maszyna  przejdzie jego test dopiero na przełomie wieków. Tak, to była jedna z wielu prognoz AI, które się nie spełnią. Jak więc test Turinga trzymał się przez lata? Cóż, okazał się trudny do złamania. Należy pamiętać, że istnieją konkursy, takie jak Nagroda Loebnera i Konkurs Testu Turinga, aby zachęcić ludzi do tworzenia inteligentnych systemów oprogramowania. W 2014 roku zdarzył się przypadek, w którym wyglądało na to, że test Turinga został zdany. Dotyczyło to komputera, który twierdził, że ma 13 lat. Co ciekawe, ludzcy sędziowie prawdopodobnie zostali oszukani, ponieważ niektóre odpowiedzi zawierały błędy. Następnie w maju 2018 r. na konferencji Google I/O dyrektor generalny Sundar Pichai zaprezentował wyróżniające się demo Asystenta Google. Przed publicznością na żywo użył urządzenia, aby zadzwonić do lokalnego fryzjera, aby umówić się na spotkanie. Osoba na drugim końcu linii zachowywała się tak, jakby rozmawiała z kimś! Niesamowite, prawda? Zdecydowanie. Mimo to prawdopodobnie nadal nie przeszedł testu Turinga. Powodem jest to, że rozmowa koncentrowała się na jednym temacie - nie była otwarta. Nie powinno dziwić, że trwają kontrowersje związane z testem Turinga, ponieważ niektórzy uważają, że można nim manipulować. W 1980 roku filozof John Searle napisał słynny artykuł zatytułowany „Umysły, mózgi i programy", w którym zainicjował własny eksperyment myślowy, nazwany „argumentem chińskiego pokoju", aby podkreślić wady. Oto jak to działało: załóżmy, że John jest w pokoju i nie rozumie języka chińskiego. Ma jednak podręczniki, które zawierają łatwe w użyciu zasady tłumaczenia. Na zewnątrz pokoju jest Jan, który rozumie język i przekazuje postacie Johnowi. Po pewnym czasie otrzyma od Johna dokładne tłumaczenie. W związku z tym rozsądnie jest założyć, że Jan wierzy, że John potrafi mówić po chińsku.

**Wniosek Searle'a:**

Sedno sporu jest takie: jeśli mężczyzna w pokoju nie rozumie języka chińskiego na podstawie zaimplementowania odpowiedniego programu do rozumienia języka chińskiego, to żaden inny komputer cyfrowy nie ma tego tylko na tej podstawie, ponieważ żaden komputer, niby komputer, nie ma niczego czego człowiek  nie ma

To był całkiem niezły argument – i od tego czasu jest gorącym tematem debaty w kręgach AI. Searle wierzył również, że istnieją dwie formy sztucznej inteligencji:

• Silna sztuczna inteligencja: To wtedy maszyna naprawdę rozumie, co się dzieje. Mogą być nawet emocje i kreatywność. W większości jest to to, co widzimy w filmach science fiction. Ten rodzaj sztucznej inteligencji jest również znany jako sztuczna ogólna inteligencja (AGI). Zwróć uwagę, że istnieje tylko kilka firm, które skupiają się na tej kategorii, takich jak DeepMind firmy Google.

• Słaba sztuczna inteligencja: Dzięki temu maszyna dopasowuje się do wzorca i zwykle koncentruje się na wąskich zadaniach. Przykładami tego są Siri firmy Apple i Alexa firmy Amazon.

W rzeczywistości sztuczna inteligencja jest we wczesnych fazach słabej sztucznej inteligencji. Osiągnięcie punktu silnej sztucznej inteligencji może z łatwością zająć dekady. Niektórzy badacze uważają, że może się to nigdy nie wydarzyć. Biorąc pod uwagę ograniczenia testu Turinga, pojawiły się alternatywy, takie jak:

• Test Kurzweila-Kapora: Pochodzi od futurologa Raya Kurzweila i przedsiębiorcy technologicznego Mitcha Kapora. Ich test wymaga, aby komputer prowadził rozmowę przez dwie godziny, a dwóch z trzech sędziów uznało, że to człowiek mówiący. Jeśli chodzi o Kapora, to nie wierzy, że uda się to osiągnąć do 2029 roku.

• Test kawy: To od współzałożyciela Apple, Steve'a Wozniaka. Według testu na kawę robot musi być w stanie wejść do domu nieznajomego, zlokalizować kuchnię i zaparzyć filiżankę kawy.

**Mózg to … maszyna?**

W 1943 Warren McCulloch i Walter Pitts spotkali się na Uniwersytecie w Chicago i szybko się zaprzyjaźnili, mimo że ich pochodzenie było zupełnie inne, podobnie jak ich wiek (McCulloch miał 42 lata, a Pitts 18). McCulloch dorastał w zamożnej rodzinie wschodniego establishmentu, uczęszczając do prestiżowych szkół. Z drugiej strony Pitts dorastał w dzielnicy o niskich dochodach i jako nastolatek był nawet bezdomny. Mimo to partnerstwo stałoby się jednym z najbardziej znaczących w rozwoju sztucznej inteligencji. McCulloch i Pitts opracowali nowe teorie wyjaśniające działanie mózgu, które często były sprzeczne z konwencjonalną mądrością psychologii Freuda. Ale oboje myśleli, że logika może wyjaśnić moce mózgu, a także przyjrzeli się spostrzeżeniom Alana Turinga. Na tej podstawie napisali w 1943 r. artykuł zatytułowany „Rachunek logiczny idei immanentnych w aktywności nerwowej", który ukazał się w Biuletynie Biofizyki Matematycznej. Postawiono tezę, że podstawowe funkcje mózgu, takie jak neurony i synapsy, można wyjaśnić za pomocą logiki i matematyki, powiedzmy za pomocą operatorów logicznych, takich jak AND , OR, i NOT. Dzięki nim można zbudować złożoną sieć, która może przetwarzać informacje, uczyć się i myśleć. Jak na ironię, praca ta nie spotkała się z dużym zainteresowaniem neurologów. Ale zwróciła uwagę osób pracujących na komputerach i sztucznej inteligencji.

**Cybernetyka**

Podczas gdy Norbert Wiener tworzył różne teorie, jego najsłynniejsza dotyczyła cybernetyki. Skupiono się na zrozumieniu sterowania i komunikacji ze zwierzętami, ludźmi i maszynami, pokazując znaczenie pętli sprzężenia zwrotnego. W 1948 roku Wiener opublikował Cybernetics: Or Control and Communication in the Animal and the Machine. Mimo że była to praca naukowa wypełniona skomplikowanymi równaniami, książka stała się bestsellerem, trafiając na listę New York Timesa. Była zdecydowanie szeroka. Niektóre z tematów obejmowały mechanikę Newtona, meteorologię, statystykę, astronomię i termodynamikę. Ta książka zapowiadała rozwój teorii chaosu, komunikacji cyfrowej, a nawet pamięci komputerowej. Ale książka miałaby również wpływ na sztuczną inteligencję. Podobnie jak McCulloch i Pitts, Wiener porównał ludzki mózg do komputera. Co więcej, spekulował, że komputer będzie w stanie grać w szachy i ostatecznie pokonać wielkich mistrzów. Głównym powodem jest to, że wierzył, że maszyna może się uczyć, grając w gry. Myślał nawet, że komputery będą w stanie się replikować. Ale Cybernetyka też nie była utopijna. Wiener był również przewidujący w zrozumieniu wad komputerów, takich jak potencjał dehumanizacji. Uważał nawet, że maszyny sprawią, że ludzie będą niepotrzebni. To było zdecydowanie mieszane przesłanie. Ale pomysły Wienera były potężne i pobudziły rozwój sztucznej inteligencji.

**Historia pochodzenia**

Zainteresowanie Johna McCarthy'ego komputerami wzrosło w 1948 roku, kiedy wziął udział w seminarium zatytułowanym „Mechanizmy mózgowe w zachowaniu", które dotyczyło tego, jak maszyny będą w końcu zdolne do myślenia. Wśród uczestników byli czołowi pionierzy w tej dziedzinie, tacy jak John von Neumann, Alan Turing i Claude Shannon. McCarthy nadal zagłębiał się w rozwijającą się branżę komputerową - wliczając w to pracę w Bell Labs - a w 1956 zorganizował dziesięciotygodniowy projekt badawczy na Uniwersytecie Dartmouth. Nazwał to „badaniem sztucznej inteligencji". Po raz pierwszy użyto tego terminu. Wśród uczestników znaleźli się naukowcy tacy jak Marvin Minsky, Nathaniel Rochester, Allen Newell, OG Selfridge, Raymond Solomonoff i Claude Shannon. Wszyscy z nich stali się głównymi graczami w sztucznej inteligencji. Cele badania były zdecydowanie ambitne:

Badanie ma opierać się na przypuszczeniu, że każdy aspekt uczenia się lub jakakolwiek inna cecha inteligencji może być w zasadzie tak dokładnie opisana, że można stworzyć maszynę do jej symulacji. Podjęta zostanie próba znalezienia sposobu na zmuszenie maszyn do używania języka, tworzenia

abstrakcji i pojęć, rozwiązywania problemów zarezerwowanych dla ludzi i samodoskonalenia. Uważamy, że w jednym lub kilku z tych problemów można dokonać znaczącego postępu, jeśli starannie dobrana grupa naukowców będzie nad nim pracować razem przez lato.

Na konferencji Allen Newell, Cliff Shaw i Herbert Simon zaprezentowali program komputerowy o nazwie Logic Theorist, który opracowali w firmie Research and Development (RAND) Corporation. Główną inspiracją był Simon (zdobywca Nagrody Nobla w dziedzinie ekonomii w 1978 roku). Kiedy zobaczył, jak komputery drukują słowa na mapie systemów obrony przeciwlotniczej, zdał sobie sprawę, że te maszyny mogą być czymś więcej niż tylko przetwarzaniem liczb. Może również pomóc w obrazach, postaciach i symbolach - wszystko to może prowadzić do myślącej maszyny. Jeśli chodzi o Logic Theorist, skupiono się na rozwiązywaniu różnych twierdzeń matematycznych z Principia Mathematica. Jedno z rozwiązań z oprogramowania okazało się bardziej eleganckie – a współautor książki Bertrand Russell był zachwycony. Stworzenie Logic Theorist nie było łatwym zadaniem. Newell, Shaw i Simon używali IBM 701, który używał języka maszynowego. Stworzyli więc język wysokiego poziomu, zwany IPL (ang. Information Processing Language), który przyspieszył programowanie. Przez kilka lat był to język z wyboru dla AI. IBM 701 również nie miał wystarczającej ilości pamięci dla teoretyka logiki. Doprowadziło to do kolejnej innowacji: przetwarzania list. Pozwalało to na dynamiczne przydzielanie i zwalnianie pamięci w trakcie działania programu. Konkluzja: Logic Theorist jest uważany za pierwszy program AI, jaki kiedykolwiek opracowano. Mimo to nie wzbudził dużego zainteresowania! Konferencja w Dartmouth była głównie rozczarowaniem. Skrytykowano nawet wyrażenie „sztuczna inteligencja". Naukowcy próbowali wymyślić alternatywy, takie jak „złożone przetwarzanie informacji". Ale nie były tak chwytliwe, jak sztuczna inteligencja – i termin utknął. Jeśli chodzi o McCarthy, kontynuował swoją misję promowania innowacji w sztucznej inteligencji. Rozważ następujące:

• Pod koniec lat pięćdziesiątych opracował język programowania Lisp, który był często używany w projektach AI ze względu na łatwość korzystania z danych nienumerycznych. Tworzył również koncepcje programowania, takie jak rekurencja, dynamiczne typowanie i zbieranie śmieci. Lisp jest nadal używany, na przykład w robotyce i aplikacjach biznesowych. Podczas gdy McCarthy rozwijał język, był także współzałożycielem Laboratorium Sztucznej Inteligencji MIT.

• W 1961 r. sformułował koncepcję podziału czasu komputerów, która miała przełomowy wpływ na branżę. Doprowadziło to również do rozwoju Internetu i przetwarzania w chmurze.

• Kilka lat później założył Laboratorium Sztucznej Inteligencji w Stanford.

• W 1969 r. napisał artykuł zatytułowany „Samochody sterowane komputerowo", w którym opisał, w jaki sposób człowiek może wprowadzać wskazówki za pomocą klawiatury, a kamera telewizyjna steruje pojazdem.

• Zdobył nagrodę Turinga w 1971 roku. Ta nagroda jest uważana za Nagrodę Nobla w dziedzinie informatyki.

W przemówieniu wygłoszonym w 2006 roku McCarthy zauważył, że jest zbyt optymistycznie nastawiony do rozwoju silnej sztucznej inteligencji. Według niego „my, ludzie, nie jesteśmy zbyt dobrzy w identyfikowaniu heurystyk, których sami używamy.

**Złoty Wiek AI**

Od 1956 do 1974 dziedzina sztucznej inteligencji była jednym z najgorętszych miejsc w świecie technologii. Głównym katalizatorem był szybki rozwój technologii komputerowych. Przeszli od ogromnych systemów opartych na lampach próżniowych do mniejszych systemów opartych na

układach scalonych, które były znacznie szybsze i miały większą pojemność. Rząd federalny również mocno inwestował w nowe technologie. Częściowo było to spowodowane ambitnymi celami programu kosmicznego Apollo i ciężkimi wymaganiami zimnej wojny. Jeśli chodzi o sztuczną inteligencję, głównym źródłem finansowania była Agencja Zaawansowanych Projektów Badawczych (ARPA), która została uruchomiona pod koniec lat 50. po szoku wywołanym przez rosyjskiego Sputnika. Wydatki na projekty wiązały się zwykle z kilkoma wymaganiami. Celem było inspirowanie przełomowych innowacji. Jeden z liderów ARPA, J.C.R. Licklider, miał motto „funduj ludzi, a nie projekty". W większości większość funduszy pochodziła ze Stanford, MIT, Lincoln Laboratories i Carnegie Mellon University. Poza IBM sektor prywatny był w niewielkim stopniu zaangażowany w rozwój sztucznej inteligencji. Należy pamiętać, że do połowy lat pięćdziesiątych IBM wycofał się i skupił na komercjalizacji swoich komputerów. Klienci obawiali się, że ta technologia doprowadzi do znacznej utraty miejsc pracy. Dlatego IBM nie chciał być obwiniany. Innymi słowy, wiele innowacji w sztucznej inteligencji wywodzi się ze środowiska akademickiego. Na przykład w 1959 roku Newell, Shaw i Simon nadal przesuwali granice w dziedzinie sztucznej inteligencji, opracowując program o nazwie „Ogólne rozwiązywanie problemów". Jak sama nazwa wskazuje, chodziło o rozwiązywanie problemów matematycznych, takich jak Wieża Hanoi. Ale było wiele innych programów, które próbowały osiągnąć pewien poziom silnej sztucznej inteligencji. Przykłady obejmowały:

• SAINT lub Symbolic Automatic INTegrator (1961): Ten program, stworzony przez badacza MIT Jamesa Slagle′a, pomógł rozwiązać problemy z rachunkiem różniczkowym dla studentów pierwszego roku. Zostałby zaktualizowany do innych programów, zwanych SIN i MACSYMA, które robiły znacznie bardziej zaawansowaną matematykę. SAINT był właściwie pierwszym przykładem systemu eksperckiego, kategorii sztucznej inteligencji

• ANALOGY (1963): Ten program został stworzony przez profesora MIT Thomasa Evansa. Aplikacja wykazała, że komputer może rozwiązać analogiczne problemy z testem IQ.

• STUDENT (1964): Pod kierunkiem Minsky′ego na MIT Daniel Bobrow stworzył tę aplikację AI do swojej pracy doktorskiej. System wykorzystywał przetwarzanie języka naturalnego (NLP) do rozwiązywania problemów algebry dla uczniów szkół średnich.

• ELIZA (1965): profesor MIT Joseph Weizenbaum zaprojektował ten program, który natychmiast stał się wielkim hitem. To nawet wywołało szum w prasie głównego nurtu. Został nazwany na cześć Elizy (na podstawie sztuki George'a Bernarda Shawa Pigmalion) i służył jako psychoanalityk. Użytkownik może wpisać pytania, a ELIZA udzieli porady (był pierwszym przykładem chatbota). Niektórzy, którzy go używali, myśleli, że program to prawdziwa osoba, co głęboko zaniepokoiło Weizenbauma, ponieważ podstawowa technologia była dość podstawowa.

• Widzenie komputerowe (1966): W legendarnej historii Marvin Minsky z MIT powiedział studentowi Geraldowi Jayowi Sussmanowi, aby spędził lato podłączając kamerę do komputera i zmuszając komputer do opisania tego, co zobaczył. Zrobił właśnie to i zbudował system, który wykrywał podstawowe wzorce. Było to pierwsze użycie widzenia komputerowego.

• Mac Hack (1968): profesor MIT Richard D. Greenblatt stworzył ten program do gry w szachy. Jako pierwszy grał w prawdziwych turniejach i otrzymał ocenę C.

• Hearsay I (koniec lat 60.): Profesor Raj Reddy opracował system ciągłego rozpoznawania mowy. Niektórzy z jego uczniów stworzyli następnie Dragon Systems, która stała się główną firmą technologiczną.

W tym okresie nastąpiło rozprzestrzenianie się artykułów naukowych i książek o AI. Niektóre z tematów obejmowały metody bayesowskie, uczenie maszynowe i widzenie. Ale generalnie istniały dwie główne teorie dotyczące sztucznej inteligencji. Jednym kierował Minsky, który powiedział, że muszą istnieć systemy symboliczne. Oznaczało to, że sztuczna inteligencja powinna opierać się na tradycyjnej logice komputerowej lub programowaniu wstępnym, czyli korzystaniu z podejść takich jak instrukcje If-Then-Else. Następnie był Frank Rosenblatt, który uważał, że sztuczna inteligencja musi używać systemów podobnych do mózgu, takich jak sieci neuronowe (to pole było również znane jako koneksjonizm). Ale zamiast nazywać wewnętrzne funkcjonowanie neuronów, nazwał je perceptronami. System byłby w stanie uczyć się w miarę przyjmowania danych w miarę upływu czasu. W 1957 roku Rosenblatt stworzył do tego celu pierwszy program komputerowy, nazwany Mark 1 Perceptron. Zawierał kamery, które pomagały odróżnić dwa obrazy (miały 20 × 20 pikseli). Perceptron Mark 1 używałby danych, które miały losowe wagi, a następnie przechodził przez następujący proces:

1. Weź wejście i wymyśl wyjście perceptronu.

2. Jeśli nie ma dopasowania, to

a. Jeśli wyjście powinno wynosić 0, ale było 1, waga dla 1 zostanie zmniejszona.

b. Jeśli wyjście powinno wynosić 1, ale było 0, waga dla 1 zostanie zwiększona.

3. Powtarzaj kroki 1 i 2, aż wyniki będą dokładne.

To było zdecydowanie przełomowe dla AI. New York Times napisał nawet dla Rosenblatta, wychwalając „Marynarka wojenna ujawniła dziś zarodek elektronicznego komputera, który oczekuje, że będzie w stanie chodzić, rozmawiać, widzieć, pisać, reprodukować się i być świadomym swojego istnienia". Ale wciąż były dokuczliwe problemy z perceptronem. Jednym z nich było to, że sieć neuronowa miała tylko jedną warstwę (głównie z powodu braku mocy obliczeniowej w tym czasie). Następnie badania nad mózgiem wciąż znajdowały się na początkowym etapie i nie oferowały wiele w zakresie zrozumienia zdolności poznawczych. Minsky napisałby wspólnie z Seymourem Papertem książkę zatytułowaną Perceptrons (1969). Autorzy bezlitośnie atakowali podejście Rosenblatta, które szybko zniknęło. Zauważ, że na początku lat pięćdziesiątych Minsky opracował prymitywną maszynę sieci neuronowych, na przykład używając setek lamp próżniowych i części zamiennych z bombowca B-24. Zauważył jednak, że technologia nie była w stanie funkcjonować. Rosenblatt próbował walczyć, ale było już za późno. Społeczność AI szybko zmieniła się w sieci neuronowe. Rosenblatt zginął kilka lat później w wypadku na łodzi. Miał 43 lata. Jednak w latach 80. jego idee zostałyby ożywione, co doprowadziłoby do rewolucji w sztucznej inteligencji, przede wszystkim wraz z rozwojem głębokiego uczenia się. W większości złoty wiek sztucznej inteligencji był swobodny i ekscytujący. Niektórzy z najzdolniejszych naukowców na świecie próbowali stworzyć maszyny, które naprawdę potrafią myśleć. Ale optymizm często dochodził do skrajności. W 1965 roku Simon powiedział, że w ciągu 20 lat maszyna może zrobić wszystko, co potrafi człowiek. Następnie w 1970 roku, w wywiadzie dla magazynu Life, powiedział, że stanie się to za 3–8 lat (nawiasem mówiąc, był doradcą przy filmie 2001: Odyseja kosmiczna). Niestety kolejna faza AI byłaby znacznie ciemniejsza. Było więcej naukowców, którzy stali się sceptyczni. Chyba najgłośniej wypowiadał się filozof Hubert Dreyfus. W książkach takich jak What Computers Still Can't Do: A Critique of Artificial Reason8 przedstawił swoje poglądy, że komputery nie są podobne do ludzkiego mózgu i że sztuczna inteligencja żałośnie nie spełniłaby wzniosłych oczekiwań.

**Zima AI**

Na początku lat 70. entuzjazm dla sztucznej inteligencji zaczął słabnąć. Stało się znane jako „zima AI", która trwała do 1980 roku (termin pochodzi od „zimy nuklearnej", wydarzenia polegającego na

wymieraniu, w którym słońce jest blokowane, a temperatury spadają na całym świecie). Mimo że sztuczna inteligencja poczyniła wiele kroków, nadal byli głównie akademiccy i zaangażowani w kontrolowane środowiska. W tym czasie systemy komputerowe były jeszcze ograniczone. Na przykład DEC PDP-11/45, który był powszechny w badaniach nad sztuczną inteligencją, miał możliwość rozszerzenia pamięci do zaledwie 128 KB. Język Lisp również nie był idealny dla systemów komputerowych. W świecie korporacji skoncentrowano się raczej na FORTRANIE. Ponadto, podczas rozumienia inteligencji i rozumowania wciąż było wiele złożonych aspektów. Tylko jedno to ujednoznacznienie. To sytuacja, w której słowo ma więcej niż jedno znaczenie. Zwiększa to trudność programu AI, ponieważ będzie również musiał zrozumieć kontekst. Wreszcie, środowisko gospodarcze w latach 70. było dalekie od solidnego. Nastąpiła utrzymująca się inflacja, powolny wzrost i zakłócenia dostaw, takie jak kryzys naftowy. Biorąc to wszystko pod uwagę, nie powinno dziwić, że rząd USA zaostrzał środki finansowe. W końcu dla planisty Pentagonu, jak użyteczny jest program, który może grać w szachy, rozwiązywać twierdzenia lub rozpoznawać podstawowe obrazy? Niestety niewiele. Godnym uwagi przykładem jest program badań rozumienia mowy na Uniwersytecie Carnegie Mellon. Dla Agencji Zaawansowanych Projektów Badawczych Obrony (DARPA) uważano, że ten system rozpoznawania mowy może być używany przez pilotów myśliwców do wydawania poleceń głosowych. Ale okazało się to niewykonalne. Jeden z programów, który nazywał się Harpia, mógł rozumieć 1011 słów, czyli tyle, ile zna typowy 3-latek. Urzędnicy DARPA faktycznie myśleli, że zostali oszukani i wyeliminowali roczny budżet programu w wysokości 3 milionów dolarów. Jednak największy cios w sztuczną inteligencję pochodził z raportu profesora Sir Jamesa Lighthilla, który ukazał się w 1973 roku. Finansowany przez brytyjski parlament był całkowitym odrzuceniem „wspaniałych celów" silnej sztucznej inteligencji. Zauważył, że głównym problemem była „eksplozja kombinatoryczna", która powodowała, że modele były zbyt skomplikowane i trudne do dostosowania. Raport stwierdzał: „W żadnej części pola odkrycia dokonane do tej pory nie wywarły większego wpływu, jaki wówczas obiecywano". Był takim pesymistą, że nie wierzył, że komputery będą w stanie rozpoznać obrazy lub pokonać wielkiego mistrza szachowego. Raport wywołał także publiczną debatę, która była transmitowana w telewizji BCC (filmy można znaleźć na YouTube). To był Lighthill przeciwko Donaldowi Michie, Richardowi Gregory′emu i Johnowi McCarthy′emu. Mimo że Lighthill miał ważne punkty - i ocenił dużą ilość badań - nie dostrzegł siły słabej sztucznej inteligencji. Ale to nie miało znaczenia, gdy nadeszła zima. Sprawy potoczyły się tak źle, że wielu badaczy zmieniło swoje ścieżki kariery. A ci, którzy nadal studiowali sztuczną inteligencję, często odnosili się do swojej pracy innymi terminami, takimi jak uczenie maszynowe, rozpoznawanie wzorców i informatyka!

**Powstanie i upadek systemów eksperckich**

Nawet podczas zimy AI nadal pojawiały się duże innowacje. Jednym z nich była propagacja wsteczna, która jest niezbędna do przypisywania wag dla sieci neuronowych. Potem nastąpił rozwój rekurencyjnej sieci neuronowej (RNN). Dzięki temu połączenia mogą przechodzić przez warstwy wejściowe i wyjściowe. Ale w latach 80. i 90. pojawiły się również systemy eksperckie. Kluczowym czynnikiem napędzającym był gwałtowny rozwój komputerów osobistych i minikomputerów. Systemy eksperckie opierały się na koncepcjach logiki symbolicznej Minsky′ego, obejmującej złożone ścieżki. Były one często opracowywane przez ekspertów z różnych dziedzin, takich jak medycyna, finanse i produkcja samochodów. Chociaż istnieją systemy eksperckie, które sięgają połowy lat sześćdziesiątych, nie znalazły one komercyjnego zastosowania aż do lat osiemdziesiątych. Przykładem był XCON (eXpert CONfigurer), który John McDermott opracował na Uniwersytecie Carnegie Mellon. System pozwalał na optymalizację doboru komponentów komputerowych i początkowo posiadał około 2500 reguł. Pomyśl o tym jako o pierwszym silniku rekomendacji. Od wprowadzenia na rynek w 1980 roku, okazał się dużą oszczędnością dla DEC dla linii komputerów VAX (około 40 milionów dolarów do 1986 roku). Gdy firmy zobaczyły sukces XCON, nastąpił boom na systemy eksperkie - przekształcenie

się w przemysł wart miliardy dolarów. Rząd japoński również dostrzegł okazję i zainwestował setki milionów, aby wzmocnić swój rynek krajowy. Jednak wyniki były w większości rozczarowaniem. Wiele innowacji miało miejsce w Stanach Zjednoczonych. Weź pod uwagę, że IBM użył systemu eksperckiego do swojego komputera Deep Blue. W 1996 roku w jednym z sześciu meczów pokonała wielkiego mistrza szachowego Garriego Kasparowa. Deep Blue, który IBM rozwijał od 1985 roku, przetwarzał 200 milionów pozycji na sekundę. Ale były problemy z systemami eksperckimi. Często były wąskie i trudne do zastosowania w innych kategoriach. Co więcej, w miarę jak systemy eksperckie rozrastały się, zarządzanie nimi i podawanie danych stało się trudniejsze. W rezultacie w wynikach było więcej błędów. Następnie testowanie systemów często okazywało się złożonym procesem. Nie oszukujmy się, były chwile, kiedy eksperci nie zgadzali się w fundamentalnych sprawach. Wreszcie, systemy eksperckie nie uczyły się z czasem. Zamiast tego konieczne były ciągłe aktualizacje podstawowych modeli logicznych, co znacznie zwiększyło koszty i złożoność. Pod koniec lat 80. systemy eksperckie zaczęły tracić na popularności w świecie biznesu, a wiele startupów połączyło się lub upadło. W rzeczywistości pomogło to spowodować kolejną zimę AI, która trwała do około 1993 roku. Komputery PC szybko zjadały rynki sprzętu z wyższej półki, co oznaczało gwałtowny spadek liczby maszyn opartych na Lisp. Finansowanie rządowe na sztuczną inteligencję, na przykład z DARPA, również wyschło. Z drugiej strony zimna wojna szybko dobiegała końca wraz z upadkiem Związku Radzieckiego.

**Sieci neuronowe i głębokie uczenie**

Jako nastolatek w latach 50. Geoffrey Hinton chciał zostać profesorem i studiować sztuczną inteligencję. Pochodził z rodziny wybitnych naukowców (jego prapradziadkiem był George Boole). Jego mama często mawiała: „Bądź naukowcem albo porażką". Nawet podczas pierwszej zimy AI Hinton pasjonował się sztuczną inteligencją i był przekonany, że podejście Rosenblatta do sieci neuronowych było właściwą ścieżką. Tak więc w 1972 otrzymał doktorat na ten temat na Uniwersytecie w Edynburgu. Ale w tym okresie wiele osób myślało, że Hinton marnuje swój czas i talenty. AI była zasadniczo uważana za obszar marginesowy. Nie myślano o tym nawet jako o nauce. Ale to tylko bardziej zachęciło Hintona. Cieszył się swoją pozycją outsidera i wiedział, że jego pomysły w końcu zwyciężą. Hinton zdał sobie sprawę, że największą przeszkodą dla sztucznej inteligencji jest moc komputera. Ale widział też, że czas jest po jego stronie. Prawo Moore′a przewidywało, że liczba elementów w chipie podwaja się co 18 miesięcy. W międzyczasie Hinton pracował niestrudzenie nad rozwojem podstawowych teorii sieci neuronowych – czegoś, co w końcu stało się znane jako głębokie uczenie. W 1986 roku napisał – wraz z Davidem Rumelhartem i Ronaldem J. Williamsem – przełomowy artykuł zatytułowany „Learning Representations by Back-propagating Errors". Przedstawiono kluczowe procesy wykorzystania wstecznej propagacji w sieciach neuronowych. W rezultacie nastąpiła znaczna poprawa dokładności, na przykład w przypadku przewidywań i rozpoznawania wizualnego. Oczywiście nie działo się to w odosobnieniu. Pionierska praca Hintona opierała się na osiągnięciach innych badaczy, którzy również wierzyli w sieci neuronowe. A jego własne badania pobudziły lawinę innych ważnych osiągnięć:

• 1980: Kunihiko Fukushima stworzyła Neocognitron, system rozpoznawania wzorców, który stał się podstawą splotowych sieci neuronowych. Były one oparte na korze wzrokowej zwierząt.

• 1982: John Hopfield opracował „Sieci Hopfielda". Była to w zasadzie rekurencyjna sieć neuronowa.

• 1989: Yann LeCun połączył sieci konwolucyjne z propagacją wsteczną. Takie podejście znalazłoby przypadki użycia z analizą odręcznych czeków.

• 1989: Rozprawa doktorska Christophera Watkinsa „Uczenie się z opóźnionych nagród" opisuje Q-Learning. Był to duży postęp w pomaganiu w uczeniu się przez wzmacnianie.

• 1998: Yann LeCun opublikował „Uczenie oparte na gradientach stosowane do rozpoznawania dokumentów", w którym wykorzystano algorytmy zstępujące do poprawy sieci neuronowych.

**Technologiczne czynniki napędzające nowoczesną sztuczną inteligencję**

Oprócz postępów w zakresie nowych podejść koncepcyjnych, teorii i modeli, sztuczna inteligencja miała kilka innych ważnych czynników. Oto spojrzenie na główne:

• Wybuchowy wzrost zbiorów danych: Internet był głównym czynnikiem dla sztucznej inteligencji, ponieważ umożliwił tworzenie ogromnych zbiorów danych. W następnym rozdziale przyjrzymy się, jak dane zmieniły tę technologię.

• Infrastruktura: być może najbardziej znaczącą firmą dla sztucznej inteligencji w ciągu ostatnich 15 lat był Google. Aby nadążyć za indeksowaniem sieci – która rosła w zawrotnym tempie – firma musiała wymyślić kreatywne podejście do budowy skalowalnych systemów. Rezultatem są innowacje w klastrach serwerów towarowych, wirtualizacji i oprogramowaniu open source. Google był również jednym z pierwszych użytkowników głębokiego uczenia się, wraz z uruchomieniem projektu „Google Brain" w 2011 roku. Aha, a kilka lat później firma zatrudniła Hintona.

• Procesory graficzne (Graphics Processing Units): Ta technologia chipowa, której pionierem była firma NVIDIA, była pierwotnie przeznaczona do szybkiej grafiki w grach. Ale architektura GPU byłaby ostatecznie idealna również dla sztucznej inteligencji. Zauważ, że większość badań dotyczących głębokiego uczenia się odbywa się za pomocą tych chipów. Powodem jest to, że przy przetwarzaniu równoległym prędkość wynosi wielokrotności wyższe niż w przypadku tradycyjnych procesorów. Oznacza to, że obliczenie modelu może zająć dzień lub dwa w porównaniu z tygodniami lub nawet miesiącami. Wszystkie te czynniki wzmocniły się, dodając paliwa do rozwoju sztucznej inteligencji. Co więcej, czynniki te prawdopodobnie pozostaną żywe przez wiele nadchodzących lat.

**Struktura AI**

Omówiliśmy wiele pojęć. Teraz zrozumienie organizacji AI może być trudne. Na przykład często zdarza się, że terminy takie jak uczenie maszynowe i uczenie głębokie są mylone. Ale ważne jest, aby zrozumieć różnice, które omówimy szczegółowo w dalszej części tej książki. Ale w ogólnym ujęciu rzeczy, Rysunek pokazuje, w jaki sposób główne elementy sztucznej inteligencji są ze sobą powiązane. Na szczycie znajduje się sztuczna inteligencja, która obejmuje szeroką gamę teorii i technologii. Następnie możesz podzielić to na dwie główne kategorie: uczenie maszynowe i uczenie głębokie.

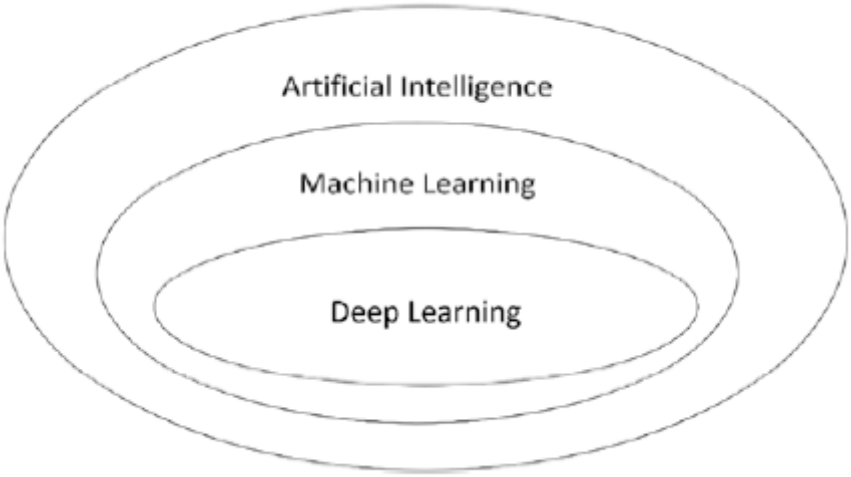

**Wniosek**

Nie ma nic nowego w tym, że sztuczna inteligencja jest dziś modnym hasłem. W ramach tego terminu pojawiły się różne cykle skręcające żołądek, takie jak boom-bust. Może po raz kolejny wyjdzie z łask? Być może. Ale tym razem istnieją prawdziwe innowacje związane ze sztuczną inteligencją, które zmieniają firmy. Mega techniczne firmy takie jak Google, Microsoft i Facebook uważają tę kategorię za główny priorytet. Podsumowując, wydaje się, że to dobry zakład, że sztuczna inteligencja będzie nadal się rozwijać i zmieniać nasz świat.

**Kluczowe dania na wynos**

• Rozwój technologii często trwa dłużej niż pierwotnie zakładano.

• AI to nie tylko informatyka i matematyka. Kluczowy wkład wniosły takie dziedziny, jak ekonomia, neuronauka, psychologia, językoznawstwo, elektrotechnika, matematyka i filozofia.

• Istnieją dwa główne typy AI: słaba i silna. Silny jest tam, gdzie maszyny stają się samoświadome, podczas gdy słaby jest w przypadku systemów, które koncentrują się na określonych zadaniach. Obecnie sztuczna inteligencja jest na słabym etapie.

• Test Turinga jest powszechnym sposobem sprawdzenia, czy maszyna potrafi myśleć. Opiera się na tym, czy ktoś naprawdę myśli, że system jest inteligentny.

• Niektóre z kluczowych czynników napędzających sztuczną inteligencję obejmują nowe teorie badaczy takich jak Hinton, gwałtowny wzrost danych, nową infrastrukturę technologiczną i procesory graficzne.

**Dane: Paliwo dla AI**

Pinterest to jeden z najgorętszych start-upów w Dolinie Krzemowej, umożliwiający użytkownikom przypinanie ulubionych elementów w celu tworzenia angażujących tablic. Witryna ma 250 milionów MAU (aktywnych użytkowników miesięcznie) i odnotowała przychody w wysokości 756 milionów dolarów w 2018 roku. Popularną aktywnością Pinteresta jest planowanie ślubów. Przyszła panna młoda będzie miała szpilki do sukni, lokale, miejsc na miesiąc miodowy, ciasta, zaproszenia i tak dalej. Oznacza to również, że Pinterest ma tę zaletę, że gromadzi ogromne ilości cennych danych. Część tego pomaga zapewnić ukierunkowane reklamy. Istnieją jednak również możliwości prowadzenia kampanii e-mailowych. W jednym przypadku Pinterest wysłał taki, który mówił:

Żenisz się! A ponieważ uwielbiamy planowanie ślubów - zwłaszcza wszystkich uroczych papeterii - zapraszamy do przeglądania naszych najlepszych plansz, których kuratorami są graficy, fotografowie i inne przyszłe panny młode, wszystkie Pinnerki z bystrym okiem i myślącym o małżeństwie.

Problem: wielu odbiorców wiadomości e-mail było już w związku małżeńskim lub nie spodziewało się, że wkrótce się pobierze.

Pinterest działał szybko i przeprosił:

Co tydzień wysyłamy e-mailem kolekcje pinów i tablic dla poszczególnych kategorii do pinnerów, którzy mamy nadzieję, że będą nimi zainteresowani. Niestety, jeden z tych ostatnich e-maili sugerował, że pinners faktycznie brali ślub, a nie tylko potencjalnie zainteresowani treściami związanymi ze ślubem. Przykro nam, że wypadliśmy jak apodyktyczna matka, która zawsze pyta, kiedy znajdziesz miłego chłopca lub dziewczynę.

To ważna lekcja. Nawet niektóre z najbardziej zaawansowanych technologicznie firm to rozwalają. Na przykład w niektórych przypadkach dane mogą być bezbłędne, ale rezultatem może być porażka. Rozważ sprawę z Target. Firma wykorzystała swoje ogromne dane, aby wysyłać spersonalizowane oferty do przyszłych matek. Zostało to oparte na tych klientach, którzy dokonali określonych rodzajów zakupów, takich jak bezzapachowe balsamy. System Target utworzyłby wynik ciąży, który dostarczyłby nawet szacunkowych terminów porodu. Cóż, ojciec jednego z klientów zobaczył e-mail i był wściekły, mówiąc, że jego córka nie jest w ciąży. Ale była – i tak, ukrywała ten fakt przed ojcem. Nie ma wątpliwości, że dane są niezwykle potężne i krytyczne dla sztucznej inteligencji. Ale musisz być rozważny i rozumieć ryzyko.

**Podstawy danych**

Dobrze jest rozumieć żargon danych. Przede wszystkim bit (skrót od „cyfra binarna”) to najmniejsza forma danych w komputerze. Pomyśl o tym jak o atomie. Bit może mieć wartość 0 lub 1, co jest binarne. Jest również powszechnie używany do pomiaru ilości przesyłanych danych (powiedzmy w sieci lub Internecie). Z drugiej strony bajt służy głównie do przechowywania. Oczywiście liczba bajtów może bardzo szybko rosnąć. Zobaczmy :

**Jednostka: Wartość: Przypadek użycia**

Megabajt: 1000 kilobajtów: Mała książka

Gigabajt: 1000 megabajtów: około 230 utworów

Terabajt: 1000 gigabajtów: 500 godzin filmów

Petabajt: 1000 terabajtów: pięć lat systemu obserwacji Ziemi (EOS)

Eksabajt: 1000 petabajtów: Cała Biblioteka Kongresu 3000 razy więcej

Zettabyte : 1000 eksabajtów : 36 000 lat wideo HD-TV

Yottabajty: 1000 zettabajtów: Wymagałoby to centrum danych wielkości Delaware i Rhode Island łącznie

Dane mogą również pochodzić z wielu różnych źródeł. Oto tylko próbka:

• Internetowe/społecznościowe (Facebook, Twitter, Instagram, YouTube)

• Dane biometryczne (monitorowanie kondycji, testy genetyczne)

• Systemy punktów sprzedaży (ze sklepów stacjonarnych i witryn e-commerce)

• Internet rzeczy lub IoT (tagi identyfikacyjne i urządzenia inteligentne)

• Systemy chmurowe (aplikacje biznesowe, takie jak Salesforce.com)

• Korporacyjne bazy danych i arkusze kalkulacyjne

**Rodzaje danych**

Istnieją cztery sposoby organizowania danych. Po pierwsze, istnieją dane strukturalne, które zwykle są przechowywane w relacyjnej bazie danych lub arkuszu kalkulacyjnym. Oto kilka przykładów:

• Informacje finansowe

• Numery ubezpieczenia społecznego

• Adresy

• Informacje o produkcie

• Dane punktów sprzedaży

• Numery telefoniczne

W większości przypadków łatwiej jest pracować z danymi strukturalnymi. Dane te często pochodzą z systemów CRM (zarządzanie relacjami z klientami) i ERP (planowanie zasobów przedsiębiorstwa) – i zwykle mają mniejsze ilości. Wydaje się również, że jest to prostsze, powiedzmy pod względem analizy. Istnieją różne programy BI (Business Intelligence), które mogą pomóc uzyskać wgląd w dane strukturalne. Jednak tego typu dane stanowią około 20% projektu AI. Większość będzie pochodzić z danych nieustrukturyzowanych, czyli informacji, które nie mają wstępnie zdefiniowanego formatowania. Musisz to zrobić sam, co może być żmudne i czasochłonne. Istnieją jednak narzędzia, takie jak bazy danych nowej generacji, takie jak te oparte na NoSQL, które mogą pomóc w tym procesie. Systemy AI są również skuteczne pod względem zarządzania danymi i ich strukturyzacji, ponieważ algorytmy potrafią rozpoznawać wzorce. Oto przykłady nieuporządkowanych danych:

• Obrazy

• Filmy

• Pliki audio

• Pliki tekstowe

• Informacje z sieci społecznościowych, takie jak tweety i posty

• Zdjęcia satelitarne

Teraz są pewne dane, które są hybrydą źródeł ustrukturyzowanych i nieustrukturyzowanych, zwanych danymi częściowo ustrukturyzowanymi. Informacje mają kilka wewnętrznych znaczników, które pomagają w kategoryzacji. Przykładami danych częściowo ustrukturyzowanych są XML (Extensible Markup Language), który opiera się na różnych regułach identyfikacji elementów dokumentu, oraz JSON ( JavaScript Object Notation), który jest sposobem przesyłania informacji w sieci poprzez API (Programowanie aplikacji interfejsy). Ale dane częściowo ustrukturyzowane stanowią tylko około 5% do 10% wszystkich danych. Wreszcie istnieją dane szeregów czasowych, które mogą dotyczyć zarówno danych ustrukturyzowanych, nieustrukturyzowanych, jak i częściowo ustrukturyzowanych. Ten rodzaj informacji służy do interakcji, powiedzmy do śledzenia „podróży klienta". Będzie to zbieranie informacji, gdy użytkownik wchodzi na stronę internetową, korzysta z aplikacji, a nawet wchodzi do sklepu. Jednak tego rodzaju dane są często chaotyczne i trudne do zrozumienia. Częściowo wynika to ze zrozumienia intencji użytkowników, które mogą się znacznie różnić. Istnieją również ogromne ilości danych interaktywnych, które mogą obejmować biliony punktów danych. Aha, a mierniki sukcesu mogą nie być jasne. Dlaczego użytkownik robi coś w witrynie? Ale sztuczna inteligencja prawdopodobnie będzie miała kluczowe znaczenie dla takich problemów. Chociaż w większości analiza danych szeregów czasowych jest wciąż na wczesnym etapie.

**Big Data**

Wraz z wszechobecnym dostępem do Internetu, urządzeń mobilnych i urządzeń do noszenia, nastąpiło uwolnienie potoku danych. Co sekundę Google przetwarza ponad 40 000 wyszukiwań, czyli 3,5 miliarda dziennie. Z minuty na minutę użytkownicy Snapchata udostępniają 527 760 zdjęć, a użytkownicy YouTube oglądają ponad 4,1 miliona filmów. Są też staromodne systemy, takie jak e-maile, które nadal odnotowują znaczny wzrost. Co minutę wysyłanych jest 156 milionów wiadomości. Ale jest jeszcze coś do rozważenia: firmy i maszyny również generują ogromne ilości danych. Według badań Statista do 2020 r. liczba czujników osiągnie 12,86 miliarda. W świetle tego wydaje się, że warto założyć, że ilość danych będzie rosła w szybkim tempie. W raporcie International Data Corporation (IDC) zatytułowanym „Data Age 2025" oczekuje się, że do 2025 roku ilość utworzonych danych osiągnie oszałamiającą liczbę 163 zetabajtów. To około dziesięciokrotnie więcej niż w 2017 roku. Aby sobie z tym wszystkim poradzić, powstała kategoria technologii zwana Big Data. W ten sposób Oracle wyjaśnia znaczenie tego trendu: Dzisiaj duże zbiory danych stały się kapitałem. Pomyśl o największych światowych firmach technologicznych. Duża część oferowanej przez nich wartości pochodzi z ich danych, które stale analizują, aby zwiększyć wydajność i opracować nowe produkty. A więc tak, Big Data pozostanie krytyczną częścią wielu projektów AI. Czym właściwie jest Big Data? Jaka jest dobra definicja? Właściwie nie ma ani jednego, chociaż jest wiele firm, które skupiają się na tym rynku! Ale Big Data ma następujące cechy, zwane trzema V (analityk Gartnera, Doug Laney, wymyślił tę strukturę w 2001 r.): Volume [wolumen] , Variety [różnorodność] i Veloity [prędkość].

**Wolumen**

Taka jest skala danych, które często są nieustrukturyzowane. Nie ma twardej i szybkiej reguły na progu, ale zwykle jest to dziesiątki terabajtów. Wolumen to często duże wyzwanie, jeśli chodzi o Big Data. Jednak przetwarzanie w chmurze i bazy danych nowej generacji bardzo pomogły pod względem pojemności i niższych kosztów.

**Różnorodność**

Opisuje to różnorodność danych, powiedzmy kombinację danych ustrukturyzowanych, częściowo ustrukturyzowanych i nieustrukturyzowanych (wyjaśnionych powyżej). Pokazuje również różne źródła

danych i zastosowań. Bez wątpienia wysoki wzrost liczby nieustrukturyzowanych danych był kluczem do różnorodności Big Data. Zarządzanie tym może szybko stać się poważnym wyzwaniem. Jednak uczenie maszynowe jest często czymś, co może pomóc usprawnić ten proces.

**Prędkość**

Pokazuje szybkość, z jaką tworzone są dane. Jak widać wcześniej w tym rozdziale, serwisy takie jak YouTube i Snapchat charakteryzują się ekstremalną szybkością (często nazywa się to „remizą" danych). Wymaga to dużych inwestycji w technologie i centra danych nowej generacji. Dane są również często przetwarzane w pamięci, a nie w systemach dyskowych. Z powodu tych problemów prędkość jest często uważana za najtrudniejszą, jeśli chodzi o trzy V. Spójrzmy prawdzie w oczy, w dzisiejszym cyfrowym świecie ludzie chcą swoich danych tak szybko, jak to możliwe. Jeśli będzie zbyt wolny, ludzie będą sfrustrowani i odejdą gdzieś indziej. Jednak z biegiem lat, wraz z ewolucją Big Data, dodano więcej V. Obecnie jest ich kilkanaście. Ale oto niektóre z typowych:

• Veracity [Prawdziwość]: dotyczy danych, które są uważane za dokładne. W tym rozdziale przyjrzymy się niektórym technikom oceny prawdziwości.

• Value [Wartość]: pokazuje przydatność danych. Często chodzi o posiadanie zaufanego źródła.

• Vaaraibility [Zmienność]: Oznacza to, że dane zwykle zmieniają się w czasie. Tak jest na przykład w przypadku treści w mediach społecznościowych, które mogą się zmieniać w oparciu o ogólne nastroje dotyczące nowych wydarzeń i najświeższych wiadomości.

• Visualisation [Wizualizacja]: wykorzystuje wizualizacje podobne do wykresów, aby lepiej zrozumieć dane.

Jak widać, zarządzanie Big Data składa się z wielu ruchomych części, co prowadzi do złożoności. To pomaga wyjaśnić, dlaczego wiele firm nadal wykorzystuje tylko niewielki ułamek swoich danych.

**Bazy danych i inne narzędzia**

Istnieje mnóstwo narzędzi, które pomagają w przetwarzaniu danych. Sednem tego jest baza danych. Nie powinno dziwić, że na przestrzeni dziesięcioleci nastąpiła ewolucja tej kluczowej technologii. Ale nawet starsze technologie, takie jak relacyjne bazy danych, są nadal bardzo często używane. Jeśli chodzi o dane o znaczeniu krytycznym, firmy niechętnie wprowadzają zmiany, nawet jeśli niosą ze sobą wyraźne korzyści. Aby zrozumieć ten rynek, cofnijmy się do 1970 r., kiedy informatyk IBM Edgar Codd opublikował „A Relational Model of Data for Large Shared Data Banks". To było przełomowe, ponieważ wprowadziło strukturę relacyjnych baz danych. Do tego momentu bazy danych były dość złożone i miały sztywną strukturę jako hierarchie. To sprawiło, że wyszukiwanie i znajdowanie relacji w danych było czasochłonne. Jeśli chodzi o podejście do relacyjnych baz danych Codda, zostało ono zbudowane dla bardziej nowoczesnych maszyn. Język skryptowy SQL był łatwy w użyciu, pozwalając na operacje CRUD (Create, Read, Update i Delete). Tabele miały również połączenia z kluczami podstawowymi i obcymi, które tworzyły ważne połączenia, takie jak:

• Jeden do jednego: Jeden wiersz w tabeli jest połączony tylko z jednym wierszem w innej tabeli. Przykład: Numer prawa jazdy, który jest unikalny, jest powiązany z jednym pracownikiem.

• Jeden-do-wielu: W tym miejscu jeden wiersz w tabeli jest połączony z innymi tabelami. Przykład: Klient ma wiele zamówień zakupu.

• Wiele do wielu: Wiersze z jednej tabeli są skojarzone z wierszami innej. Przykład: Różne raporty mają różnych autorów.

Przy tego typu strukturach relacyjna baza danych może usprawnić proces tworzenia zaawansowanych raportów. To było naprawdę rewolucyjne. Jednak pomimo zalet, IBM nie był zainteresowany technologią i nadal skupiał się na własnych systemach. Firma uznała, że relacyjne bazy danych są zbyt wolne i kruche dla klientów korporacyjnych. Ale był ktoś, kto miał inne zdanie w tej sprawie: Larry Ellison. Przeczytał artykuł Codda i wiedział, że to zmieni zasady gry. Aby to udowodnić, w 1977 r. współzałożył firmę Oracle, skupiając się na budowaniu relacyjnych baz danych, które szybko stałyby się ogromnym rynkiem. Dopiero w 1993 roku IBM wyszedł z własną relacyjną bazą danych DB2. Ale było za późno. W tym czasie Oracle był liderem na rynku baz danych. W latach 80. i 90. relacyjna baza danych była standardem dla systemów mainframe i klient-serwer. Ale kiedy Big Data stało się czynnikiem, technologia miała poważne wady, takie jak:

• Rozciąganie się danych: Z biegiem czasu różne bazy danych rozprzestrzeniłyby się w całej organizacji. W rezultacie centralizacja danych stała się trudniejsza.

• Nowe środowiska: Technologia relacyjnych baz danych nie została stworzona do przetwarzania w chmurze, danych o dużej prędkości lub danych nieustrukturyzowanych.

• Wysokie koszty: relacyjne bazy danych mogą być drogie. Oznacza to, że korzystanie z technologii w projektach AI może być niedopuszczalne.

• Wyzwania programistyczne: Współczesne tworzenie oprogramowania w dużej mierze opiera się na iteracji. Ale relacyjne bazy danych okazały się trudne w tym procesie.

Pod koniec lat 90. opracowano projekty open source, które miały pomóc w tworzeniu systemów baz danych nowej generacji. Być może najbardziej krytyczny pochodził od Douga Cuttinga, który opracował Lucene, który służył do wyszukiwania tekstu. Technologia została oparta na wyrafinowanym systemie indeksów, który umożliwiał działanie z niskimi opóźnieniami. Lucene stał się natychmiastowym hitem i zaczął ewoluować, tak jak Apache Nutch, który sprawnie przeszukiwał sieć i przechowywał dane w indeksie. Ale był duży problem: aby przeszukiwać sieć, potrzebna była infrastruktura zdolna do hiperskalowania. Tak więc pod koniec 2003 roku Cutting rozpoczął prace nad nowym rodzajem platformy infrastrukturalnej, która może rozwiązać ten problem. Pomysł wpadł na pomysł z artykułu opublikowanego przez Google, który opisywał jego ogromny system plików. Rok później Cutting zbudował swoją nową platformę, która pozwoliła na wyrafinowane przechowywanie bez komplikacji. U podstaw tego był MapReduce, który umożliwiał przetwarzanie na wielu serwerach. Wyniki byłyby następnie scalane, umożliwiając tworzenie znaczących raportów. Ostatecznie system Cutting przekształcił się w platformę o nazwie Hadoop - i byłby niezbędny do zarządzania Big Data, na przykład do tworzenia wyrafinowanych hurtowni danych. Początkowo Yahoo! używał go, a następnie szybko się rozprzestrzenił, ponieważ firmy takie jak Facebook i Twitter przyjęły tę technologię. Firmy te mogły teraz uzyskać pełny widok swoich danych, a nie tylko ich podzbiorów. Oznaczało to, że mogą być bardziej efektywne eksperymenty z danymi. Jednak jako projekt open source Hadoop wciąż nie dysponował zaawansowanymi systemami dla klientów korporacyjnych. Aby sobie z tym poradzić, startup Hortonworks zbudował nowe technologie, takie jak YARN, na platformie Hadoop. Posiadał funkcje, takie jak przetwarzanie analityczne w pamięci, przetwarzanie danych online i interaktywne przetwarzanie SQL. Takie możliwości wspierały przyjęcie Hadoopa w wielu korporacjach. Ale oczywiście pojawiły się inne projekty hurtowni danych typu open source. Te dobrze znane, jak Storm i Spark, skupiały się na strumieniowaniu danych. Z drugiej strony Hadoop został zoptymalizowany pod kątem przetwarzania wsadowego. Oprócz hurtowni danych pojawiła się również innowacja tradycyjnego biznesu bazodanowego. Często były one znane jako systemy NoSQL. Weź MongoDB. Rozpoczęło się jako projekt open source i przekształciło się w odnoszącą sukcesy firmę, która weszła na giełdę w październiku 2017 r. Baza danych MongoDB, która ma ponad 40 milionów pobrań, została

stworzona do obsługi środowisk chmurowych, lokalnych i hybrydowych. Istnieje również duża elastyczność strukturyzowania danych, która opiera się na modelu dokumentu. MongoDB może nawet zarządzać ustrukturyzowanymi i nieustrukturyzowanymi danymi na dużą skalę petabajtów. Chociaż startupy były źródłem innowacji w systemach baz danych i pamięci masowej, ważne jest, aby pamiętać, że operatorzy mega tech również byli krytyczni. Z drugiej strony firmy takie jak Amazon.com i Google musiały znaleźć sposoby radzenia sobie z ogromną ilością danych ze względu na potrzebę zarządzania swoimi ogromnymi platformami. Jedną z innowacji jest jezioro danych, które umożliwia bezproblemowe przechowywanie ustrukturyzowanych i nieustrukturyzowanych danych. Pamiętaj, że nie ma potrzeby ponownego formatowania danych. Jezioro danych poradzi sobie z tym i umożliwi szybkie wykonywanie funkcji AI. Według badania przeprowadzonego przez Aberdeen firmy korzystające z tej technologii osiągają średnio 9% wzrost organiczny w porównaniu z tymi, które tego nie robią. Teraz nie oznacza to, że musisz pozbyć się hurtowni danych. Oba służą raczej określonym funkcjom i przypadkom użycia. Hurtownia danych jest ogólnie dobra w przypadku danych strukturalnych, podczas gdy jezioro danych jest lepsze w przypadku zróżnicowanych środowisk. Co więcej, prawdopodobnie duża część danych nigdy nie zostanie wykorzystana. W większości dostępnych jest mnóstwo narzędzi. I oczekuj, że w miarę jak środowiska danych stają się coraz bardziej złożone, rozwinie się więcej. Ale to nie znaczy, że powinieneś wybrać najnowszą technologię. Ponownie, nawet starsze relacyjne bazy danych mogą być całkiem skuteczne w przypadku projektów AI. Kluczem jest zrozumienie zalet i wad każdego z nich, a następnie opracowanie jasnej strategii.

**Przetwarzanie danych**

Ilość pieniędzy wydanych na dane jest ogromna. Według IDC, przewiduje się, że wydatki na Big Data i rozwiązania analityczne wzrosną z 166 miliardów dolarów w 2018 r. do 260 miliardów dolarów do 2022 r.11 Stanowi to 11,9% łączną stopę wzrostu rocznego. Najwięksi wydający to banki, dyskretni producenci, producenci procesów, profesjonalne firmy usługowe i rząd federalny. Stanowią one blisko połowę ogólnej kwoty. Oto, co powiedziała Jessica Goepfert z IDC — wiceprezes programu (VP) Customer Insights and Analysis:

Na wysokim poziomie organizacje zwracają się do Big Data i rozwiązań analitycznych, aby poruszać się po konwergencji swojego świata fizycznego i cyfrowego. Ta transformacja przybiera różny kształt w zależności od branży. Na przykład w bankowości i handlu detalicznym – w dwóch najszybciej rozwijających się obszarach Big Data i inwestycji w analitykę – chodzi o zarządzanie i ożywianie doświadczeń klientów. . Podczas gdy w branży produkcyjnej, firmy wymyślają się na nowo, aby zasadniczo stać się firmami high-tech, wykorzystując swoje produkty jako platformę umożliwiającą i dostarczającą usługi cyfrowe.

Ale wysoki poziom wydatków niekoniecznie przekłada się na dobre wyniki. Badanie Gartnera szacuje, że około 85% projektów Big Data jest porzucanych, zanim dotrą do etapu pilotażowego.13 Niektóre z przyczyn są następujące:

- Brak wyraźnego skupienia
- Brudne dane
- Inwestycja w niewłaściwe narzędzia informatyczne
- Problemy z gromadzeniem danych
- Brak akceptacji ze strony kluczowych interesariuszy i czempionów w organizacji.

W związku z tym bardzo ważne jest posiadanie procesu danych. Pomimo tego, że istnieje wiele podejść -często wychwalanych przez dostawców oprogramowania — jest jedno, które cieszy się powszechną akceptacją. Grupa ekspertów, programistów, konsultantów i naukowców stworzyła proces CRISP-DM pod koniec lat 90-tych. W tym rozdziale przyjrzymy się krokom od 1 do 3. Następnie w dalszej części książki omówimy pozostałe (czyli przyjrzymy się modelowaniu i ocenie w rozdziale 3 i wdrażaniu w rozdziale 8). Należy zauważyć, że kroki 1–3 mogą stanowić 80% czasu przetwarzania danych, co opiera się na doświadczeniu Atifa Kureishy, który jest globalnym wiceprezesem ds. pojawiających się praktyk w firmie Teradata.14 Wynika to z takich czynników, jak: Dane nie są dobrze zorganizowane i pochodzą z różnych źródeł (od różnych dostawców lub silosów w organizacji), nie ma wystarczającego skupienia na narzędziach automatyzacji, a wstępne planowanie było niewystarczające dla zakresu projektu. Warto również pamiętać, że proces CRISP-DM nie jest procesem ściśle liniowym. Kiedy mamy do czynienia z danymi, może być wiele iteracji. Na przykład może być wiele prób wymyślenia właściwych danych i przetestowania ich.

**Krok #1-Zrozumienie biznesowe**

Powinieneś mieć jasny obraz problemu biznesowego do rozwiązania. Kilka przykładów:

• W jaki sposób korekta ceny może wpłynąć na sprzedaż?

• Czy zmiana tekstu doprowadzi do poprawy konwersji reklam cyfrowych?

• Czy spadek zaangażowania oznacza wzrost rezygnacji?

Następnie musisz ustalić, jak będziesz mierzyć sukces. Czy to możliwe, że sprzedaż powinna wzrosnąć o co najmniej 1% lub że konwersje powinny wzrosnąć o 5%? Oto przypadek Prasada Vuyyuru, który jest partnerem w Enterprise Insights Practice firmy Infosys Consulting:

Identyfikacja problemu biznesowego do rozwiązania za pomocą sztucznej inteligencji i ocena, jaka wartość zostanie stworzona, ma kluczowe znaczenie dla powodzenia wszystkich projektów AI. Bez tak starannego skupienia się na wartości biznesowej projekty AI mogą nie zostać przyjęte w organizacji. Doświadczenie AB Inbev w wykorzystywaniu sztucznej inteligencji do identyfikacji silników linii pakujących, które mogą ulec awarii, jest doskonałym przykładem tego, jak sztuczna inteligencja tworzy praktyczną wartość. ABInbev zainstalował 20 bezprzewodowych czujników do pomiaru drgań na silnikach linii pakujących. Porównali dźwięki z normalnie działającymi silnikami, aby zidentyfikować anomalie, które przewidywały ostateczną awarię silników.

Niezależnie od celu ważne jest, aby proces był wolny od wszelkich uprzedzeń lub uprzedzeń. Celem jest znalezienie najlepszych wyników. Bez wątpienia w niektórych przypadkach nie będzie satysfakcjonującego wyniku. Lub w innych sytuacjach mogą być duże niespodzianki. Słynny przykład tego pochodzi z książki „Moneyball" Michaela Lewisa, która również została nakręcona w 2011 roku na film z Bradem Pittem w roli głównej. To prawdziwa historia o tym, jak Oakland A wykorzystał techniki analizy danych do rekrutacji graczy. Tradycją w baseballu było poleganie na wskaźnikach, takich jak średnie mrugnięcia. Jednak przy użyciu wyrafinowanych technik analizy danych uzyskano zaskakujące wyniki. Oakland A zdał sobie sprawę, że należy skupić się na obijaniu i procentach bazowych. Dzięki tym informacjom zespół był w stanie zrekrutować najlepszych graczy na niższych poziomach wynagrodzenia. W rezultacie musisz być otwarty i chętny do eksperymentowania. W kroku #1 powinieneś również zebrać odpowiedni zespół do projektu. Teraz, o ile nie pracujesz w firmie takiej jak Facebook czy Google, nie będziesz miał luksusu wyboru grupy doktorów z zakresu uczenia maszynowego i data science. Taki talent jest dość rzadki i drogi. Ale nie potrzebujesz też armii najwyższej klasy inżynierów do projektu AI. W rzeczywistości stosowanie modeli uczenia maszynowego

i głębokiego uczenia się staje się coraz łatwiejsze dzięki systemom open source, takim jak TensorFlow i platformom w chmurze Google, Amazon.com i Microsoft. Innymi słowy, możesz potrzebować tylko kilku osób z doświadczeniem w nauce danych. Następnie powinieneś znaleźć osoby – prawdopodobnie z Twojej organizacji – które mają odpowiednią wiedzę specjalistyczną w zakresie domeny dla projektu AI. Będą musieli przemyśleć przepływy pracy, modele i dane szkoleniowe – ze szczególnym zrozumieniem branży i wymagań klientów. Na koniec musisz ocenić potrzeby techniczne. Jaka infrastruktura i narzędzia programowe zostaną wykorzystane? Czy będzie potrzeba zwiększenia wydajności lub zakupu nowych rozwiązań?

**Krok #2 - Zrozumienie danych**

W tym kroku przyjrzysz się źródłom danych projektu. Weź pod uwagę, że są trzy główne, do których należą:

• Dane wewnętrzne: Dane te mogą pochodzić ze strony internetowej, sygnałów nawigacyjnych w lokalizacji sklepu, czujników IoT, aplikacji mobilnych i tak dalej. Główną zaletą tych danych jest to, że są bezpłatne i dostosowane do Twojej firmy. Ale z drugiej strony istnieje pewne ryzyko. Mogą wystąpić problemy, jeśli nie poświęcono wystarczającej uwagi formatowaniu danych lub jakie dane należy wybrać.

• Dane typu Open Source: są one zazwyczaj dostępne bezpłatnie, co z pewnością jest miłą korzyścią. Niektóre przykłady danych o otwartym kodzie źródłowym obejmują informacje rządowe i naukowe. Dostęp do danych jest często uzyskiwany za pośrednictwem interfejsu API, co sprawia, że proces jest dość prosty. Dane open source są również zwykle dobrze sformatowane. Jednak niektóre zmienne mogą być niejasne i mogą występować uprzedzenia, takie jak przeskalowanie do określonej grupy demograficznej.

• Dane stron trzecich: Są to dane od komercyjnego dostawcy. Ale opłaty mogą być wysokie. W rzeczywistości w niektórych przypadkach może brakować jakości danych.

Według Teradata, na podstawie własnych działań firmy w zakresie sztucznej inteligencji, około 70% źródeł danych to źródła wewnętrzne, 20% z open source, a reszta od dostawców komercyjnych. Ale niezależnie od źródła wszystkie dane muszą być zaufane. Jeśli nie, prawdopodobnie pojawi się problem „śmieci wchodzą, śmieci wychodzą". Aby ocenić dane, musisz odpowiedzieć na następujące pytania:

• Czy dane są kompletne? Czego może brakować?

• Skąd pochodzą dane?

• Jakie były punkty zbiórki?

• Kto dotykał danych i je przetwarzał?

• Jakie były zmiany w danych?

• Jakie są problemy z jakością?

Jeśli pracujesz z danymi strukturalnymi, ten etap powinien być łatwiejszy. Jednak jeśli chodzi o dane nieustrukturyzowane i częściowo ustrukturyzowane, będziesz musiał oznaczyć dane, co może być długotrwałym procesem. Na rynku pojawia się jednak kilka narzędzi, które mogą pomóc zautomatyzować ten proces.

**Krok #3 – Przygotowanie danych**

Pierwszym krokiem w procesie przygotowania danych jest podjęcie decyzji, jakich zestawów danych użyć. Przyjrzyjmy się scenariuszowi: Załóżmy, że pracujesz dla firmy wydawniczej i chcesz opracować strategię poprawy utrzymania klientów. Niektóre dane, które powinny pomóc, obejmują informacje demograficzne dotyczące bazy klientów, takie jak wiek, płeć, dochód i wykształcenie. Aby zapewnić więcej kolorów, możesz również spojrzeć na informacje o przeglądarce. Jaki rodzaj treści interesuje klientów? Jaka jest częstotliwość i czas trwania? Jakieś inne ciekawe wzorce - powiedzmy, że dostęp do informacji w weekendy? Łącząc źródła informacji, możesz stworzyć potężny model. Na przykład, jeśli w niektórych obszarach nastąpi rezygnacja z aktywności, może to stwarzać ryzyko anulowania. To ostrzegałoby sprzedawców, aby skontaktowali się z klientami. Chociaż jest to sprytny proces, nadal istnieją miny lądowe. Uwzględnienie lub wykluczenie nawet jednej zmiennej może mieć istotny negatywny wpływ na model AI. W celu zobacz dlaczego, spójrz wstecz na kryzys finansowy. Modele gwarantowania kredytów hipotecznych były wyrafinowane i oparte na ogromnych ilościach danych. W normalnych czasach ekonomicznych działały całkiem dobrze, ponieważ duże instytucje finansowe, takie jak Goldman Sachs, JP Morgan i AIG, w dużym stopniu na nich polegały. Ale był problem: modele nie uwzględniały spadających cen mieszkań! Głównym powodem było to, że przez dziesięciolecia nigdy nie było krajowego spadku. Założono, że mieszkalnictwo jest głównie zjawiskiem lokalnym. Oczywiście ceny mieszkań nie tylko spadły, ale spadły. Modele okazały się wtedy dalekie od celu, a miliardy dolarów strat niemal zniszczyły amerykański system finansowy. Rząd federalny nie miał innego wyjścia, jak pożyczyć 700 miliardów dolarów na ratowanie Wall Street. To prawda, to skrajny przypadek. Podkreśla jednak znaczenie selekcji danych. W tym przypadku niezbędne może być posiadanie solidnego zespołu ekspertów dziedzinowych i analityków danych. Następnie, na etapie przygotowania danych, konieczne będzie czyszczenie danych. Faktem jest, że wszystkie dane mają problemy. Nawet firmy takie jak Facebook mają luki, niejasności i wartości odstające w swoich zbiorach danych. To nieuniknione. Oto kilka działań, które możesz podjąć, aby wyczyścić dane:

• Deduplikacja: Ustaw testy, aby zidentyfikować wszelkie duplikaty i usunąć zbędne dane.

• Wartości odstające: są to dane, które znacznie wykraczają poza zakres większości pozostałych danych. Może to wskazywać, że informacje nie są przydatne. Ale oczywiście zdarzają się sytuacje, w których jest odwrotnie. To byłoby do odliczenia oszustwa.

• Spójność: Upewnij się, że masz jasne definicje zmiennych. Nawet terminy takie jak „przychody" czy „klient" mogą mieć wiele znaczeń.

• Reguły walidacji: Patrząc na dane, spróbuj znaleźć nieodłączne ograniczenia. Na przykład możesz mieć flagę dla kolumny wiek. Jeśli w wielu przypadkach jest ponad 120, to dane mają poważne problemy.

• Binning: Niektóre dane nie muszą być szczegółowe. Czy to naprawdę ma znaczenie, czy ktoś ma 35 czy 37 lat? Prawdopodobnie nie. Ale porównanie tych od 30-40 do 41-50 prawdopodobnie tak.

• Nieaktualność: czy dane są aktualne i istotne?

• Scalanie: W niektórych przypadkach kolumny danych mogą zawierać bardzo podobne informacje. Być może jeden ma wzrost w calach, a drugi w stopach. Jeśli Twój model nie wymaga bardziej szczegółowego numeru, możesz po prostu użyć tego dla stóp.

• One-Hot Encoding: Jest to sposób na zastąpienie danych kategorycznych jako liczb. Przykład: Załóżmy, że mamy bazę danych z kolumną, która ma trzy możliwe wartości: Apple, Ananas i Orange. Możesz reprezentować Apple jako 1, Ananas jako 2, a Orange jako 3. Brzmi rozsądnie, prawda? Może nie. Problem w tym, że algorytm AI może uznać, że Orange jest większy niż Apple. Ale dzięki kodowaniu

na gorąco możesz uniknąć tego problemu. Utworzysz trzy nowe kolumny: is_Apple, is_Pineapple i is_Orange. Dla każdego wiersza w danych wpiszesz 1 dla miejsca występowania owocu i 0 dla reszty.

• Tabele przeliczeniowe: Można tego użyć podczas tłumaczenia danych z jednego standardu na inny. Byłoby tak w przypadku, gdy masz dane w systemie dziesiętnym i chcesz przejść do systemu metrycznego.

Te kroki znacznie poprawią jakość danych. Istnieją również narzędzia do automatyzacji, które mogą pomóc, takie jak firmy takie jak SAS, Oracle, IBM, Lavastorm Analytics i Talend. Są też projekty typu open source, takie jak OpenRefine, plyr i reshape2. Niezależnie od tego dane nie będą idealne. Brak źródła danych. Prawdopodobnie nadal będą luki i nieścisłości. Dlatego musisz być kreatywny. Zobacz, co zrobił Eyal Lifshitz, który jest dyrektorem generalnym BlueVine. Jego firma wykorzystuje sztuczną inteligencję do finansowania małych firm. „Jednym z naszych źródeł danych są informacje kredytowe naszych klientów" – powiedział. „Odkryliśmy jednak, że właściciele małych firm błędnie identyfikują swój rodzaj działalności. Może to oznaczać złe wyniki dla naszego ubezpieczenia. Aby sobie z tym poradzić, zbieramy dane ze strony klienta za pomocą algorytmów AI, które pomagają zidentyfikować branżę". Podejścia do czyszczenia danych będą również zależeć od przypadków użycia w projekcie AI. Na przykład, jeśli budujesz system do konserwacji predykcyjnej w produkcji, wyzwaniem będzie radzenie sobie z dużą różnorodnością różnych czujników. W rezultacie duża ilość danych może mieć niewielką wartość i być w większości szumem.

**Etyka i zarządzanie**

Musisz pamiętać o wszelkich ograniczeniach dotyczących danych. Czy sprzedawca może zabronić Ci wykorzystywania informacji do określonych celów? Być może Twoja firma będzie na haku, jeśli coś pójdzie nie tak? Aby poradzić sobie z tymi kwestiami, wskazane jest, aby sprowadzić dział prawny. W większości przypadków dane należy traktować z ostrożnością. W końcu istnieje wiele głośnych przypadków, w których firmy naruszyły prywatność. Wybitnym tego przykładem jest Facebook. Jeden z partnerów firmy, Cambridge Analytica, uzyskał dostęp do milionów punktów danych z profili bez zgody użytkowników. Kiedy demaskator odkrył to, akcje Facebooka spadły, tracąc ponad 100 miliardów dolarów wartości. Firma znalazła się również pod presją rządów USA i Europy. Należy uważać na zbieranie danych ze źródeł publicznych. To prawda, że często jest to skuteczny sposób tworzenia dużych zestawów danych. Istnieje również wiele narzędzi, które mogą zautomatyzować ten proces. Jednak skrobanie może narazić Twoją firmę na odpowiedzialność prawną, ponieważ dane mogą podlegać prawom autorskim lub prawom prywatności. Istnieją również pewne środki ostrożności, które, jak na ironię, mogą mieć nieodłączne wady. Na przykład ostatnie badanie przeprowadzone przez MIT pokazuje, że dane zanonimizowane mogą nie być bardzo zanonimizowane. Naukowcy odkryli, że w rzeczywistości dość łatwo jest zrekonstruować tego typu dane i zidentyfikować osoby- na przykład przez połączenie dwóch zestawów danych. Dokonano tego przy użyciu danych w Singapurze z sieci komórkowej (śledzenie GPS) i lokalnego systemu transportowego. Po około 11 tygodniach analizy naukowcy byli w stanie zidentyfikować 95% osobników. Na koniec upewnij się, że podejmujesz kroki w celu zabezpieczenia danych. Liczba cyberataków i zagrożeń wciąż rośnie w zastraszającym tempie. Według Verizon w 2018 r. miało miejsce ponad 53 000 incydentów i około 2200 naruszeń. W raporcie odnotowano również następujące kwestie:

• 76% naruszeń było motywowanych finansami.

• 73% pochodziło z osób spoza firmy.

• Około połowa pochodziła ze zorganizowanych grup przestępczych, a 12% z państw narodowych lub podmiotów powiązanych z państwem.

Rosnące wykorzystanie danych w chmurze i danych lokalnych może również narazić firmę na luki w zabezpieczeniach. Do tego dochodzi mobilna siła robocza, co może oznaczać dostęp do danych, który może narazić ją na naruszenia. Ataki również stają się znacznie bardziej szkodliwe. W rezultacie firma może łatwo ponieść kary, procesy sądowe i uszczerbek na reputacji. Zasadniczo, przygotowując projekt AI, upewnij się, że istnieje plan bezpieczeństwa i że jest on przestrzegany.

**Ile danych potrzebujesz do sztucznej inteligencji?**

Im więcej danych, tym lepiej, prawda? Tak jest zwykle. Spójrz na coś, co nazywa się Hughes Phenomenon. Oznacza to, że wraz z dodawaniem funkcji do modelu wydajność ogólnie wzrasta. Ale ilość to nie koniec, wszystko. Może nadejść moment, w którym dane zaczną się degradować. Pamiętaj, że możesz natknąć się na coś, co nazywa się przekleństwem wymiarowości. Według Charlesa Isbella, profesora i starszego zastępcy dziekana School of Interactive Computing w Georgia Tech: „Wraz ze wzrostem liczby funkcji lub wymiarów ilość danych, które potrzebujemy do dokładnego uogólnienia, rośnie wykładniczo". Jaki jest praktyczny wpływ? Może to uniemożliwić posiadanie dobrego modelu, ponieważ może nie być wystarczającej ilości danych. To dlatego, jeśli chodzi o aplikacje takie jak rozpoznawanie wzroku, przekleństwo wymiarowości może być dość problematyczne. Nawet analizując obrazy RGB, liczba wymiarów wynosi około 7500. Wyobraź sobie, jak intensywny byłby ten proces przy użyciu wideo w wysokiej rozdzielczości w czasie rzeczywistym.

**Więcej terminów i pojęć dotyczących danych**

Angażując się w analizę danych powinieneś znać podstawowe pojęcia. Oto kilka, które często słyszysz:

Dane kategoryczne: są to dane, które nie mają znaczenia liczbowego. Ma raczej znaczenie tekstowe, jak opis grupy (rasa i płeć). Chociaż możesz przypisać numery do każdego z elementów.

Typ danych: Jest to rodzaj informacji, które reprezentuje zmienna, na przykład Boolean, liczba całkowita, ciąg znaków lub liczba zmiennoprzecinkowa.

Analityka opisowa: to analiza danych w celu lepszego zrozumienia aktualnego stanu firmy. Niektóre przykłady obejmują mierzenie, które produkty sprzedają się lepiej lub określanie ryzyka w obsłudze klienta. Istnieje wiele tradycyjnych narzędzi programowych do analizy opisowej, takich jak aplikacja BI.

Analiza diagnostyczna: to zapytanie o dane, aby zobaczyć, dlaczego coś się stało. Ten rodzaj analizy wykorzystuje techniki takie jak eksploracja danych, drzewa decyzyjne i korelacje.

ETL (Ekstrakcja, Transformacja i Ładowanie): Jest to forma integracji danych i jest zwykle używana w hurtowni danych.

Funkcja: To jest kolumna danych.

Instancja: To jest rząd danych.

Metadane: Są to dane dotyczące danych, czyli opisów. Na przykład plik muzyczny może zawierać metadane, takie jak rozmiar, długość, data przesłania, komentarze, gatunek, wykonawca itd. Ten rodzaj danych może okazać się bardzo przydatny w projekcie AI.

Dane liczbowe: są to dowolne dane, które mogą być reprezentowane przez liczbę. Ale dane liczbowe mogą mieć dwie formy. Istnieją dane dyskretne, które są liczbą całkowitą, czyli liczbą bez kropki dziesiętnej. Następnie są dane ciągłe, które mają przepływ, powiedzmy temperaturę lub czas.

OLAP (Online Analytical Processing): Jest to technologia, która umożliwia analizowanie informacji z różnych baz danych.

Dane porządkowe: Jest to połączenie danych liczbowych i kategorycznych. Typowym tego przykładem jest pięciogwiazdkowa ocena na Amazon.com. Ma zarówno gwiazdkę, jak i powiązany z nią numer.

Analityka predykcyjna: obejmuje wykorzystanie danych do tworzenia prognoz. Modele do tego są zwykle wyrafinowane i opierają się na podejściach AI, takich jak uczenie maszynowe. Aby być skutecznym, ważne jest aktualizowanie bazowego modelu o nowe dane. Niektóre z narzędzi do analizy predykcyjnej obejmują podejścia do uczenia maszynowego, takie jak regresje.

Analiza nakazowa: chodzi o wykorzystanie Big Data do podejmowania lepszych decyzji. Koncentruje się to nie tylko na przewidywaniu wyników, ale także na zrozumieniu przesłanek. I tutaj AI odgrywa dużą rolę.

Zmienne skalarne: są to zmienne, które przechowują pojedyncze wartości, takie jak imię i nazwisko lub numer karty kredytowej.

Dane transakcyjne: Są to dane rejestrowane na temat działań finansowych, biznesowych i logistycznych. Przykłady obejmują płatności, faktury i roszczenia ubezpieczeniowe.

**Wniosek**

Odniesienie sukcesu dzięki sztucznej inteligencji oznacza posiadanie kultury opartej na danych. To jest kluczowe dla firm takich jak Amazon.com, Google i Facebook. Podejmując decyzje, najpierw patrzą na dane. Powinna również istnieć szeroka dostępność danych w całej organizacji. Bez tego podejścia sukces z AI będzie ulotny, niezależnie od tego, jak planujesz. Być może pomaga to wyjaśnić, że = według badania przeprowadzonego przez NewVantage Partners - około 77% respondentów twierdzi, że „przyjęcie biznesowe” Big Data i sztucznej inteligencji pozostaje wyzwaniem.

**Kluczowe dania na wynos**

* Dane strukturalne są oznaczone i sformatowane - i często są przechowywane w relacyjnej bazie danych lub arkuszu kalkulacyjnym.

* Dane nieustrukturyzowane to informacje, które nie mają wstępnie zdefiniowanego formatowania.

* Częściowo ustrukturyzowane dane mają kilka wewnętrznych znaczników, które pomagają w kategoryzacji.

* Big Data opisuje sposób obsługi ogromnych ilości informacji.

* Relacyjna baza danych jest oparta na relacjach danych. Ale ta struktura może okazać się trudna dla współczesnych aplikacji, takich jak sztuczna inteligencja.

* Baza danych NoSQL jest bardziej swobodna, oparta na modelu dokumentu. Dzięki temu lepiej radzi sobie z danymi nieustrukturyzowanymi i częściowo ustrukturyzowanymi.

* Proces CRISP-DM zapewnia sposób zarządzania danymi projektu, obejmujący etapy, które obejmują zrozumienie biznesowe, zrozumienie danych, przygotowanie danych, modelowanie, ocenę i wdrażanie.

* Ilość danych jest z pewnością ważna, ale trzeba też dużo pracy nad jakością. Nawet małe błędy mogą mieć ogromny wpływ na wyniki modelu AI.

**Nauczanie maszynowe . Wydobywanie spostrzeżeń z danych.**

Chociaż Katrina Lake lubiła robić zakupy online, wiedziała, że może być znacznie lepiej. Główny problem: trudno było znaleźć modę spersonalizowaną. Tak zaczęła się inspiracja dla Stitch Fix, którą Katrina uruchomiła w swoim mieszkaniu w Cambridge podczas nauki w Harvard Business School w 2011 roku (swoją drogą, oryginalna nazwa firmy brzmiała mniej chwytliwie „Rack Habit"). Witryna zawierała pytania i odpowiedzi dla swoich użytkowników - pytając o rozmiar i style ubioru, żeby wymienić tylko kilka czynników - a doświadczeni styliści składali następnie wyselekcjonowane pudełka z ubraniami i akcesoriami, które były wysyłane co miesiąc. Koncepcja szybko się przyjęła, a wzrost był solidny. Trudno było jednak pozyskać kapitał, ponieważ wielu inwestorów venture capital nie widziało potencjału w tym biznesie. Jednak Katrina uparła się i była w stanie stworzyć dochodową operację - dość szybko. Po drodze program Stitch Fix zbierał ogromne ilości cennych danych, takich jak rozmiary ciała i preferencje dotyczące stylu. Katrina zdała sobie sprawę, że byłoby to idealne rozwiązanie do uczenia maszynowego. Aby to wykorzystać, zatrudniła Erica Colsona, który był wiceprezesem Data Science and Engineering w Netflix, a jego nowym tytułem jest dyrektor ds. algorytmów. Ta zmiana strategii była kluczowa. Modele uczenia maszynowego stawały się coraz lepsze dzięki ich przewidywaniom, ponieważ Stitch Fix zebrał więcej danych - nie tylko z początkowych ankiet, ale także z bieżących informacji zwrotnych. Dane zostały również zakodowane w jednostkach SKU. Rezultat: Stitch Fix zapewnił stałą poprawę lojalności klientów i współczynników konwersji. Nastąpiła również poprawa w obrocie zapasami, co pomogło obniżyć koszty. Ale nowa strategia nie oznaczała zwolnienia stylistów. Uczenie maszynowe znacznie zwiększyło ich produktywność i skuteczność. Dane dostarczyły również informacji o tym, jakie rodzaje odzieży należy tworzyć. Doprowadziło to do uruchomienia Hybrid Designs w 2017 roku, który jest marką prywatną Stitch Fix. Okazało się to skuteczne w radzeniu sobie z lukami w zapasach. Do listopada 2017 r. Katrina upubliczniła Stitch Fix, zdobywając 120 milionów dolarów. Firma została wyceniona na niezłe 1,63 miliarda dolarów, co czyni ją jedną z najbogatszych kobiet w Stanach Zjednoczonych. Aha, w tym czasie miała 14-miesięcznego syna! Przechodząc do dzisiaj, Stitch Fix ma 2,7 miliona klientów w Stanach Zjednoczonych i generuje ponad 1,2 miliarda dolarów przychodów. Zatrudnionych jest również ponad 100 naukowców zajmujących się danymi, a większość z nich ma doktoraty w dziedzinach takich jak neuronauka, matematyka, statystyka i sztuczna inteligencja. Według zgłoszenia firmy 10-K:

Nasze możliwości w zakresie analizy danych napędzają naszą działalność. Na te możliwości składa się nasz bogaty i stale powiększający się zestaw szczegółowych danych o klientach i towarach oraz nasze autorskie algorytmy. Korzystamy z analizy danych w całej naszej działalności, w tym do stylizowania naszych klientów, przewidywania zachowań zakupowych, prognozowania popytu, optymalizacji zapasów i projektowania nowej odzieży.

Bez wątpienia historia Stitch Fix wyraźnie pokazuje niesamowitą moc uczenia maszynowego i to, jak może ono zrewolucjonizować branżę. W wywiadzie dla digiday.com Lake zauważyła:

Historycznie istniała przepaść między tym, co dajesz firmom, a tym, jak bardzo poprawia się ich doświadczenie. Wielkie zbiory danych śledzą Cię w całej sieci, a największą korzyścią, jaką teraz z tego czerpiesz, jest: jeśli klikniesz parę butów, zobaczysz tę parę ponownie za tydzień. Zobaczymy, jak ta przepaść zacznie się zamykać. Oczekiwania są bardzo różne w odniesieniu do personalizacji, ale co ważne, jej autentycznej wersji. Nie: „Porzuciłeś swój koszyk, a my to rozpoznajemy". Będzie to autentyczne rozpoznanie, kim jesteś jako wyjątkowy człowiek. Jedynym sposobem na zrobienie tego w sposób skalowalny jest uwzględnienie nauki o danych i tego, co można zrobić dzięki innowacjom.

No dobrze, na czym tak naprawdę polega uczenie maszynowe? Dlaczego może mieć taki wpływ? A jakie zagrożenia należy wziąć pod uwagę? Odpowiemy na te pytania i nie tylko.

**Co to jest uczenie maszynowe?**

Po przepracowaniu w MIT i Bell Telephone Laboratories, Arthur L. Samuel dołączył do IBM w 1949 roku w Poughkeepsie Laboratory. Jego wysiłki pomogły zwiększyć moc obliczeniową maszyn firmy, na przykład przy opracowaniu 701 (był to pierwszy skomercjalizowany system komputerowy IBM). Ale programował też aplikacje. I była taka, która zapisze się w historii, to znaczy jego komputerowa gra w warcaby. Był to pierwszy przykład systemu uczenia maszynowego (Samuel opublikował wpływowy artykuł na ten temat w 1959 roku). CEO IBM, Thomas J. Watson, Sr., powiedział, że innowacja zwiększy cenę akcji o 15 punktów! Dlaczego więc artykuł Samuela był tak istotny? Patrząc na warcaby, pokazał, jak działa uczenie maszynowe - innymi słowy, komputer może uczyć się i ulepszać, przetwarzając dane bez konieczności wyraźnego programowania. Było to możliwe dzięki wykorzystaniu zaawansowanych koncepcji statystyki, zwłaszcza analizy prawdopodobieństwa. W ten sposób komputer można wytrenować, aby dokonywał dokładnych prognoz. Było to rewolucyjne, ponieważ tworzenie oprogramowania w tym czasie było głównie o liście poleceń, które następowały po przepływie pracy logiki. Aby zrozumieć, jak działa uczenie maszynowe, użyjmy przykładu z serialu komediowego HBO Dolina Krzemowa. Inżynier Jian-Yang miał stworzyć Shazam do jedzenia. Aby wytrenować aplikację, musiał dostarczyć ogromny zestaw danych ze zdjęciami jedzenia. Niestety, z powodu ograniczeń czasowych aplikacja nauczyła się dopiero rozpoznawać hot dogi. Innymi słowy, jeśli użyjesz aplikacji, odpowie tylko „hot dog” i „nie hot dog”. Choć zabawny, odcinek wykonał całkiem niezłą robotę, demonstrując uczenie maszynowe. W istocie jest to proces przyjmowania oznaczonych danych i znajdowania relacji. Jeśli wytrenujesz system z hot dogami – na przykład z tysiącami obrazów – będzie coraz lepiej je rozpoznawał. Tak, nawet programy telewizyjne mogą dostarczyć cennych lekcji na temat sztucznej inteligencji! Ale oczywiście nadal potrzebujesz znacznie więcej. W następnej części rozdziału przyjrzymy się dokładniej podstawowym statystykom, które musisz wiedzieć o uczeniu maszynowym. Obejmuje to odchylenie standardowe, rozkład normalny, twierdzenie Bayesa, korelację i ekstrakcję cech. Następnie omówimy takie tematy, jak przypadki użycia uczenia maszynowego, ogólny proces i popularne algorytmy.

**Odchylenie standardowe**

Odchylenie standardowe mierzy średnią odległość od średniej. W rzeczywistości nie ma potrzeby uczenia się, jak to obliczyć (proces obejmuje wiele kroków), ponieważ Excel lub inne oprogramowanie może to zrobić z łatwością. Aby zrozumieć odchylenie standardowe, weźmy przykład wartości domu w Twojej okolicy. Załóżmy, że średnia wynosi 145 000 USD, a odchylenie standardowe to 24 000 USD. Oznacza to, że jedno odchylenie standardowe poniżej średniej wyniosłoby 133 000 USD (145 000 USD - 12 000 USD), a jedno odchylenie standardowe powyżej średniej wyniosłoby 157 000 USD (145 000 USD + 12 000 USD). Daje nam to możliwość ilościowego określenia zmienności danych. Oznacza to, że istnieje spread w wysokości 24 000 USD od średniej. Następnie spójrzmy na dane, jeśli, no cóż, Mark Zuckerberg przenosi się do twojego sąsiedztwa i w rezultacie średnia skacze do 850 000 USD, a odchylenie standardowe wynosi 175 000 USD. Ale czy te dane statystyczne odzwierciedlają wyceny? Nie bardzo. Zakup Zuckerberga jest czymś odstającym. W takiej sytuacji najlepszym rozwiązaniem może być zamiast tego wykluczenie jego domu.

**Rozkład normalny**

Na wykresie rozkład normalny wygląda jak dzwon (dlatego inna nazwa to „krzywa dzwonowa”). Reprezentuje sumę prawdopodobieństw dla zmiennej. Co ciekawe, krzywa normalna jest powszechna w świecie przyrody, ponieważ odzwierciedla rozkład takich rzeczy, jak wzrost i waga. Ogólnym

podejściem do interpretacji rozkładu normalnego jest zastosowanie reguły 68-95-99,7. Szacuje się, że 68% pozycji danych będzie mieścić się w obrębie jednego odchylenia standardowego, 95% w obrębie dwóch odchyleń standardowych, a 99,7% w obrębie trzech odchyleń standardowych. Sposobem na zrozumienie tego jest użycie wyników IQ. Załóżmy, że średni wynik to 100, a odchylenie standardowe to 15. Otrzymalibyśmy to dla trzech odchyleń standardowych Zauważ, że szczyt na tym wykresie jest średnią. Tak więc, jeśli dana osoba ma IQ 145, to tylko 0,15% będzie miało wyższy wynik. Teraz krzywa może mieć różne kształty, w zależności od zmienności danych. Na przykład, jeśli nasze dane IQ mają dużą liczbę geniuszy, rozkład będzie przekrzywiony w prawo.

**Twierdzenie Bayesa**

Jak sama nazwa wskazuje, statystyki opisowe dostarczają informacji o Twoich danych. Widzieliśmy już to z takimi rzeczami jak średnie i odchylenia standardowe. Ale oczywiście możesz wyjść daleko poza to - w zasadzie, używając twierdzenia Bayesa. Takie podejście jest powszechne w analizie chorób medycznych, w których przyczyna i skutek są kluczowymi słowami dla badań FDA (Federal Drug Administration). Aby zrozumieć, jak działa twierdzenie Bayesa, weźmy przykład. Badacz wymyśla test na określony rodzaj nowotworu i okazuje się, że jest dokładny w 80% przypadków. Nazywa się to prawdziwym pozytywem. Jednak w 9,6% przypadków test zidentyfikuje osobę jako chorą na raka, nawet jeśli go nie ma, co jest znane jako fałszywie dodatni. Pamiętaj, że w niektórych testach narkotykowych odsetek ten może być wyższy niż wskaźnik dokładności! I wreszcie 1% populacji ma raka. W świetle tego wszystkiego, jeśli lekarz użyje testu na tobie i wykaże, że masz raka, jakie jest prawdopodobieństwo, że naprawdę masz raka? Cóż, twierdzenie Bayesa wskaże drogę. To obliczenie wykorzystuje takie czynniki, jak wskaźniki dokładności, wyniki fałszywie dodatnie, a wskaźnik populacji do wymyślenia prawdopodobieństwa:

• Krok #1: 80% wskaźnik dokładności × prawdopodobieństwo zachorowania na raka (1%) = 0,008.

• Krok #2: Szansa na brak raka (99%) × 9,6% fałszywie dodatnich = 0,09504.

• Krok #3: Następnie wstaw powyższe liczby do następującego równania: 0,008 / (0,008 + 0,09504) = 7,8%.

Brzmi trochę dziwnie, prawda? Zdecydowanie. W końcu, jak to się dzieje, że test, który jest dokładny w 90%, ma tylko 7,8% prawdopodobieństwa poprawności? Pamiętaj jednak, że wskaźnik dokładności opiera się na pomiarze tych, którzy mają grypę. A to niewielka liczba, ponieważ tylko 1% populacji ma grypę. Co więcej, test nadal daje fałszywie pozytywne wyniki. Twierdzenie Bayesa jest więc sposobem na lepsze zrozumienie wyników – co ma kluczowe znaczenie dla systemów takich jak sztuczna inteligencja.

**Korelacja**

Algorytm uczenia maszynowego często obejmuje pewien rodzaj korelacji między danymi. Ilościowym sposobem opisania tego jest wykorzystanie korelacji Pearsona, która pokazuje siłę związku między dwiema zmiennymi w zakresie od 1 do –1 (jest to współczynnik). Oto jak to działa:

• Większe niż 0: W tym przypadku wzrost jednej zmiennej prowadzi do wzrostu innej. Na przykład: Załóżmy, że istnieje korelacja 0,9 między dochodem a wydatkami. Jeśli dochód wzrośnie o 1000 USD, wydatki wzrosną o 900 USD (1000 USD x 0,9).

• 0: Nie ma korelacji między dwiema zmiennymi.

• Mniej niż 0: Każdy wzrost zmiennej oznacza spadek innej i odwrotnie. To opisuje odwrotną zależność.

Czym zatem jest silna korelacja? Ogólna zasada mówi, że współczynnik wynosi około +0,7. A jeśli jest poniżej 0,3, to korelacja jest słaba. Wszystko to nawiązuje do starego powiedzenia: „Korelacja niekoniecznie jest przyczyną". Jednak jeśli chodzi o uczenie maszynowe, tę koncepcję można łatwo zignorować i prowadzić do mylących wyników. Na przykład istnieje wiele korelacji, które są po prostu losowe. W rzeczywistości niektóre mogą być wręcz komiczne. Sprawdź następujące informacje z Tylervigen.com:

• Wskaźnik rozwodów w Maine wykazuje 99,26% korelacji ze spożyciem margaryny na mieszkańca.

• Wiek Miss America ma 87,01% korelacji z morderstwami parą wodną, gorącymi oparami i gorącymi tropikami.

• Import ropy naftowej do USA z Norwegii wykazuje 95,4% korelacji z kierowcami zabitymi w zderzeniu z pociągiem kolejowym.

Jest na to nazwa: wzorzystość. Jest to tendencja do znajdowania wzorców w bezsensownym szumie.

**Ekstrakcja funkcji**

W Części 2 przyjrzeliśmy się doborowi zmiennych do modelu. Proces ten jest często nazywany wyodrębnianiem funkcji lub inżynierią funkcji.

Przykładem może być model komputerowy, który identyfikuje mężczyznę lub kobietę na zdjęciu. Dla ludzi jest to dość łatwe i szybkie. To coś intuicyjnego. Ale gdyby ktoś poprosił Cię o opisanie różnic, czy byłbyś w stanie to zrobić? Dla większości ludzi byłoby to trudne zadanie. Jeśli jednak chcemy zbudować skuteczny model uczenia maszynowego, musimy prawidłowo wyodrębnić funkcje - a to może być subiektywne. To tylko zarysowuje powierzchnię, ponieważ jestem pewien, że masz własne pomysły lub podejścia. I to jest normalne. Ale właśnie dlatego takie rzeczy jak rozpoznawanie twarzy są bardzo złożone i obarczone błędami. Ekstrakcja funkcji ma również pewne niuanse. Jednym z nich jest potencjał stronniczości. Na przykład, czy masz uprzedzenia dotyczące tego, jak wygląda mężczyzna lub kobieta? Jeśli tak, może to spowodować, że modele dadzą błędne wyniki. Z tego powodu dobrze jest mieć grupę ekspertów, którzy potrafią określić odpowiednie cechy. A jeśli inżynieria funkcji okaże się zbyt złożona, uczenie maszynowe prawdopodobnie nie jest dobrym rozwiązaniem. Ale jest jeszcze inne podejście do rozważenia: głębokie uczenie. Obejmuje to wyrafinowane modele, które znajdują funkcje w danych. Właściwie jest to jeden z powodów, dla których uczenie głębokie stało się wielkim przełomem w sztucznej inteligencji.

**Co możesz zrobić dzięki uczeniu maszynowemu?**

Ponieważ uczenie maszynowe istnieje od dziesięcioleci, ta potężna technologia ma wiele zastosowań. Pomaga również w uzyskaniu wyraźnych korzyści pod względem oszczędności kosztów, możliwości uzyskania przychodów i monitorowania ryzyka. Aby przybliżyć niezliczone zastosowania, przyjrzyjmy się kilku przykładom:

• Konserwacja predykcyjna: Monitoruje czujniki, aby przewidzieć, kiedy sprzęt może ulec awarii. Pomaga to nie tylko obniżyć koszty, ale także skraca przestoje i zwiększa bezpieczeństwo. W rzeczywistości firmy takie jak PrecisionHawk faktycznie używają dronów do zbierania danych, co jest znacznie bardziej wydajne. Technologia okazała się dość skuteczna w branżach takich jak energetyka, rolnictwo i budownictwo. Oto, co PrecisionHawk zauważa na temat własnego systemu konserwacji predykcyjnej opartego na dronach: „Jeden klient przetestował wykorzystanie dronów z wizualną linią wzroku (VLOS), aby sprawdzić klaster 10 studzienek w promieniu trzech mil. Nasz klient ustalił, że

użycie dronów obniżyło koszty inspekcji o około 66%, z 80-90 USD za podkładkę od tradycyjnej metodologii inspekcji do 45–60 USD za studnię przy użyciu misji dronów VLOS".

• Rekrutacja pracowników: może to być żmudny proces, ponieważ wiele życiorysów jest często zróżnicowanych. Oznacza to, że łatwo jest pominąć świetnych kandydatów. Jednak uczenie maszynowe może w dużym stopniu pomóc. Spójrz na CareerBuilder, który zebrał i przeanalizował ponad 2,3 miliona ofert pracy, 680 milionów unikalnych profili, 310 milionów unikalnych życiorysów, 10 milionów tytułów pracy, 1,3 miliarda umiejętności i 2,5 miliona weryfikacji przeszłości, aby stworzyć Hello to Hire. Jest to platforma, która wykorzystała uczenie maszynowe, aby zmniejszyć liczbę podań o pracę - w celu pomyślnego zatrudnienia - średnio do 75. Z drugiej strony średnia w branży wynosi około 150,10. System automatyzuje również tworzenie opisów stanowisk, co uwzględnia nawet niuanse oparte na branży i lokalizacji!

• Doświadczenie klienta: W dzisiejszych czasach klienci chcą spersonalizowanych doświadczeń. Przyzwyczaili się do tego, korzystając z usług takich jak Amazon.com i Uber. Dzięki uczeniu maszynowemu firma może wykorzystać swoje dane, aby uzyskać wgląd — dowiedzieć się, co naprawdę działa. Jest to tak ważne, że skłoniło Krogera do zakupu firmy w przestrzeni o nazwie 84,51°. Zdecydowanie kluczowe jest to, że posiada dane dotyczące ponad 60 milionów gospodarstw domowych w USA. Oto krótki przypadek badania: W większości swoich sklepów Kroger miał duże ilości awokado, a tylko kilka miało 4-paki. Powszechnie uważano, że 4-paki należy przecenić ze względu na różnice w wielkości w stosunku do produktów masowych. Jednak przy zastosowaniu analizy uczenia maszynowego okazało się to niepoprawne, ponieważ 4-paki przyciągnęły nowe i różne gospodarstwa domowe, takie jak Millenialsi i kupujący na ClickList. Dzięki rozszerzeniu 4-paków w całej sieci nastąpił ogólny wzrost sprzedaży awokado.

• Finanse: uczenie maszynowe może wykrywać rozbieżności, na przykład z rozliczeniami. Ale istnieje nowa kategoria technologii, zwana RPA (Robotic Process Automation), która może w tym pomóc. Automatyzuje rutynowe procesy w celu zmniejszenia liczby błędów. ZAP może również wykorzystywać uczenie maszynowe do wykrywania nietypowych lub podejrzanych transakcji.

• Obsługa klienta: W ciągu ostatnich kilku lat nastąpił wzrost liczby chatbotów, które wykorzystują uczenie maszynowe do automatyzacji interakcji z klientami.

• Randki: Uczenie maszynowe może pomóc w znalezieniu bratniej duszy! Tinder, jedna z największych aplikacji randkowych, wykorzystuje tę technologię do ulepszania dopasowań. Na przykład ma system, który automatycznie oznacza ponad 10 miliardów zdjęć przesyłanych codziennie.

**Proces uczenia maszynowego**

Aby odnieść sukces w zastosowaniu uczenia maszynowego do problemu, ważne jest, aby przyjąć systematyczne podejście. Jeśli nie, wyniki mogą być dalekie od podstaw. Przede wszystkim musisz przejść przez proces przetwarzania danych, który omówiliśmy wcześniej. Po zakończeniu dobrze jest wykonać wizualizację danych. Czy jest w większości rozproszony? A może są jakieś wzory? Jeśli odpowiedź brzmi tak, dane mogą być dobrym kandydatem do uczenia maszynowego. Celem procesu uczenia maszynowego jest stworzenie modelu, który opiera się na jednym lub kilku algorytmach. Rozwijamy to, szkoląc go. Celem jest, aby model powinien zapewniać wysoki stopień przewidywalności. Teraz przyjrzyjmy się temu bliżej (nawiasem mówiąc, będzie to również miało zastosowanie do głębokiego uczenia się.

**Krok #1-Zamówienie danych**

Jeśli twoje dane są posortowane, może to zniekształcić wyniki. Oznacza to, że algorytm uczenia maszynowego może wykryć to jako wzorzec! Dlatego dobrym pomysłem jest losowanie kolejności danych.

**Krok #2-Wybierz model**

Musisz wybrać algorytm. Będzie to przypuszczenie oparte na wiedzy, które będzie wymagało procesu prób i błędów. W tym rozdziale przyjrzymy się różnym dostępnym algorytmom.

**Krok #3 - Trenuj model**

Dane uczące, które będą stanowić około 70% całego zbioru danych, zostaną wykorzystane do stworzenia relacji w algorytmie. Załóżmy na przykład, że budujesz system uczenia maszynowego, aby znaleźć wartość używanego samochodu. Niektóre cechy obejmują rok produkcji, markę, model, przebieg i stan. Przetwarzając te dane treningowe, algorytm obliczy wagi dla każdego z tych czynników. Przykład: Załóżmy, że używamy algorytmu regresji liniowej, który ma następujący format:

y = m * x + b

W fazie uczenia system wygeneruje wartości dla m (co jest nachyleniem na wykresie) i b (co jest punktem przecięcia z osią y).

**Krok #4 - Oceń model**

Zbierzecie dane testowe, które stanowią pozostałe 30% zbioru danych. Powinien być reprezentatywny dla zakresów i rodzaju informacji w danych treningowych. Dzięki danym testowym możesz sprawdzić, czy algorytm jest dokładny. Czy w naszym przykładzie używanego samochodu wartości rynkowe są zgodne z tym, co dzieje się w prawdziwym świecie?

**Uwaga**: Z danymi treningowymi i testowymi nie może być żadnego przemieszania. Może to łatwo prowadzić do zniekształconych wyników. Co ciekawe, jest to częsty błąd.

Teraz dokładność jest jedną z miar sukcesu algorytmu. Ale w niektórych przypadkach może to być mylące. Rozważ sytuację z odliczeniem oszustwa. W porównaniu do zbioru danych zazwyczaj występuje niewielka liczba funkcji. Ale pominięcie jednego może być katastrofalne i kosztować firmę miliony dolarów strat. Dlatego możesz chcieć użyć innych podejść, takich jak twierdzenie Bayesa.

**Krok #5 - Dostrój model**

W tym kroku możemy dostosować wartości parametrów w algorytmie. Ma to na celu sprawdzenie, czy możemy uzyskać lepsze wyniki. Podczas dostrajania modelu mogą również występować hiperparametry. Są to parametry, których nie można nauczyć się bezpośrednio z procesu szkolenia.

**Stosowanie algorytmów**

Niektóre algorytmy są dość łatwe do obliczenia, podczas gdy inne wymagają skomplikowanych kroków i matematyki. Dobrą wiadomością jest to, że zwykle nie musisz obliczać algorytmu, ponieważ istnieje wiele języków, takich jak Python i R, które upraszczają ten proces. Jeśli chodzi o uczenie maszynowe, algorytm zazwyczaj różni się od tradycyjnego. Powodem jest to, że pierwszym krokiem jest przetwarzanie danych - a następnie komputer zacznie się uczyć. Mimo że dostępne są setki algorytmów uczenia maszynowego, można je w rzeczywistości podzielić na cztery główne kategorie: uczenie nadzorowane, uczenie nienadzorowane, uczenie ze wzmacnianiem i uczenie częściowo nadzorowane. Przyjrzymy się każdemu.

**Nadzorowana nauka**

Uczenie nadzorowane wykorzystuje dane oznaczone etykietami. Załóżmy na przykład, że mamy zestaw zdjęć tysięcy psów. Dane uważa się za oznaczone, jeśli każde zdjęcie identyfikuje każdą z ras. W większości ułatwia to analizę, ponieważ możemy porównać nasze wyniki z poprawną odpowiedzią. Jednym z kluczy w uczeniu nadzorowanym jest to, że powinny być duże ilości danych. Pomaga to udoskonalić model i uzyskać dokładniejsze wyniki. Ale jest duży problem: w rzeczywistości wiele dostępnych danych nie jest oznaczonych. Ponadto dostarczenie etykiet może być czasochłonne, jeśli istnieje ogromny zbiór danych. Istnieją jednak kreatywne sposoby radzenia sobie z tym, takie jak finansowanie społecznościowe. Tak powstał system ImageNet, który był przełomem w innowacjach AI. Ale stworzenie go zajęło kilka lat. Lub, w niektórych przypadkach, mogą istnieć zautomatyzowane podejścia do etykietowania danych. Weźmy za przykład Facebooka. W 2018 roku firma ogłosiła - na konferencji deweloperów F8 - że wykorzystała swoją ogromną bazę zdjęć z Instagrama, które zostały oznaczone hashtagami. To prawda, to podejście miało swoje wady. Hashtag może zawierać niewizualny opis zdjęcia, powiedzmy #tbt (co oznacza „wspomnienie w czwartek)" lub może być zbyt niejasny, jak #impreza. Dlatego Facebook nazwał swoje podejście „słabo nadzorowanymi danymi".

Ale utalentowani inżynierowie w firmie znaleźli sposoby na poprawę jakości, na przykład przez zbudowanie wyrafinowanego modelu przewidywania hashtagów. W sumie wszystko ułożyło się całkiem dobrze. Model uczenia maszynowego Facebooka, który obejmował 3,5 miliarda zdjęć, miał wskaźnik dokładności 85,4%, co oparto na benchmarku rozpoznawania ImageNet. W rzeczywistości była to najwyższa odnotowana w historii, bo aż o 2%. Ten projekt AI wymagał również innowacyjnych podejść do budowy infrastruktury. Zgodnie z wpisem na blogu na Facebooku: Ponieważ jedna maszyna zajęłaby ponad rok, aby ukończyć szkolenie modelu, stworzyliśmy sposób na rozłożenie zadania na maksymalnie 336 procesorów graficznych, skracając całkowity czas szkolenia do zaledwie kilku tygodni. Przy coraz większych rozmiarach modelu - największy w tym badaniu jest ResNeXt 101-32x48d z ponad 861 milionami parametrów – takie rozproszone szkolenie jest coraz bardziej istotne. Ponadto opracowaliśmy metodę usuwania duplikatów, aby upewnić się, że przypadkowo nie przeszkolimy naszych modeli na obrazach, na których chcemy je ocenić, co jest problemem, który nęka podobne badania w tej dziedzinie.

Wybiegając w przyszłość, Facebook dostrzega potencjał w wykorzystaniu swojego podejścia do różnych obszarów, w tym:

• Ulepszony ranking w kanale informacyjnym

• Lepsze wykrywanie kontrowersyjnych treści

• Automatyczne generowanie napisów dla osób niedowidzących

**Nauka nienadzorowana**

Uczenie nienadzorowane ma miejsce wtedy, gdy pracujesz z danymi nieoznaczonymi. Oznacza to, że do wykrywania wzorców użyjesz algorytmów głębokiego uczenia. Zdecydowanie najczęstszym podejściem do uczenia nienadzorowanego jest grupowanie, które polega na pobieraniu danych nieoznaczonych i używa algorytmów do grupowania podobnych elementów. Proces zwykle rozpoczyna się od zgadywania, a następnie wykonuje się iteracje obliczeń, aby uzyskać lepsze wyniki. Sednem tego jest znajdowanie elementów danych, które są blisko siebie, co można osiągnąć za pomocą różnych metod ilościowych:

• Metryka Euklidesa: Jest to linia prosta pomiędzy dwoma punktami danych. Metryka euklidesowa jest dość powszechna w przypadku uczenia maszynowego.

• Metryka podobieństwa cosinusa: Jak sama nazwa wskazuje, do pomiaru kąta użyjesz cosinusa. Chodzi o to, aby znaleźć podobieństwa między dwoma punktami danych pod względem orientacji.

• Manhattan Metric: Obejmuje sumę bezwzględnych odległości dwóch punktów na współrzędnych wykresu. Nazywa się „Manhattanem", ponieważ nawiązuje do układu ulic miasta, który pozwala na krótsze odległości podróży.

Jeśli chodzi o przypadki użycia klastrowania, jednym z najczęstszych jest segmentacja klientów, która ma pomóc w lepszym ukierunkowaniu komunikatów marketingowych. W większości grupa, która ma podobne cechy, prawdopodobnie podziela zainteresowania i preferencje. Inną aplikacją jest analiza sentymentu, w której wydobywasz społecznościowe dane medialne i znajdź trendy. Dla firmy modowej może to mieć kluczowe znaczenie dla zrozumienia, jak dostosować styl nadchodzącej linii ubrań. Obecnie istnieją inne podejścia niż tylko grupowanie. Oto spojrzenie na trzy kolejne:

• Asocjacja: Podstawowa koncepcja jest taka, że jeśli zdarzy się X, to prawdopodobnie wydarzy się Y. Tak więc, jeśli kupisz moją książkę o AI, prawdopodobnie będziesz chciał kupić inne tytuły z tego gatunku. Dzięki skojarzeniu algorytm głębokiego uczenia może rozszyfrować tego rodzaju relacje. Może to skutkować potężnymi silnikami rekomendacji

• Wykrywanie anomalii: Identyfikuje wartości odstające lub anomalne wzorce w zestawie danych, co może być pomocne w aplikacjach cyberbezpieczeństwa. Według Asafa Cidona, który jest wiceprezesem ds. bezpieczeństwa poczty e-mail w Barracuda Networks: „Odkryliśmy, że łącząc wiele różnych sygnałów, takich jak treść wiadomości e-mail, nagłówek, wykres komunikacji społecznościowej, loginy IP, reguły przekazywania skrzynki odbiorczej itp. .- jesteśmy w stanie osiągnąć niezwykle wysoką precyzję w wykrywaniu ataków socjotechnicznych, nawet jeśli ataki są wysoce spersonalizowane i stworzone z myślą o konkretnej osobie w określonej organizacji. Uczenie maszynowe umożliwia nam wykrywanie ataków pochodzących z wewnątrz organizacji, których źródłem jest legalna skrzynka pocztowa pracownika, co byłoby niemożliwe w przypadku statycznego, uniwersalnego silnika reguł".

• Autokodery: Dzięki temu dane zostaną umieszczone w skompresowanej formie, a następnie zostaną zrekonstruowane. Z tego mogą wyłonić się nowe wzorce. Jednak użycie autokoderów jest rzadkie. Można jednak wykazać, że może być przydatny w aplikacjach, takich jak redukcja szumu w danych.

Weź pod uwagę, że wielu badaczy sztucznej inteligencji uważa, że nienadzorowane uczenie się będzie prawdopodobnie miało kluczowe znaczenie dla następnego poziomu osiągnięć. Według artykułu w Nature autorstwa Yanna LeCuna, Geoffreya Hintona i Yoshuy Bengio: „Oczekujemy, że nauka bez nadzoru stanie się znacznie ważniejsza w dłuższej perspektywie. Uczenie się ludzi i zwierząt jest w dużej mierze nienadzorowane: odkrywamy strukturę świata, obserwując go, a nie wymawiając nazwę każdego przedmiotu

**Nauka przez wzmacnianie**

Kiedy byłeś dzieckiem i chciałeś uprawiać nowy sport, prawdopodobnie nie czytałeś instrukcji. Zamiast tego obserwowałeś, co robią inni ludzie i próbowałeś to rozgryźć. W niektórych sytuacjach popełniłeś błędy i straciłeś piłkę, gdy twoi koledzy z drużyny okazywali niezadowolenie. Ale w innych przypadkach wykonałeś właściwe ruchy i zdobyłeś punkty. Dzięki temu procesowi opartemu na próbach i błędach Twoja nauka została ulepszona w oparciu o pozytywne i negatywne wzmocnienie. Na wysokim poziomie jest to analogiczne do uczenia się przez wzmacnianie. Było to kluczowe dla niektórych z najbardziej znaczących osiągnięć w sztucznej inteligencji, takich jak:

• Gry: są idealne do uczenia się przez wzmacnianie, ponieważ istnieją jasne zasady, wyniki i różne ograniczenia (takie jak plansza do gry). Budując model, możesz go przetestować za pomocą milionów symulacji, co oznacza, że system szybko stanie się coraz mądrzejszy. W ten sposób program może nauczyć się pokonać mistrza świata Go lub szachów.

• Robotyka: Kluczem jest umiejętność poruszania się w przestrzeni – a to wymaga oceny środowiska w wielu różnych punktach. Jeśli robot chce się przenieść, powiedzmy, do kuchni, będzie musiał omijać meble i inne przeszkody. Jeśli wpadnie na różne rzeczy, nastąpi negatywna akcja wzmacniająca.

**Nauka częściowo nadzorowana**

Jest to połączenie nauki nadzorowanej i nienadzorowanej. Dzieje się tak, gdy masz niewielką ilość nieoznakowanych danych. Można jednak użyć systemów uczenia głębokiego, aby przetłumaczyć nienadzorowane dane na dane nadzorowane - proces ten nazywa się pseudo-etykietowaniem. Następnie możesz zastosować algorytmy. Ciekawym przypadkiem użycia częściowo nadzorowanego uczenia się jest interpretacja MRI. Radiolog może najpierw oznaczyć skany, a następnie system głębokiego uczenia może znaleźć pozostałe wzorce.

**Typowe typy algorytmów uczenia maszynowego**

Nie mamy wystarczająco dużo miejsca, aby omówić wszystkie algorytmy uczenia maszynowego! Zamiast tego lepiej skupić się na najczęstszych. W dalszej części przyjrzymy się tym w następujących przypadkach:

• Uczenie nadzorowane: Algorytmy można sprowadzić do dwóch wariantów. Jednym z nich jest klasyfikacja, która dzieli zbiór danych na wspólne etykiety. Przykłady algorytmów obejmują naiwny klasyfikator Bayesa i k-najbliższy sąsiad. Następnie następuje regresja, która znajduje w danych ciągłe wzorce. W tym celu przyjrzymy się regresji liniowej, modelowaniu zespołowemu i drzewom decyzyjnym.

• Nienadzorowane uczenie się: W tej kategorii przyjrzymy się grupowaniu. W tym celu omówimy klastrowanie k-średnich.

**Naiwny klasyfikator Bayesa (nadzorowane uczenie się/klasyfikacja)**

Wcześniej przyjrzeliśmy się twierdzeniu Bayesa. Jeśli chodzi o uczenie maszynowe, zostało to zmodyfikowane w coś, co nazywa się Naïve Bayes Classifier. Jest to „naiwne", ponieważ zakłada się, że zmienne są od siebie niezależne, to znaczy występowanie jednej zmiennej nie ma nic wspólnego z innymi. To prawda, może się to wydawać wadą. Ale faktem jest, że klasyfikator Naïve Bayes okazał się dość skuteczny i szybki w rozwoju. Należy również zwrócić uwagę na inne założenie: założenie a priori. To mówi, że prognozy będą błędne, jeśli dane się zmienią. Istnieją trzy odmiany klasyfikatora Naïve Bayes:

• Bernoulli: Dzieje się tak, jeśli masz dane binarne (prawda/fałsz, tak/nie).

• Wielomianowy: Dzieje się tak, gdy dane są dyskretne, takie jak liczba stron książki.

• Gaussian: Dzieje się tak, jeśli pracujesz z danymi, które są zgodne z rozkładem normalnym.

Typowym przypadkiem użycia klasyfikatorów naiwnych Bayesa jest analiza tekstu. Przykłady obejmują wykrywanie spamu w wiadomościach e-mail, segmentację klientów, analizę sentymentu, diagnostykę medyczną i prognozy pogody. Powodem jest to, że takie podejście jest przydatne w klasyfikowaniu danych na podstawie kluczowych cech i wzorców. Aby zobaczyć, jak to się robi, weźmy przykład: załóżmy, że prowadzisz witrynę e-commerce i masz dużą bazę danych transakcji klientów. Chcesz

zobaczyć, jak zmienne, takie jak oceny produktów, rabaty i pora roku, wpływają na sprzedaż. Tabela jak wygląda zbiór danych.

**Rabat : Recenzja produktu : Zakup**

Tak : Wysoki : Tak

Tak : Niski : Tak

Nie : Niski : Nie

Nie : Niski : Nie

Nie : Niski : Nie

Nie : Wysoki : Tak

Tak : Wysoki : Nie

Tak : Niski : Tak

Nie : Wysoki : Tak

Tak : Wysoki : Tak

Nie : Wysoki : Nie

Nie : Niski : Tak

Tak : Wysoki : Tak

Tak : Niski : Nie

Następnie zorganizujesz te dane w tabelach częstości, jak pokazano w tabelach 3 i 4.

| | | Purchase | |
|---|---|---|---|
| | | Yes | No |
| **Discount** | Yes | 19 | 1 |
| | Yes | 5 | 5 |

| | | Purchase | | |
|---|---|---|---|---|
| | | Yes | No | Total |
| **Product Review** | **High** | 21 | 2 | 11 |
| | **Low** | 3 | 4 | 8 |
| | **Total** | 24 | 6 | 19 |

Patrząc na to, zakup nazywamy wydarzeniem, a rabaty i recenzje produktów jako zmienne niezależne. Następnie możemy stworzyć tabelę prawdopodobieństwa dla jednej ze zmiennych niezależnych, powiedzmy, recenzje produktów.

| | | Purchase | | |
|---|---|---|---|---|
| | | Yes | No | |
| Product Reviews | High | 9/24 | 2/6 | 11/30 |
| | Low | 7/24 | 1/6 | 8/30 |
| | | 24/30 | 6/30 | |

Korzystając z tego wykresu, widzimy, że prawdopodobieństwo zakupu przy niskiej recenzji produktu wynosi 7/24 lub 29%. Innymi słowy, naiwny klasyfikator Bayesa umożliwia bardziej szczegółowe prognozy w zbiorze danych. Jest również stosunkowo łatwy do nauczenia i może dobrze współpracować z małymi zestawami danych.

**K-Nearest Neighbor (nadzorowane uczenie się/klasyfikacja)**

K-Nearest Neighbor (k-NN) to metoda klasyfikacji zbioru danych (k oznacza liczbę sąsiadów). Teoria mówi, że te wartości, które są blisko siebie, prawdopodobnie będą dobrymi predyktorami dla modelu. Pomyśl o tym jako „Ptaki ze stada piór razem". Przypadkiem użycia k-NN jest ocena kredytowa, która opiera się na różnych czynnikach, takich jak dochód, historia płatności, lokalizacja, własność domu i tak dalej. Algorytm podzieli zbiór danych na różne segmenty klientów. Następnie, gdy do bazy zostanie dodany nowy klient, zobaczysz, do jakiego klastra się zalicza – i będzie to ocena kredytowa. K-NN jest w rzeczywistości prosty do obliczenia. W rzeczywistości nazywa się to leniwym uczeniem się, ponieważ nie ma procesu uczenia się z danymi. Aby użyć k-NN, musisz wymyślić odległość między najbliższymi wartościami. Jeśli wartości są liczbowe, można je oprzeć na odległości euklidesowej, co wymaga skomplikowanej matematyki. Lub, jeśli istnieją dane kategoryczne, możesz użyć metryki nakładania się (w tym przypadku dane są takie same lub bardzo podobne). Następnie musisz określić liczbę sąsiadów. Chociaż posiadanie większej ilości wygładzi model, może również oznaczać zapotrzebowanie na ogromną ilość zasobów obliczeniowych. Aby temu zaradzić, możesz przypisać wyższe wagi do danych, które są bliżej swoich sąsiadów.

**Regresja liniowa (nadzorowane uczenie/regresja)**

Regresja liniowa pokazuje związek między pewnymi zmiennymi. Równanie — zakładając, że istnieje wystarczająca ilość danych wysokiej jakości — może pomóc w przewidywaniu wyników na podstawie danych wejściowych. Przykład: Załóżmy, że mamy dane dotyczące liczby godzin spędzonych na nauce do egzaminu i oceny.

| Hours of Study | Grade Percentage |
|---|---|
| 1 | 0.75 |
| 1 | 0.69 |
| 1 | 0.71 |
| 3 | 0.82 |
| 3 | 0.83 |
| 4 | 0.86 |
| 5 | 0.85 |
| 5 | 0.89 |
| 5 | 0.84 |
| 6 | 0.91 |
| 6 | 0.92 |
| 7 | 0.95 |

Jak widać, ogólna zależność jest pozytywna (opisuje to tendencję, w której wyższa ocena jest skorelowana z większą liczbą godzin nauki). Za pomocą algorytmu regresji możemy wykreślić linię, która ma najlepsze dopasowanie (odbywa się to za pomocą obliczenia zwanego „najmniejszymi kwadratami", które minimalizuje błędy).

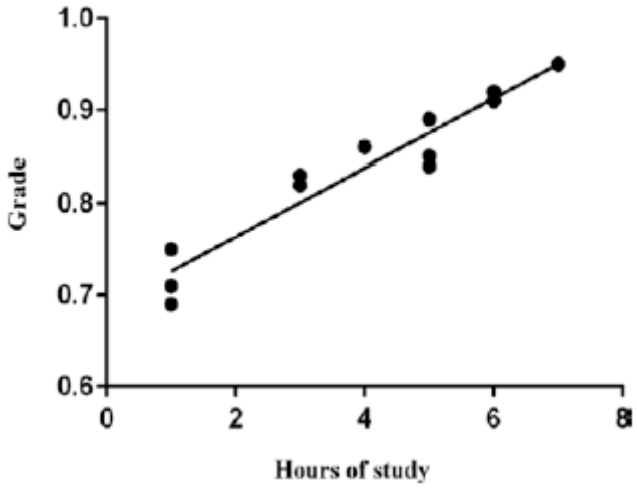


Z tego otrzymujemy następujące równanie:

Ocena = liczba godzin nauki × 0,03731 + 0,6889

Następnie załóżmy, że uczysz się 4 godziny do egzaminu. Jaka będzie Twoja szacunkowa ocena? Równanie mówi nam, jak:

0,838 = 4 × 0,03731 + 0,6889

Jak dokładne jest to? Aby pomóc odpowiedzieć na to pytanie, możemy użyć obliczenia o nazwie R-kwadrat. W naszym przypadku jest to 0,9180 (zakres od 0 do 1). Im wartość jest bliższa 1, tym lepsze dopasowanie. Tak więc 0,9180 jest dość wysokie. Oznacza to, że godziny nauki wyjaśniają 91,8% oceny z egzaminu. Teraz to prawda, że ten model jest uproszczony. Aby lepiej odzwierciedlić rzeczywistość,

możesz dodać więcej zmiennych, aby wyjaśnić ocenę na egzaminie - powiedz obecność ucznia. Robiąc to, użyjesz czegoś, co nazywa się regresją wielowymiarową.

* Uwaga Jeśli współczynnik dla zmiennej jest dość mały, dobrym pomysłem może być nieuwzględnianie go w modelu.

Czasami dane mogą również nie być w linii prostej, w którym to przypadku algorytm regresji nie zadziała. Ale możesz użyć bardziej złożonej wersji, zwanej regresją wielomianową.

**Drzewo decyzyjne (nadzorowane uczenie się/regresja)**

Bez wątpienia klastrowanie może nie działać w przypadku niektórych zestawów danych. Ale dobrą wiadomością jest to, że istnieją alternatywy, takie jak drzewo decyzyjne. To podejście ogólnie działa lepiej w przypadku danych nienumerycznych. Początkiem drzewa decyzyjnego jest węzeł główny, który znajduje się na górze schematu blokowego. Od tego momentu powstanie drzewo ścieżek decyzyjnych, które nazywane są podziałami. W tych punktach użyjesz algorytmu do podjęcia decyzji i zostanie obliczone prawdopodobieństwo. Na końcu drzewa będzie liść (lub wynik). Znanym przykładem w kręgach uczenia maszynowego jest wykorzystanie drzewa decyzyjnego do tragicznego zatonięcia Titanica. Model przewiduje przeżycie pasażera na podstawie trzech cech: płci, wieku i liczby współmałżonków lub dzieci (sibsp). Oto jak to wygląda na rysunku.

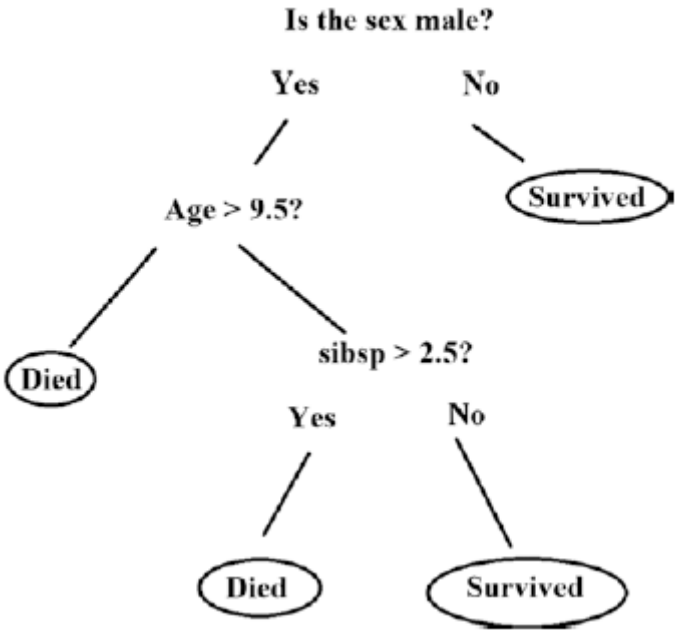


Drzewa decyzyjne mają wyraźne zalety. Są łatwe do zrozumienia, dobrze współpracują z dużymi zestawami danych i zapewniają przejrzystość modelu. Jednak drzewa decyzyjne mają również wady. Jednym z nich jest propagacja błędów. Jeśli jeden z podziałów okaże się błędny, błąd ten może kaskadowo rozprzestrzenić się na resztę modelu! Następnie, w miarę wzrostu drzew decyzyjnych, będzie wzrastać złożoność, ponieważ będzie duża liczba algorytmów. Może to ostatecznie skutkować niższą wydajnością modelu.

**Modelowanie zespołowe (nadzorowane uczenie się/regresja)**

Modelowanie zespołowe oznacza używanie więcej niż jednego modelu do prognoz. Mimo że zwiększa to złożoność, wykazano, że takie podejście generuje dobre wyniki. Aby zobaczyć to w akcji, spójrz na „Nagrodę Netflix", która rozpoczęła się w 2006 roku. Firma ogłosiła, że zapłaci milion dolarów każdemu

lub dowolnemu zespołowi, który może poprawić dokładność swojego systemu rekomendacji filmów o 10% lub więcej. Netflix dostarczył również zbiór danych zawierający ponad 100 milionów ocen 17 770 filmów od 480 189 użytkowników16. Ostatecznie liczba pobrań przekroczyłaby 30 000. Dlaczego Netflix to wszystko zrobił? Dużym powodem jest to, że inżynierowie firmy mieli problemy z postępem. Dlaczego więc nie dać tego tłumowi, aby się zorientował? Okazało się to dość pomysłowe — a wypłata 1 miliona dolarów była naprawdę skromna w porównaniu z potencjalnymi korzyściami. Konkurs z pewnością wywołał dużą aktywność ze strony programistów i naukowców zajmujących się danymi, od studentów po pracowników firm takich jak AT&T. Netflix również uprościł konkurs. Głównym wymogiem było ujawnienie przez zespoły swoich metod, co pomogło zwiększyć wyniki (był nawet dashboard z rankingami zespołów). Jednak dopiero w 2009 roku nagrodę zdobył zespół – Pragmatic Chaos firmy BellKor. Z drugiej strony pojawiły się spore wyzwania. Jak więc udało się to zwycięskiej drużynie? Pierwszym krokiem było stworzenie modelu bazowego, który wygładził trudne problemy z danymi. Na przykład niektóre filmy miały tylko kilka ocen, podczas gdy inne miały tysiące. Następnie pojawił się drażliwy problem polegający na tym, że byli użytkownicy, którzy zawsze oceniali film jedną gwiazdką. Aby poradzić sobie z tymi sprawami, BellKor wykorzystał uczenie maszynowe do przewidywania ocen w celu wypełnienia luk. Po zakończeniu planu bazowego pojawiły się trudniejsze wyzwania, takie jak:

• System może zakończyć się polecaniem tych samych filmów wielu użytkownikom.

• Niektóre filmy mogą nie pasować do gatunków. Na przykład Alien to tak naprawdę skrzyżowanie science fiction i horroru.

• Były filmy, takie jak Napoleon Dynamite, które okazały się niezwykle trudne do zrozumienia dla algorytmów.

• Oceny filmu często zmieniały się z czasem.

Zwycięski zespół wykorzystał modelowanie zespołowe, które obejmowało setki algorytmów. Wykorzystali również coś, co nazywa się boostingiem, czyli gdzie budujesz kolejne modele. Dzięki temu wagi w algorytmach są dostosowywane w oparciu o wyniki poprzedniego modelu, co pomaga z czasem poprawiać przewidywania (inne podejście, zwane baggingiem, polega na równoległym budowaniu różnych modeli, a następnie wybraniu najlepszego). Ale w końcu BellKor znalazł rozwiązanie. Jednak mimo to Netflix nie wykorzystał tego modelu! Teraz nie jest jasne, dlaczego tak było. Być może chodziło o to, że Netflix i tak odchodził od pięciogwiazdkowych ocen i był bardziej skoncentrowany na przesyłaniu strumieniowym. Konkurs spotkał się również z reakcją osób, które sądziły, że mogło dojść do naruszenia prywatności. Niezależnie od tego konkurs podkreślał siłę uczenia maszynowego i znaczenie współpracy.

**Klastrowanie metodą K-Means (nienadzorowane/klastrowanie)**

Algorytm grupowania k-średnich, który jest skuteczny w przypadku dużych zestawów danych, umieszcza podobne, nieoznakowane dane w różnych grupach. Pierwszym krokiem jest wybranie k, czyli liczby klastrów. Aby w tym pomóc, możesz wykonać wizualizacje tych danych, aby sprawdzić, czy istnieją zauważalne obszary grupowania. Oto spojrzenie na przykładowe dane na rysunku:

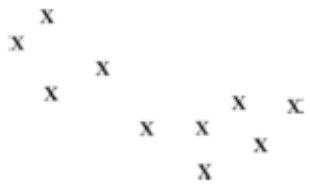

W tym przykładzie zakładamy, że będą dwa klastry, a to oznacza, że będą też dwa centroidy. Centroid to środek klastra. Każdy przypiszemy losowo, co widać na rysunku.

Jak widać, centroid w lewym górnym rogu wygląda daleko, ale ten po prawej stronie jest lepszy. Algorytm k-średnich obliczy następnie średnie odległości centroidów, a następnie zmieni ich położenie. Będzie to powtarzane, aż błędy będą dość minimalne - punkt zwany zbieżnością, który można zobaczyć na rysunku.

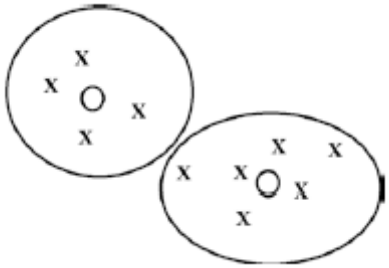

To prawda, to prosta ilustracja. Ale oczywiście przy złożonym zbiorze danych trudno będzie określić liczbę początkowych klastrów. W tej sytuacji możesz poeksperymentować z różnymi wartościami k, a następnie zmierzyć średnie odległości. Robiąc to wiele razy, powinno być więcej dokładności. Dlaczego więc nie mieć po prostu wysokiej liczby dla k? Z pewnością możesz to zrobić. Ale kiedy obliczysz średnią, zauważysz, że będą tylko przyrostowe ulepszenia. Tak więc jedną metodą jest zatrzymanie się w punkcie, w którym to się zaczyna. Widać to na rysunku.

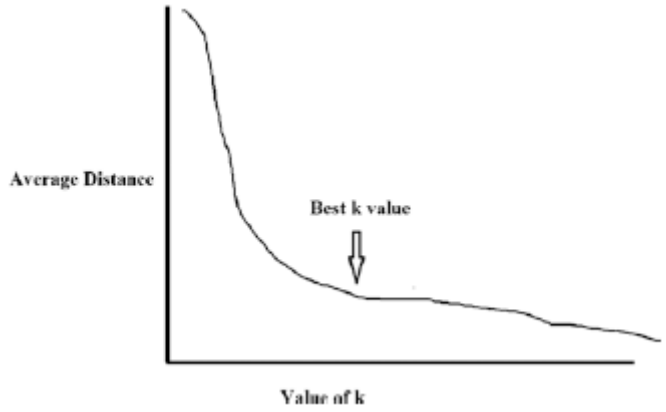


Jednak k-Means ma swoje wady. Na przykład nie działa dobrze z danymi niesferycznymi, co ma miejsce na rysunku.

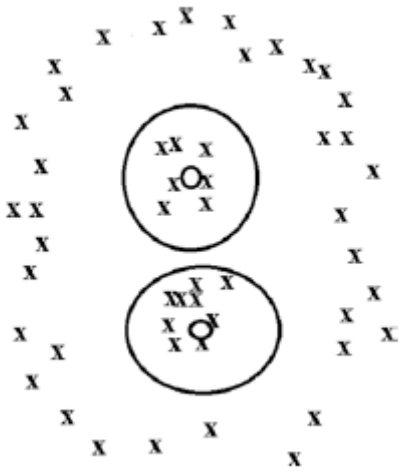

Dzięki temu algorytm k-średnich prawdopodobnie nie wykryłby otaczających danych, mimo że ma wzór. Ale istnieją pewne algorytmy, które mogą pomóc, takie jak DBScan (przestrzenne klastrowanie aplikacji z szumem oparte na gęstości), które ma obsługiwać mieszankę zestawów danych o bardzo różnych rozmiarach. Chociaż DBScan może wymagać dużej mocy obliczeniowej. Następnie mamy do czynienia z sytuacją, w której istnieją klastry z dużą ilością danych, a inne z niewielką ilością. Co może się stać? Istnieje szansa, że algorytm k-średnich nie wykryje tego lekkiego. Tak jest w przypadku rysunku.

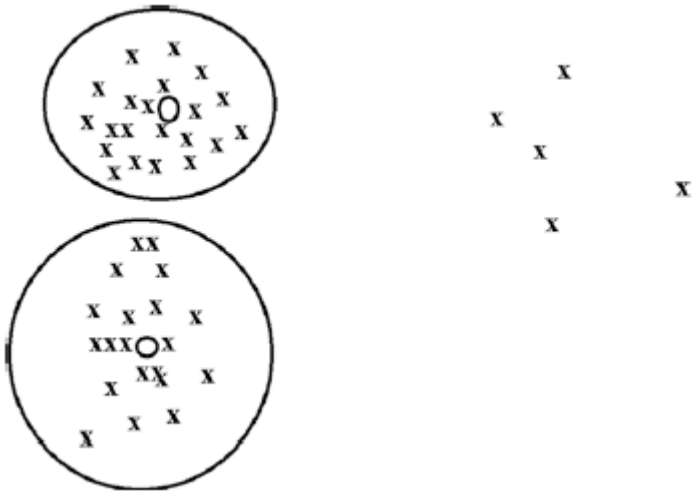

**Wniosek**

Algorytmy te mogą się skomplikować i wymagają dużych umiejętności technicznych. Ale ważne jest, aby nie ugrzęznąć zbytnio w technologii. W końcu skupiamy się na znalezieniu sposobów wykorzystania uczenia maszynowego do osiągnięcia jasnych celów. Ponownie, Stich Fix to dobre miejsce, aby uzyskać wskazówki na ten temat. W listopadowym numerze Harvard Business Review, dyrektor ds. algorytmów firmy, Eric Colson, opublikował artykuł „Curiosity-Driven Data Science”17. Przedstawił w nim swoje doświadczenia w tworzeniu organizacji opartej na danych. Sednem tego jest umożliwienie analitykom danych odkrywania nowych pomysłów, koncepcji i podejść. Doprowadziło to do wdrożenia sztucznej inteligencji w podstawowych funkcjach firmy, takich jak zarządzanie zapasami, zarządzanie relacjami, logistyka i kupowanie towarów. Przekształciło to, czyniąc organizację bardziej zwinną i usprawnioną. Colson uważa również, że stanowi „barierę ochronną przed konkurencją”. Jego artykuł zawiera również inne przydatne porady dotyczące analizy danych:

• Naukowcy zajmujący się danymi: Nie powinni być częścią innego działu. Raczej powinni mieć swój własny, który podlega bezpośrednio prezesowi. Pomaga to skoncentrować się na kluczowych priorytetach, a także mieć holistyczne spojrzenie na potrzeby organizacji.

• Eksperymenty: Kiedy analityk danych ma nowy pomysł, powinien zostać przetestowany na małej próbce klientów. Jeśli jest przyczepność, można ją rozwinąć na resztę podstawy.

• Zasoby: Analitycy danych potrzebują pełnego dostępu do danych i narzędzi. Powinny też odbywać się ciągłe szkolenia.

• Generaliści: Zatrudnij naukowców zajmujących się danymi, którzy zajmują się różnymi dziedzinami, takimi jak modelowanie, uczenie maszynowe i analityka (Colson określa tych ludzi jako „pełnostackowych analityków danych"). Prowadzi to do powstania małych zespołów, które często są bardziej wydajne i produktywne.

• Kultura: Colson poszukuje wartości, takich jak „uczenie się przez działanie, bycie komfortowym w niejednoznaczności, równoważenie długo- i krótkoterminowych zysków".

**Kluczowe dania na wynos**

• Uczenie maszynowe, którego korzenie sięgają lat pięćdziesiątych, to miejsce, w którym komputer może uczyć się bez wyraźnego programowania. Raczej pozyskuje i przetwarza dane przy użyciu zaawansowanych technik statystycznych.

• Wartość odstająca to dane, które znacznie wykraczają poza pozostałe liczby w zbiorze danych.

• Odchylenie standardowe mierzy średnią odległość od średniej.

• Rozkład normalny, który ma kształt dzwonu, reprezentuje sumę prawdopodobieństw dla zmiennej.

• Twierdzenie Bayesa to zaawansowana technika statystyczna, która zapewnia głębsze spojrzenie na prawdopodobieństwa.

• Prawdziwie pozytywne jest to, gdy model dokonuje prawidłowej prognozy. Z drugiej strony, fałszywie dodatni wynik ma miejsce, gdy prognoza modelu pokazuje, że wynik jest prawdziwy, mimo że tak nie jest.

• Korelacja Pearsona pokazuje siłę związku między dwiema zmiennymi w zakresie od 1 do -1.

• Ekstrakcja cech lub inżynieria cech opisuje proces wyboru zmiennych do modelu. Jest to krytyczne, ponieważ nawet jedna niewłaściwa zmienna może mieć duży wpływ na wyniki.

• Dane uczące są używane do tworzenia relacji w algorytmie. Z drugiej strony dane testowe służą do oceny modelu.

• Uczenie nadzorowane wykorzystuje oznakowane dane do stworzenia modelu, podczas gdy uczenie nienadzorowane nie. Istnieje również nauka częściowo nadzorowana, która wykorzystuje mieszankę obu podejść.

• Uczenie się ze wzmacnianiem to sposób na trenowanie modelu poprzez nagradzanie trafnych prognoz i karanie tych, które nie są.

• K-Nearest Neighbor (k-NN) to algorytm oparty na założeniu, że wartości, które są blisko siebie, są dobrymi predyktorami modelu.

• Regresja liniowa szacuje związek między pewnymi zmiennymi. R-kwadrat wskaże siłę związku.

- Drzewo decyzyjne to model oparty na przepływie pracy decyzji tak/nie.
- Model zespołowy wykorzystuje do prognoz więcej niż jeden model.
- Algorytm grupowania k-średnich umieszcza podobne nieoznakowane dane w różnych grupach.

Regresja liniowa (nadzorowane uczenie/regresja)

Regresja liniowa pokazuje związek między pewnymi zmiennymi. Równanie — zakładając, że istnieje wystarczająca ilość danych wysokiej jakości — może pomóc w przewidywaniu wyników na podstawie danych wejściowych. Przykład: Załóżmy, że mamy dane dotyczące liczby godzin spędzonych na nauce do egzaminu i oceny. Zobacz Tabela 3-6.

**Głęboka nauka. Rewolucja w AI**

Weźmy dowolny stary problem z klasyfikacją, w którym masz dużo danych, a zostanie on rozwiązany przez głębokie uczenie. Będą tysiące zastosowań głębokiego uczenia się. - Geoffrey Hinton

Angielsko-kanadyjska psycholog kognitywna i informatyk Fei-Fei Li, która uzyskała tytuł licencjata z fizyki w Princeton w 1999 roku z wysokim wyróżnieniem oraz doktorat z elektrotechniki w Caltech w 2005 roku, skupiła się na tworzeniu modeli AI. Miała jednak poważne wyzwanie: znalezienie wysokiej jakości zbiorów danych. Początkowo przyglądała się tworzeniu ich ręcznie, na przykład ze studentami, którzy pobierali obrazy z Internetu. Ale proces był zbyt powolny i żmudny. Pewnego dnia student wspomniał Li, że Mechanical Turk firmy Amazon.com, usługa online wykorzystująca crowdsourcing do rozwiązywania problemów, może być dobrym sposobem na skalowanie procesu. Pozwoliłoby to na szybkie i dokładne oznakowanie danych. Li spróbował i wyszło całkiem nieźle. Do 2010 roku stworzyła ImageNet, który zawierał 3,2 miliona obrazów w ponad 5200 kategoriach. Jednak spotkał się z chłodną reakcją społeczności akademickiej. Ale to nie powstrzymało Li. Kontynuowała niestrudzoną pracę nad ewangelizacją zbioru danych. W 2012 roku ogłosiła konkurs, aby zachęcić naukowców do tworzenia bardziej efektywnych modeli i przesuwania granic innowacji. Okazałby się przełomem, a konkurs stałby się corocznym wydarzeniem. W pierwszym konkursie profesorowie z University of Toronto-Geoffrey Hinton, Ilya Sutskever i Alex Krizhevsky wykorzystali zaawansowane algorytmy głębokiego uczenia. A wyniki były wyjątkowe. Zbudowany przez nich system, nazwany AlexNet, pokonał wszystkich pozostałych uczestników o 10,8%. To nie był przypadek. W następnych latach głębokie uczenie się nadal wykazywało przyspieszone postępy z ImageNet. W tej chwili wskaźnik błędów dla głębokiego uczenia się wynosi zaledwie 2%, co jest lepsze niż u ludzi. Nawiasem mówiąc, Li od tego czasu została profesorem w Stanford i współdyrektorem szkolnego laboratorium sztucznej inteligencji. Jest także głównym naukowcem Google zajmującym się sztuczną inteligencją i uczeniem maszynowym. Nie trzeba dodawać, że ilekroć ma teraz nowe pomysły, ludzie jej słuchają. Przyjrzymy się głębokiemu uczeniu, które jest zdecydowanie najgorętszym obszarem sztucznej inteligencji. Doprowadziło to do znacznych postępów w obszarach takich jak autonomiczne samochody i wirtualni asystenci, tacy jak Siri. Tak, głębokie uczenie się może być skomplikowanym tematem, a dziedzina ciągle się zmienia. Ale przyjrzymy się głównym koncepcjom i trendom – bez wchodzenia w szczegóły techniczne.

**Różnica między głębokim uczeniem a uczeniem maszynowym**

Często dochodzi do zamieszania między głębokim uczeniem a uczeniem maszynowym. I to jest rozsądne. Oba tematy są dość złożone i mają wiele podobieństw. Aby zrozumieć różnice, przyjrzyjmy się najpierw dwóm wysokopoziomowym aspektom uczenia maszynowego i ich powiązaniu z uczeniem głębokim. Przede wszystkim, chociaż oba zwykle wymagają dużej ilości danych, typy są generalnie różne. Weźmy następujący przykład: Załóżmy, że mamy zdjęcia tysięcy zwierząt i chcemy stworzyć algorytm do wyszukiwania koni. Cóż, uczenie maszynowe nie może analizować samych zdjęć; zamiast tego dane muszą być oznakowane. Algorytm uczenia maszynowego zostanie następnie przeszkolony do rozpoznawania koni w procesie znanym jako uczenie nadzorowane. Nawet jeśli uczenie maszynowe prawdopodobnie przyniesie dobre wyniki, nadal będą miały ograniczenia. Czy nie byłoby lepiej przyjrzeć się pikselom samych obrazów i znaleźć wzory? Zdecydowanie. Ale aby to zrobić z uczeniem maszynowym, musisz użyć procesu zwanego wyodrębnianiem funkcji. Oznacza to, że musisz wymyślić rodzaje cech konia – takie jak kształt, kopyta, kolor i wzrost – które algorytmy spróbują następnie zidentyfikować. Znowu jest to dobre podejście, ale daleko mu do ideału. Co się stanie, jeśli Twoje cechy są nieodpowiednie lub nie uwzględniają wartości odstających lub wyjątków? W takich przypadkach prawdopodobnie ucierpi dokładność modelu. W końcu istnieje wiele odmian konia. Wyodrębnianie funkcji ma również wadę polegającą na ignorowaniu dużej ilości danych. Może to być niezwykle skomplikowane – jeśli nie niemożliwe – w niektórych przypadkach użycia. Spójrz na wirusy

komputerowe. Ich struktury i wzory, znane jako sygnatury, nieustannie się zmieniają, aby przenikać do systemów. Ale przy ekstrakcji cech osoba musiałaby jakoś to przewidzieć, co nie jest praktyczne. To dlatego oprogramowanie cyberbezpieczeństwa często zbiera sygnatury po tym, jak wirus wyrządził szkody. Ale dzięki głębokiemu uczeniu możemy rozwiązać te problemy. Podejście to analizuje wszystkie dane piksel po pikselu, a następnie odnajduje zależności za pomocą sieci neuronowej, która naśladuje ludzki mózg. Spójrzmy…

**Czym więc jest głębokie uczenie?**

Głębokie uczenie to poddziedzina uczenia maszynowego. Ten rodzaj systemu pozwala na przetwarzanie ogromnych ilości danych w celu znalezienia relacji i wzorców, których ludzie często nie są w stanie wykryć. Słowo „głębokie" odnosi się do liczby ukrytych warstw w sieci neuronowej, które zapewniają dużą moc uczenia się. Jeśli chodzi o sztuczną inteligencję, głębokie uczenie jest w czołówce i często generuje większość szumu w mediach głównego nurtu. „[Głębokie uczenie] AI to nowa elektryczność" – wychwalał Andrew Yan-Tak Ng, były główny naukowiec w Baidu i współzałożyciel Google Brain. Ale ważne jest również, aby pamiętać, że uczenie głębokie jest wciąż na wczesnym etapie rozwoju i komercjalizacji. Na przykład dopiero około 2015 roku Google zaczął używać tej technologii w swojej wyszukiwarce. Jak widzieliśmy w rozdziale 1, historia sieci neuronowych była pełna przypływów i przepływów. To Frank Rosenblatt stworzył perceptron, który był dość podstawowym systemem. Jednak prawdziwy postęp akademicki w zakresie sieci neuronowych nastąpił dopiero w latach 80., tak jak w przypadku przełomów w zakresie wstecznej propagacji, splotowych sieci neuronowych i sieci neuronowych rekurencyjnych. Aby jednak uczenie głębokie miało wpływ na rzeczywisty świat, potrzebny byłby oszałamiający wzrost ilości danych, na przykład z Internetu, oraz gwałtowny wzrost mocy obliczeniowej.

**Mózg i głębokie uczenie**

Ważący zaledwie około 3,3 funta ludzki mózg jest niesamowitym wyczynem ewolucji. Istnieje około 86 miliardów neuronów - często nazywanych istotą szarą – które są połączone z bilionami synaps. Pomyśl o neuronach jako procesorach (Central Processing Units), które pobierają dane. Uczenie następuje wraz ze wzmocnieniem lub osłabieniem synaps. Mózg składa się z trzech regionów: przodomózgowia, śródmózgowia i tyłomózgowia. Wśród nich jest wiele obszarów, które pełnią różne funkcje. Niektóre z głównych to:

• Hipokamp: To tutaj twój mózg przechowuje wspomnienia. W rzeczywistości jest to część, która zawodzi, gdy osoba cierpi na chorobę Alzheimera, w której osoba traci zdolność do tworzenia wspomnień krótkotrwałych.

• Płat czołowy: tutaj mózg skupia się na emocjach, mowie, kreatywności, ocenie, planowaniu i rozumowaniu.

• Kora mózgowa: jest to prawdopodobnie najważniejsza cecha, jeśli chodzi o sztuczną inteligencję. Kora mózgowa pomaga w myśleniu i innych czynnościach poznawczych. Według badań Suzany Herculano-Houzel poziom inteligencji jest powiązany z liczbą neuronów w tym obszarze mózgu.

Zatem jak głębokie uczenie się wypada w porównaniu z ludzkim mózgiem? Istnieją pewne wątłe podobieństwa. Przynajmniej w obszarach takich jak siatkówka istnieje proces pozyskiwania danych i przetwarzania ich przez złożoną sieć, która opiera się na przypisywaniu wag. Ale oczywiście jest to tylko minutowa część procesu uczenia się. Poza tym ludzki mózg wciąż kryje wiele tajemnic i oczywiście nie opiera się on na takich rzeczach jak komputery cyfrowe (zamiast tego wydaje się, że jest to raczej

system analogowy). Jednak wraz z postępem badań odkrycia w neuronauce mogą pomóc w tworzeniu nowych modeli sztucznej inteligencji.

**Sztuczne sieci neuronowe (SSN)**

Na najbardziej podstawowym poziomie sztuczna sieć neuronowa (SSN) to funkcja obejmująca jednostki (które mogą być również nazywane neuronami, perceptronami lub węzłami). Każda jednostka będzie miała wartość i wagę, które wskazują na względną wagę, i trafi do ukrytej warstwy. Warstwa ukryta używa funkcji, a wynik staje się wynikiem. Istnieje również inna wartość, zwana bias, która jest stałą i jest używana do obliczania funkcji. Ten rodzaj uczenia modelu nazywa się siecią neuronową ze sprzężeniem do przodu. Innymi słowy, przechodzi tylko od wejścia do ukrytej warstwy do wyjścia. Nie wraca. Ale może trafić do nowej sieci neuronowej, w której dane wyjściowe stają się danymi wejściowymi. Rysunek przedstawia wykres sieci neuronowej ze sprzężeniem do przodu.

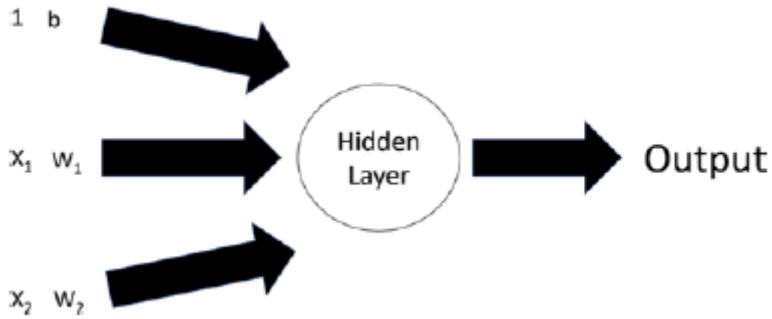


Zagłębmy się w to, biorąc przykład. Załóżmy, że tworzysz model, aby przewidzieć, czy akcje firmy wzrosną. Poniżej przedstawiono, co reprezentują zmienne, a także przypisane wartości i wagi:

• X1: Przychody rosną o co najmniej 20% rocznie. Wartość to 2.

• X2: Marża zysku wynosi co najmniej 20%. Wartość to 4.

• W1: 1.9.

• W2: 9.6.

• b: To jest odchylenie (wartość wynosi 1), które pomaga wygładzić obliczenia.

Następnie zsumujesz wagi, a następnie funkcja przetworzy informacje. Często wiąże się to z funkcją aktywacji, która jest nieliniowa. Odzwierciedla to bardziej rzeczywisty świat, ponieważ dane zwykle nie są w linii prostej. Teraz do wyboru jest wiele funkcji aktywacji. Jednym z najczęstszych jest esicy. Powoduje to kompresję wartości wejściowej do zakresu 0–1. Im bliżej 1, tym dokładniejszy model. Kiedy narysujesz tę funkcję, będzie ona wyglądać jak kształt litery S. Patrz rysunek

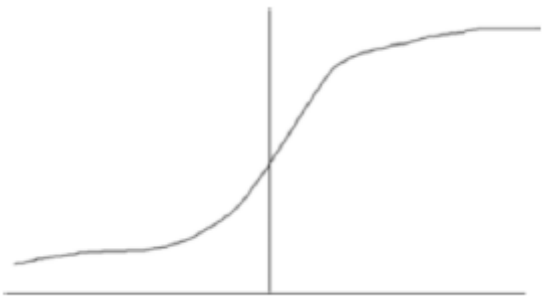

Jak widać, system jest stosunkowo uproszczony i nie będzie pomocny w zaawansowanych modelach AI. Aby dodać znacznie więcej mocy, zwykle potrzeba wielu ukrytych warstw. Powoduje to wielowarstwowy perceptron (MLP). Pomaga również użyć czegoś, co nazywa się propagacją wsteczną, która pozwala na zakręcenie wyjścia z powrotem do sieci neuronowej.

**Propagacja wsteczna**

Jedną z głównych wad sztucznych sieci neuronowych jest proces wprowadzania korekt wag w modelu. Tradycyjne podejścia, takie jak zastosowanie algorytmu mutacji, wykorzystywały wartości losowe, które okazały się czasochłonne. Biorąc to pod uwagę, naukowcy szukali alternatyw, takich jak wsteczna propagacja. Ta technika istniała od lat 70., ale nie cieszyła się dużym zainteresowaniem, ponieważ brakowało jej wydajności. Ale David Rumelhart, Geoffrey Hinton i Ronald Williams zdali sobie sprawę, że wsteczna propagacja wciąż ma potencjał, o ile została udoskonalona. W 1986 r. napisali artykuł zatytułowany „Uczenie się reprezentacji przez błędy wstecznej propagacji błędów" i był to bomba w społeczności AI. Wyraźnie pokazało, że wsteczna propagacja może być znacznie szybsza, ale także umożliwiać tworzenie potężniejszych sztucznych sieci neuronowych. Nie powinno dziwić, że w propagację wsteczną jest dużo matematyki. Ale kiedy się sprowadza, chodzi o dostosowanie sieci neuronowej, gdy zostaną znalezione błędy, a następnie iterowanie nowych wartości przez sieć neuronową ponownie. Zasadniczo proces obejmuje niewielkie zmiany, które nadal optymalizują model. Na przykład załóżmy, że jedno z wejść ma wyjście 0,6. Oznacza to, że błąd wynosi 0,4 (1,0 minus 0,6), co jest subpar. Ale możemy wtedy dokonać wstecznej propagacji danych wyjściowych i być może nowe dane wyjściowe mogą osiągnąć 0,65. To szkolenie będzie trwało do momentu, gdy wartość będzie znacznie zbliżona do 1. Rysunek 4-3 ilustruje ten proces.

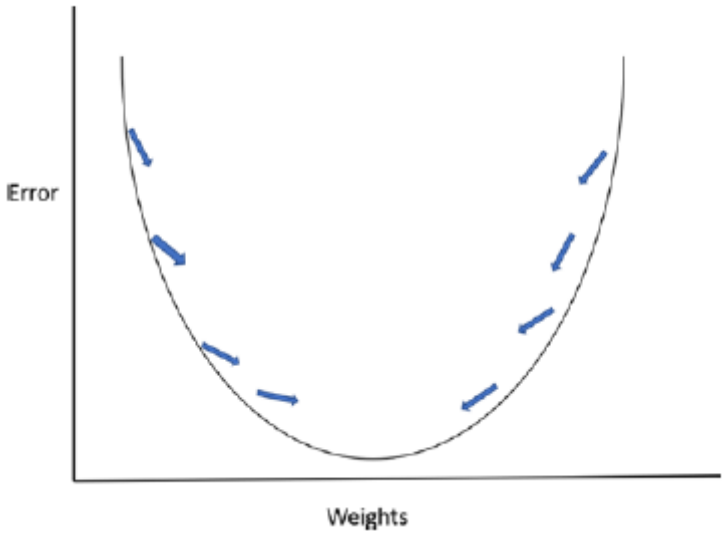


Na początku występuje wysoki poziom błędów, ponieważ wagi są zbyt duże. Ale robiąc iteracje, błędy będą stopniowo spadać. Jednak robienie tego zbyt wiele może oznaczać wzrost liczby błędów. Innymi słowy, celem propagacji wstecznej jest znalezienie punktu środkowego. Miarą powodzenia wstecznej propagacji było pojawienie się niezliczonych zastosowań komercyjnych. Jeden nazywał się NETtalk, który został opracowany przez Terrence'a Sejnowskiego i Charlesa Rosenberga w połowie lat 80-tych. Maszyna była w stanie nauczyć się wymawiać tekst w języku angielskim. NETtalk był tak interesujący, że został nawet zaprezentowany w programie Today. Powstało również wiele startupów wykorzystujących wsteczną propagację, takich jak HNC Software. Zbudował modele wykrywające oszustwa związane z kartami kredytowymi. Aż do tego momentu — kiedy pod koniec lat 80. założono

HNC — proces ten był wykonywany głównie ręcznie, co prowadziło do kosztownych błędów i niskich wolumenów emisji. Jednak stosując metody głębokiego uczenia się, firmy obsługujące karty kredytowe były w stanie zaoszczędzić miliardy dolarów. W 2002 roku firma HNC została przejęta przez Fair, Isaac i wyceniona na 810 milionów dolarów.

**Różne sieci neuronowe**

Najbardziej podstawowym typem sieci neuronowej jest w pełni połączona sieć neuronowa. Jak sama nazwa wskazuje, jest to miejsce, w którym wszystkie neurony mają połączenia między warstwami. Ta sieć jest w rzeczywistości dość popularna, ponieważ oznacza to, że przy tworzeniu modelu trzeba używać niewielkiego osądu. A jakie są inne sieci neuronowe? Typowe z nich obejmują rekurencyjną sieć neuronową (RNN), splotową sieć neuronową (CNN) i generatywną sieć kontradyktoryjną (GAN), którą omówimy dalej.

**Rekurencyjna sieć neuronowa**

W przypadku rekurencyjnej sieci neuronowej (RNN) funkcja nie tylko przetwarza dane wejściowe, ale także wcześniejsze dane wejściowe w czasie. Przykładem tego jest to, co dzieje się, gdy wprowadzasz znaki w aplikacji do przesyłania wiadomości. Gdy zaczniesz pisać, system przewidzi słowa. Jeśli więc naciśniesz „On", komputer zasugeruje „On", „Cześć" i „Oto". RNN jest zasadniczo ciągiem sieci neuronowych, które żywią się sobą na podstawie złożonych algorytmów. Istnieją odmiany modelu. Jeden nazywa się LSTM, co oznacza długą pamięć krótkotrwałą. Wynikało to z artykułu napisanego przez profesorów Seppa Hochreitera i Jürgena Schmidhubera w 1997 roku6. Przedstawili w nim sposób na efektywne wykorzystanie danych wejściowych, które są od siebie oddzielone przez długi czas, co pozwala na użycie większej liczby zbiorów danych. Oczywiście RNN mają wady. Występuje problem znikającego gradientu, co oznacza, że dokładność spada wraz ze wzrostem modeli. Trening modeli może zająć więcej czasu. Aby sobie z tym poradzić, Google opracował nowy model o nazwie Transformer, który jest znacznie bardziej wydajny, ponieważ równolegle przetwarza dane wejściowe. Daje to również dokładniejsze wyniki. Google uzyskał wiele informacji na temat RNN dzięki aplikacji Tłumacz, która obsługuje ponad 100 języków i przetwarza ponad 100 miliardów słów dziennie. Uruchomiony w 2006 roku, początkowo wykorzystywał systemy uczenia maszynowego. Ale w 2016 r. Google przeszło na głębokie uczenie, tworząc Google Neural Machine Translation.8 Podsumowując, zaowocowało to znacznie wyższymi wskaźnikami dokładności. Zastanów się, jak Tłumacz Google pomógł lekarzom, którzy pracują z pacjentami posługującymi się innymi językami. Według badania przeprowadzonego na Uniwersytecie Kalifornijskim w San Francisco (UCSF), opublikowanego w JAMA Internal Medicine, aplikacja miała wskaźnik dokładności na poziomie 92% z tłumaczeniami z języka angielskiego na hiszpański. To wzrosło z 60% w ciągu ostatnich kilku lat.

**Konwolucyjna sieć neuronowa (CNN)**

Intuicyjnie, sensowne jest, aby wszystkie jednostki w sieci neuronowej były połączone. Działa to dobrze z wieloma aplikacjami. Ale są scenariusze, w których jest to dalekie od optymalnego, takie jak rozpoznawanie obrazu. Wyobraź sobie, jak skomplikowany byłby model, w którym każdy piksel jest jednostką! Może szybko stać się nie do opanowania. Pojawiłyby się również inne komplikacje, takie jak nadmierne dopasowanie. W tym miejscu dane nie odzwierciedlają tego, co jest testowane lub skupiają się na niewłaściwych funkcjach. Aby sobie z tym wszystkim poradzić, możesz użyć splotowej sieci neuronowej (CNN). Początki tego zjawiska sięgają profesora Yanna LeCuna w 1998 roku, kiedy opublikował artykuł zatytułowany „Gradient-Based Learning Applied to Document Recognition"11. Jednak gdy w 2012 r. uczenie głębokie zaczęło wykazywać znaczne postępy, naukowcy ponownie przyjrzeli się modelowi. LeCun czerpał inspirację dla CNN od zdobywców Nagrody Nobla Davida Hubela i Torstena Wiesela, którzy badali neurony kory wzrokowej. System ten pobiera obraz z siatkówki i

przetwarza go na różnych etapach – od łatwego do bardziej złożonego. Każdy z etapów nazywany jest splotem. Na przykład pierwszym poziomem byłoby zidentyfikowanie linii i kątów; następnie kora wzrokowa znajdzie kształty; a następnie wykryje obiekty. Jest to analogiczne do tego, jak działa komputerowa CNN. Weźmy przykład: załóżmy, że chcesz zbudować model, który może identyfikować literę. CNN będzie mieć dane wejściowe w postaci obrazu, który ma 3072 piksele. Każdy z pikseli będzie miał wartość od 0 do 255, co wskazuje na ogólną intensywność. Korzystając z CNN, komputer przejdzie przez wiele odmian, aby zidentyfikować cechy. Pierwsza to warstwa splotowa, czyli filtr skanujący obraz. W naszym przykładzie może to być 5 × 5 pikseli. Proces utworzy mapę funkcji, która jest długą tablicą liczb. Następnie model zastosuje więcej filtrów do obrazu. W ten sposób CNN zidentyfikuje linie, krawędzie i kształty – wszystkie wyrażone w liczbach. W przypadku różnych warstw wyjściowych model użyje puli, która łączy je w celu wygenerowania jednego wyniku, a następnie stworzenia w pełni połączonej sieci neuronowej. CNN z pewnością może się skomplikować. Powinien jednak być w stanie dokładnie zidentyfikować liczby wprowadzane do systemu.

**Generatywne sieci kontradyktoryjne (GAN)**

Ian Goodfellow, który uzyskał tytuł magistra informatyki na Stanford i doktorat z uczenia maszynowego na Université de Montréal, zaczął pracować w Google. W wieku 20 lat był współautorem jednej z najlepszych książek o sztucznej inteligencji, zatytułowanej Deep Learning, a także wprowadzał innowacje dzięki Google Maps. Ale to właśnie w 2014 roku miał swój największy przełom. Tak naprawdę zdarzyło się to w pubie w Montrealu, kiedy rozmawiał z niektórymi ze swoich przyjaciół o tym, jak głębokie uczenie może tworzyć zdjęcia. W tamtym czasie podejściem było stosowanie modeli generatywnych, ale często były one rozmyte i bezsensowne.

Goodfellow zdał sobie sprawę, że musi być lepsze dlaczego. Dlaczego więc nie wykorzystać teorii gier? Oznacza to, że dwa modele rywalizują ze sobą w ścisłej pętli sprzężenia zwrotnego. Można to również zrobić z danymi nieoznakowanymi. Oto podstawowy przepływ pracy:

• Generator: ta sieć neuronowa tworzy mnóstwo nowych kreacji, takich jak zdjęcia lub zdania.

• Dyskryminator: ta sieć neuronowa analizuje kreacje, aby zobaczyć, które z nich są prawdziwe.

• Korekty: przy tych dwóch wynikach nowy model zmieniłby kreacje, aby były jak najbardziej realistyczne.

Dzięki wielu powtórzeniom dyskryminator nie będzie już musiał być używany. Był tak podekscytowany pomysłem, że po wyjściu z pubu zaczął kodować swoje pomysły. W rezultacie powstał nowy model głębokiego uczenia: generatywna sieć adwersarzy lub GAN. A wyniki były wyjątkowe. Wkrótce miał zostać gwiazdą rocka AI. Badania GAN zaowocowały już ponad 500 artykułami akademickimi. Firmy takie jak Facebook również wykorzystały tę technologię, na przykład do analizy i przetwarzania zdjęć. Główny naukowiec firmy zajmujący się sztuczną inteligencją, Yann LeCun, zauważył, że GAN to „najfajniejszy pomysł na głębokie uczenie w ciągu ostatnich 20 lat". Wykazano również, że GAN pomagają w zaawansowanych badaniach naukowych. Na przykład pomogli poprawić dokładność wykrywania zachowania cząstek subatomowych w Wielkim Zderzaczu Hadronów w CERN w Szwajcarii. Jeszcze we wczesnych fazach ta technologia może prowadzić do takich rzeczy, jak komputer, który może opracowywać nowe rodzaje modnych przedmiotów a może nowomodne urządzenie do noszenia. Być może GAN mógłby nawet wymyślić hitową piosenkę rapową. I może być wcześniej niż myślisz. Jako nastolatek Robbie Barrat nauczył się korzystać z systemów głębokiego uczenia i zbudował model do rapowania w stylu Kanye Westa. Ale to był dopiero początek jego magii AI. Jako badacz w Stanford opracował własną platformę GAN, która przetworzyła około 10 000 nagich portretów. System tworzyłby wtedy naprawdę fascynujące nowe dzieła sztuki (można je znaleźć na jego koncie na

Twitterze @DrBeef_). Aha, a także stworzył swój system jako open source na swoim koncie GitHub. Zwróciło to uwagę kolektywu francuskich artystów o nazwie Obvious, który wykorzystał tę technologię do stworzenia portretów osiemnastowiecznej fikcyjnej rodziny. Polegała na przetworzeniu 15 000 portretów z XIV-XX wieku. W 2018 roku Obvious wystawił swoje dzieło na aukcji Christie's, przynosząc 432 000 $. Ale niestety, jeśli chodzi o GAN, zdarzały się zastosowania, które były mniej niż godne podziwu. Jednym z przykładów jest użycie ich do deepfake, które polega na wykorzystaniu sieci neuronowych do tworzenia obrazów lub filmów, które wprowadzają w błąd. Niektóre z nich są po prostu zabawne. Na przykład jeden GAN pozwala Barackowi Obamie powiedzieć wszystko, co mu powiesz! Jednak istnieje wiele zagrożeń. Naukowcy z New York University i Michigan State University napisali artykuł, który skupił się na „DeepMasterPrints. Pokazał, jak GAN może opracować fałszywe odciski palców, aby odblokować trzy rodzaje smartfonów! Potem był incydent z tak zwanym deepfake wideo aktorki Jennifer Lawrence na konferencji prasowej Złotych Globów. Jej twarz połączyła się z twarzą Steve'a Buscemi

**Aplikacje do głębokiego uczenia**

Przy tak dużej ilości pieniędzy i zasobów przeznaczanych na głębokie uczenie nastąpił gwałtowny wzrost innowacji. Wydaje się, że każdego dnia ogłasza się coś niesamowitego. Więc jakie są niektóre aplikacje? Gdzie okazało się, że głębokie uczenie się zmienia zasady gry? Rzućmy okiem na niektóre, które obejmują obszary takie jak opieka zdrowotna, energia, a nawet trzęsienia ziemi

**Przypadek użycia: wykrywanie choroby Alzheimera**

Pomimo dziesięcioleci badań, lekarstwo na chorobę Alzheimera pozostaje nieuchwytne. Chociaż naukowcy opracowali leki, które spowolniły postęp choroby. W związku z tym wczesna diagnoza ma kluczowe znaczenie, a głębokie uczenie się może być potencjalnie dużą pomocą. Naukowcy z Zakładu Radiologii i Biomedycyny UCSF

Obrazowanie wykorzystało tę technologię do analizy ekranów mózgu - z publicznego zbioru danych inicjatywy Alzheimer’s Disease Neuroimaging Initiative - i do wykrywania zmian w poziomie glukozy. Wynik: model może diagnozować chorobę Alzheimera do sześciu lat przed diagnozą kliniczną. Jeden z testów wykazał 92% dokładność, a drugi 98%. Teraz jest to wciąż w początkowej fazie — i będzie trzeba przeanalizować więcej zbiorów danych. Ale jak dotąd wyniki są bardzo zachęcające. Według dr Jae Ho Sohn, autorki badania: Jest to idealne zastosowanie uczenia głębokiego, ponieważ jest ono szczególnie silne w wykrywaniu bardzo subtelnych, ale rozproszonych procesów. Radiolodzy są naprawdę silni w identyfikowaniu niewielkich ogniskowych, takich jak guz mózgu, ale walczymy z wykrywaniem wolniejszych, globalnych zmian. Biorąc pod uwagę siłę głębokiego uczenia się w tego typu aplikacjach, zwłaszcza w porównaniu z ludźmi, wydawało się to naturalnym zastosowaniem.

**Zastosowanie: energia**

Ze względu na ogromną infrastrukturę centrum danych Google jest jednym z największych konsumentów energii. Nawet niewielka poprawa wydajności może mieć znaczny wpływ na wynik finansowy. Ale mogą też być korzyści z mniejszej emisji dwutlenku węgla. Aby pomóc w realizacji tych celów, jednostka DeepMind firmy Google stosuje głębokie uczenie, które obejmuje lepsze zarządzanie energią wiatrową. Mimo że jest to czyste źródło energii, może być trudne w użyciu ze względu na zmiany pogody. Ale algorytmy głębokiego uczenia DeepMind były krytyczne. Przy zastosowaniu 700 megawatów energii wiatrowej w Stanach Zjednoczonych byli w stanie sporządzić dokładne prognozy dotyczące produkcji z czasem realizacji wynoszącym 36 godzin. Według bloga DeepMind: Jest to ważne, ponieważ źródła energii, które można zaplanować (tj. mogą dostarczyć określoną ilość energii elektrycznej w ustalonym czasie) są często bardziej wartościowe dla sieci… Do tej pory uczenie

maszynowe zwiększyło wartość naszego wiatru energii o około 20 procent w porównaniu ze scenariuszem bazowym, w którym brak zobowiązań czasowych do sieci. Ale oczywiście ten system głębokiego uczenia może być czymś więcej niż tylko Google – może mieć szeroki wpływ na zużycie energii na całym świecie.

**Zastosowanie: trzęsienia ziemi**

Trzęsienia ziemi są niezwykle trudne do zrozumienia. Są też niezwykle trudne do przewidzenia. Musisz ocenić uskoki, formacje skalne i deformacje, aktywność elektromagnetyczną i zmiany w wodzie gruntowej. Hej, są nawet dowody na to, że zwierzęta potrafią wyczuć trzęsienie ziemi! Ale przez dziesięciolecia naukowcy zebrali ogromne ilości danych na ten temat. Innymi słowy, może to być aplikacja do głębokiego uczenia się, prawda? Absolutnie. Sejsmolodzy z Caltech, do których należą Yisong Yue, Egill Hauksson, Zachary Ross i Men-Andrin Meier, prowadzą znaczne badania na ten temat, używając splotowych i rekurencyjnych sieci neuronowych. Próbują zbudować skuteczny system wczesnego ostrzegania. Oto, co miał do powiedzenia Yue:

Sztuczna inteligencja może [analizować trzęsienia ziemi] szybciej i dokładniej niż ludzie, a nawet znajdować wzorce, które w przeciwnym razie umknęłyby ludzkiemu oku. Co więcej, wzorce, które mamy nadzieję wyodrębnić, są trudne do odpowiedniego uchwycenia przez systemy oparte na regułach, a zatem zaawansowane możliwości dopasowywania wzorców współczesnego głębokiego uczenia mogą zapewnić lepszą wydajność niż istniejące zautomatyzowane algorytmy monitorowania trzęsień ziemi.

Ale kluczem jest poprawa gromadzenia danych. Oznacza to więcej analiz małych trzęsień ziemi (w Kalifornii jest ich średnio 50 dziennie). Celem jest stworzenie katalogu trzęsień ziemi, który może doprowadzić do stworzenia wirtualnego sejsmologa, który może dokonać oceny trzęsienia ziemi szybciej niż człowiek. Może to pozwolić na skrócenie czasu realizacji w przypadku trzęsienia ziemi, co może pomóc uratować życie i mienie.

**Przypadek użycia: Radiologia**

Skany PET i MRI to niesamowita technologia. Ale są zdecydowanie wady. Pacjent musi pozostać w rurce ograniczającej przez 30 minut do godziny. Jest to niewygodne i oznacza narażenie na gadolin, który, jak wykazano, ma szkodliwe skutki uboczne. Greg Zaharchuk i Enhao Gong, którzy spotkali się w Stanford, myśleli, że może być lepszy sposób. Zaharchuk był doktorem medycyny i doktorem ze specjalizacją z radiologii. Był również promotorem doktoratu Gong, który był doktorem elektrotechniki w zakresie głębokiego uczenia się i rekonstrukcji obrazu medycznego. W 2017 roku założyli firmę Subtle Medical i zatrudnili jednych z najzdolniejszych naukowców zajmujących się obrazowaniem, radiologów i ekspertów AI. Wspólnie podjęli wyzwanie ulepszenia skanów PET i MRI. Firma Subtle Medical stworzyła system, który nie tylko skraca czas skanowania MRI i PET nawet dziesięciokrotnie, ale dokładność jest znacznie wyższa. To było zasilane przez wysokiej klasy procesory graficzne NVIDIA. Następnie w grudniu 2018 r. system otrzymał dopuszczenie FDA (Federal Drug Administration) 510(k) oraz dopuszczenie znaku CE na rynek europejski. Było to pierwsze w historii jądrowe urządzenie medyczne oparte na sztucznej inteligencji, które uzyskało oba te oznaczenia. Subtle Medical ma więcej planów, aby zrewolucjonizować biznes radiologiczny. Od 2019 roku opracowuje SubtleMRTM, który będzie jeszcze silniejszy niż obecne rozwiązanie firmy, oraz SubtleGADTM, który zmniejszy dawki gadolinu

**Sprzęt do głębokiego uczenia**

Jeśli chodzi o układy scalone do głębokiego uczenia się, głównym wyborem były procesory graficzne. Ale w miarę jak sztuczna inteligencja staje się coraz bardziej wyrafinowana - na przykład w przypadku sieci GAN - i zbiory danych są znacznie większe, z pewnością jest więcej miejsca na nowe podejścia. Firmy mają również niestandardowe potrzeby, takie jak funkcje i dane. W końcu aplikacja dla konsumenta jest zwykle zupełnie inna niż aplikacja skoncentrowana na przedsiębiorstwie.

W rezultacie niektóre z wielkich firm technologicznych opracowały własne chipsety:

• Google: Latem 2018 r. firma ogłosiła trzecią wersję swojego procesora Tensor Processing Unit (TPU; pierwszy układ został opracowany w 2016 r.). do chłodzenia cieczą w centrach danych. Google ogłosił również wersję swojego TPU dla urządzeń. Zasadniczo oznacza to, że przetwarzanie będzie miało mniejsze opóźnienia, ponieważ nie będzie potrzeby uzyskiwania dostępu do chmury.

• Amazon: w 2018 roku firma ogłosiła AWS Inferentia.26 Technologia, która powstała w wyniku przejęcia Annapurny w 2015 roku, koncentruje się na obsłudze złożonych operacji wnioskowania. Innymi słowy, dzieje się tak po wytrenowaniu modelu.

• Facebook i Intel: Firmy te połączyły siły, aby stworzyć chip AI.27 Jednak inicjatywa jest wciąż w początkowej fazie. Intel również zyskuje przyczepność dzięki chipowi AI o nazwie Nervana Neural Network Processor (NNP).

• Alibaba: Firma stworzyła własną firmę produkującą układy sztucznej inteligencji o nazwie Pingtouge.28 Ma również plany zbudowania procesora komputera kwantowego opartego na kubitach (reprezentują cząstki subatomowe, takie jak elektrony i fotony).

• Tesla: Elon Musk opracował swój własny chip AI. Ma 6 miliardów tranzystorów i może przetwarzać 36 bilionów operacji na sekundę

Istnieje wiele startupów, które również grają na rynku chipów AI. Wśród wiodących firm znajduje się Untether AI, która koncentruje się na tworzeniu chipów zwiększających prędkości przesyłania danych (jest to szczególnie trudna część AI). W jednym z prototypów firmy proces ten był o ponad 1000 szybszy niż w przypadku typowego układu AI30. Intel wraz z innymi inwestorami wziął udział w rundzie finansowania o wartości 13 milionów dolarów w 2019 r. Teraz, jeśli chodzi o układy AI, NVIDIA ma dominujący udział w rynku. Jednak ze względu na znaczenie tej technologii wydaje się nieuniknione, że na rynku pojawi się coraz więcej ofert.

**Kiedy używać głębokiego uczenia?**

Ze względu na moc głębokiego uczenia istnieje pokusa, aby najpierw użyć tej technologii podczas tworzenia projektu AI. Ale to może być duży błąd. Głębokie uczenie nadal ma wąskie przypadki użycia, takie jak w przypadku zestawów danych tekstowych, wideo, graficznych i szeregów czasowych. Istnieje również zapotrzebowanie na duże ilości danych i systemy komputerowe o dużej mocy. Aha, a głębokie uczenie się jest lepsze, gdy wyniki można określić ilościowo i zweryfikować. Aby zobaczyć dlaczego, rozważmy następujący przykład. Zespół naukowców kierowany przez Thomasa Hartunga (toksykologa z Johns Hopkins University) stworzył zbiór danych zawierający około 10 000 substancji chemicznych, które zostały oparte na 800 000 testów na zwierzętach. Dzięki wykorzystaniu głębokiego uczenia wyniki wykazały, że model był bardziej predykcyjny niż wiele testów na zwierzętach pod kątem toksyczności. Pamiętaj, że testy na zwierzętach mogą być nie tylko kosztowne i wymagać środków bezpieczeństwa, ale także dawać niespójne wyniki z powodu powtarzanych testów na tej samej substancji chemicznej. „Pierwszy scenariusz ilustruje moc predykcyjną głębokiego uczenia i jego zdolność do odkrywania korelacji z dużych zbiorów danych, których człowiek nigdy by nie znalazł" - powiedział Sheldon Fernandez, który jest dyrektorem generalnym DarwinAI. Więc gdzie jest scenariusz, w którym głębokie

uczenie się nie sprawdza? W rzeczywistości ilustracją tego są Mistrzostwa Świata FIFA 2018 w Rosji, które wygrała Francja. Wielu badaczy próbowało przewidzieć wyniki wszystkich 64 meczów, ale wyniki były dalekie od dokładności:

• Jedna grupa badaczy zastosowała model konsensusu bukmacherskiego, który wskazywał, że Brazylia wygra.

• Inna grupa badaczy wykorzystała algorytmy, takie jak losowy las i ranking Poissona, aby przewidzieć, że Hiszpania zwycięży.

Problem polega na tym, że trudno jest znaleźć odpowiednie zmienne, które mają moc predykcyjną. W rzeczywistości modele uczenia głębokiego w zasadzie nie są w stanie poradzić sobie ze złożonością funkcji niektórych wydarzeń, zwłaszcza tych, które mają elementy chaotyczne. Jednak nawet jeśli dysponujesz odpowiednią ilością danych i mocą obliczeniową, nadal musisz zatrudniać osoby z doświadczeniem w głębokim uczeniu, co nie jest łatwe. Należy pamiętać, że wybór odpowiedniego modelu i dopracowanie go to nie lada wyzwanie. Ile powinno być hiperparametrów? Jaka powinna być liczba ukrytych warstw? A jak oceniasz model? Wszystko to jest bardzo złożone. Nawet eksperci mogą się pomylić. Oto następująca wiadomość od Sheldona: Jeden z naszych klientów z branży motoryzacyjnej spotkał się z dziwnym zachowaniem, w którym autonomiczny samochód coraz częściej skręcał w lewo, gdy niebo miało określony odcień fioletu. Po miesiącach bolesnego debugowania ustalili, że szkolenie dotyczące pewnych scenariuszy zwrotnych zostało przeprowadzone na pustyni Nevada, gdy niebo miało szczególny odcień. Bez wiedzy ludzkich projektantów sieć neuronowa ustaliła korelację między jej zachowaniem obrotowym a niebiańskim odcieniem. Istnieje kilka narzędzi, które pomagają w procesie głębokiego uczenia się, takich jak SageMaker firmy Amazon.com, HyperTune firmy Google i SigOpt. Ale przed nami jeszcze długa droga. Jeśli uczenie głębokie nie pasuje, możesz rozważyć uczenie maszynowe, które często wymaga stosunkowo mniej danych. Co więcej, modele wydają się być znacznie prostsze, ale wyniki mogą być nadal bardziej efektywne.

**Wady Deep Learning**

Biorąc pod uwagę wszystkie innowacje i przełomy, rozsądne jest, że wiele osób uważa głębokie uczenie się za srebrną kulę. Oznacza to, że nie będziemy już musieli prowadzić samochodu. Może nawet oznaczać, że wyleczymy raka. Jak nie być podekscytowanym i optymistycznym? To naturalne i rozsądne. Należy jednak zauważyć, że głębokie uczenie jest wciąż w początkowej fazie i faktycznie istnieje wiele dokuczliwych problemów. Dobrym pomysłem jest złagodzenie oczekiwań. W 2018 roku Gary Marcus napisał artykuł zatytułowany „Głębokie uczenie: krytyczna ocena", w którym jasno przedstawił wyzwania. W swoim artykule zauważa:

Na tle znacznego postępu w takich obszarach, jak rozpoznawanie mowy, rozpoznawanie obrazów i granie w gry oraz znacznego entuzjazmu w prasie popularnej, przedstawiam dziesięć obaw dotyczących uczenia głębokiego i sugeruję, że uczenie głębokie musi być uzupełnione innymi technikami, jeśli aby osiągnąć sztuczną ogólną inteligencję. Marcus z pewnością ma odpowiedni rodowód, aby przedstawić swoje obawy, ponieważ ma zarówno akademickie, jak i biznesowe doświadczenie w sztucznej inteligencji. Zanim został profesorem na Wydziale Psychologii Uniwersytetu Nowojorskiego, sprzedał swój startup o nazwie Geometric Intelligence firmie Uber. Marcus jest także autorem kilku bestsellerowe książki, takie jak The Haphazard Construction of the Human Mind. Oto kilka z jego obaw związanych z głębokim uczeniem:

• Czarna skrzynka: Model głębokiego uczenia może z łatwością zawierać miliony parametrów, które obejmują wiele ukrytych warstw. Jasne zrozumienie tego jest naprawdę poza możliwościami danej osoby. To prawda, że niekoniecznie musi to być problem z rozpoznawaniem kotów w zbiorze danych.

Ale z pewnością może to być problem z modelami do diagnostyki medycznej lub określania bezpieczeństwa platformy wiertniczej. W takich sytuacjach regulatorzy będą chcieli dobrze zrozumieć przejrzystość modeli. Z tego powodu naukowcy szukają systemów do określania „wyjaśnialności", co zapewnia zrozumienie modeli głębokiego uczenia się.

• Dane: ludzki mózg ma swoje wady. Ale są pewne funkcje, które bardzo dobrze przypominają zdolność uczenia się przez abstrakcję. Załóżmy na przykład, że Jan, która ma pięć lat, idzie z rodziną do restauracji. Jej matka wskazuje przedmiot na talerzu i mówi, że to „taco". Nie musi tego wyjaśniać ani podawać żadnych informacji na ten temat. Zamiast tego mózg Jana natychmiast przetworzy te informacje i zrozumie ogólny wzór. W przyszłości, gdy zobaczy kolejne taco – nawet jeśli ma różnice, na przykład z ubiorem – będzie wiedziała, co to jest. W większości jest to intuicyjne. Ale niestety, jeśli chodzi o głębokie uczenie się, nie ma nauki taco przez abstrakcję! System musi przetworzyć ogromne ilości informacji, aby je rozpoznać. Oczywiście nie stanowi to problemu dla firm takich jak Facebook, Google, czy nawet Uber. Jednak wiele firm ma znacznie bardziej ograniczone zbiory danych. W rezultacie głębokie uczenie się może nie być dobrą opcją.

• Struktura hierarchiczna: Ten sposób organizowania nie istnieje w głębokim uczeniu się. Z tego powodu zrozumienie języka ma jeszcze długą drogę do przebycia (zwłaszcza w przypadku długich dyskusji).

• Wnioskowanie otwarte: Marcus zauważa, że uczenie głębokie nie może zrozumieć niuansów między „Jan obiecał, że Mary odejdzie" a „Jan obiecał, że opuści Mary". Co więcej, głębokie uczenie jest dalekie od możliwości, na przykład, przeczytania Dumy i uprzedzenia Jane Austen i umiejętności odgadnięcia motywacji postaci Elizabeth Bennet.

• Myślenie koncepcyjne: Głębokie uczenie się nie pozwala na zrozumienie pojęć takich jak demokracja, sprawiedliwość czy szczęście. Nie ma też wyobraźni, wymyślania nowych pomysłów czy planów.

• Zdrowy rozsądek: To jest coś, czego głębokie uczenie się nie sprawdza. Jeśli już, oznacza to, że model można łatwo pomylić. Na przykład, powiedzmy, że pytasz system AI: „Czy można zrobić komputer z gąbką?" W większości prawdopodobnie nie będzie wiedział, że to śmieszne pytanie.

• Przyczyna: głębokie uczenie nie jest w stanie tego określić. Wszystko sprowadza się do znajdowania korelacji.

• Wcześniejsza wiedza: CNN mogą pomóc w uzyskaniu pewnych wcześniejszych informacji, ale jest to ograniczone. Głębokie uczenie jest nadal dość samowystarczalne, ponieważ rozwiązuje tylko jeden problem na raz. Nie może pobierać danych i tworzyć algorytmów obejmujących różne domeny. Ponadto model się nie dostosowuje. W przypadku zmiany danych należy przeszkolić i przetestować nowy model. I wreszcie, uczenie głębokie nie ma wcześniejszego zrozumienia tego, co ludzie wiedzą instynktownie — na przykład podstaw fizyki rzeczywistego świata. To jest coś, co musi być wyraźnie zaprogramowane w systemie AI.

• Statyczny: głębokie uczenie działa najlepiej w dość prostych środowiskach. Właśnie dlatego sztuczna inteligencja jest tak skuteczna w grach planszowych, które mają jasny zestaw zasad i granic. Ale prawdziwy świat jest chaotyczny i nieprzewidywalny. Oznacza to, że głębokie uczenie się może spaść

krótki ze złożonymi problemami, nawet z samojezdnymi samochodami.

• Zasoby: Model uczenia głębokiego często wymaga ogromnej mocy procesora, tak jak w przypadku procesorów graficznych. To może być kosztowne. Chociaż jedną z opcji jest skorzystanie z usługi w chmurze innej firmy.

To dość dużo? To prawda. Ale papier nadal pomija pewne wady. Oto kilka innych:

• Efekt motyla: Ze względu na złożoność danych, sieci i połączeń, drobna zmiana może mieć duży wpływ na wyniki modelu głębokiego uczenia się. Może to łatwo prowadzić do wniosków, które są błędne lub mylące.

• Overfitting.

Jeśli chodzi o Marcusa, jego największą obawą jest to, że sztuczna inteligencja może „zostać uwięziona w lokalnym minimum, zagnieżdżając się zbyt mocno w niewłaściwej części przestrzeni intelektualnej, zbytnio skupiając się na szczegółowej eksploracji określonej klasy dostępnych, ale ograniczonych modeli, które są nastawione na przechwytywanie nisko wiszących owoców – potencjalnie zaniedbując bardziej ryzykowne wycieczki, które mogą ostatecznie prowadzić do bardziej solidnej ścieżki". Nie jest jednak pesymistą. Uważa, że naukowcy muszą wyjść poza głębokie uczenie i znaleźć nowe techniki, które mogą rozwiązać trudne problemy.

**Wniosek**

Chociaż Marcus wskazał na wady głębokiego uczenia się, faktem jest, że to podejście AI jest nadal niezwykle skuteczne. W niecałą dekadę zrewolucjonizował świat technologii, a także znacząco wpływa na takie obszary, jak finanse, robotyka i opieka zdrowotna. Wraz ze wzrostem inwestycji ze strony dużych firm technologicznych i VC, modele będą wprowadzać dalsze innowacje. Zachęci to również inżynierów do uzyskania stopni podyplomowych, tworząc pozytywny cykl przełomy.

**Kluczowe dania na wynos**

• Głębokie uczenie, które jest poddziedziną uczenia maszynowego, przetwarza ogromne ilości danych w celu wykrycia relacji i wzorców, których ludzie często nie są w stanie wykryć. Słowo „głębokie" opisuje liczbę ukrytych warstw.

• Sztuczna sieć neuronowa (ANN) to funkcja obejmująca jednostki posiadające wagi i służąca do przewidywania wartości w modelu AI.

• Ukryta warstwa jest częścią modelu, która przetwarza przychodzące dane.

• Sieć neuronowa typu feed-forward zawiera dane, które przechodzą tylko od wejścia do warstwy ukrytej do wyjścia. Wyniki nie wracają. Mogą jednak wejść do innej sieci neuronowej.

• Funkcja aktywacji jest nieliniowa. Innymi słowy, lepiej odzwierciedla rzeczywisty świat.

• Sigmoid to funkcja aktywacji, która kompresuje wartość wejściową do zakresu 0–1, co ułatwia analizę.

• Propagacja wsteczna to zaawansowana technika dostosowywania wag w sieci neuronowej. Takie podejście miało kluczowe znaczenie dla rozwoju głębokiego uczenia się.

• Rekurencyjna sieć neuronowa (RNN) to funkcja, która nie tylko przetwarza dane wejściowe, ale także wcześniejsze dane wejściowe w czasie.

• Splotowa sieć neuronowa (CNN) analizuje dane sekcja po sekcji (czyli według splotów). Model ten jest przeznaczony do złożonych aplikacji, takich jak rozpoznawanie obrazu.

• Generacyjna sieć kontradyktoryjna lub GAN to miejsce, w którym dwie sieci neuronowe konkurują ze sobą w ścisłej pętli sprzężenia zwrotnego. Rezultatem jest często stworzenie nowego obiektu.

- Wyjaśnialność opisuje techniki przejrzystości ze złożonymi modelami uczenia głębokiego.

**Robotic Process Automation (RPA)**

**Łatwiejsza droga do AI**

Wchodząc w interakcję z aplikacjami tak, jak robiłby to człowiek, roboty programowe mogą otwierać załączniki do wiadomości e-mail, wypełniać formularze elektroniczne, rejestrować i ponownie wprowadzać dane oraz wykonywać inne zadania, które naśladują ludzkie działania. -Kaushik Iyengar, dyrektor ds. cyfrowej transformacji i optymalizacji w AT&T

W 2005 roku Daniel Dines i Marius Tirca założyli UiPath z siedzibą w Bukareszcie w Rumunii. Firma skupiła się głównie na świadczeniu usług integracyjnych dla aplikacji firm Google, Microsoft i IBM. Ale była to walka, ponieważ firma polegała głównie na pracy niestandardowej dla klientów. Do 2013 r. UiPath był bliski zamknięcia. Jednak założyciele nie poddali się, ponieważ widzieli w tym okazję do przemyślenia firmy i znalezienia nowej okazji. W tym celu rozpoczęli budowę platformy dla Robotic Process Automation (RPA). Kategoria, która istnieje od 2000 roku, dotyczyła automatyzacji rutynowych i przyziemnych zadań w firmie. Jednak RPA była w rzeczywistości obszarem zaścianka w świecie technologii - jak widać przy powolnym tempie wzrostu. Dines i Tirca byli jednak przekonani, że mogą zmienić branżę. Jeden z głównych powodów: rozwój AI i chmury. Nowa strategia była strzałem w dziesiątkę, a wzrost wystartował. Dines i Tirca też agresywnie poszukiwali finansowania, wprowadzali innowacje w swojej platformie RPA i wchodzili na rynki globalne. Do 2018 r. UiPath został uznany za najszybciej rozwijającą się firmę tworzącą oprogramowanie dla przedsiębiorstw - w historii. Roczny dochód cykliczny wzrósł z 1 miliona do 100 milionów dolarów przy ponad 1800 klientach. Firma posiadała najpopularniejszy system RPA na świecie. UiPath pozyskał łącznie 448 milionów dolarów kapitału wysokiego ryzyka od takich firm jak CapitalG, Sequoia Capital i Accel. Wycena wyniosła 3 miliardy dolarów. W związku z tym więcej startupów RPA zdobyło również znaczne fundusze. Z drugiej strony przewiduje się, że rynek odnotuje ogromny wzrost. Grand View Research przewiduje, że do 2025 r. wydatki w Stanach Zjednoczonych osiągną 3,97 miliarda dolarów. Co ciekawe, firma Forrester miała do powiedzenia na temat trendu RPA:

Dzisiejsze firmy odnoszące największe sukcesy na ogół zatrudniają mniej pracowników niż te w przeszłości. Weź pod uwagę, że Kodak w szczytowym momencie w 1973 r. zatrudniał 120 000 osób, ale kiedy Facebook kupił Instagram w 2012 r., witryna do udostępniania zdjęć zatrudniała tylko 13 pracowników. W 2019 roku przewidujemy, że co dziesiąty startup – działający w bardziej zwinny, szczupły i skalowalny sposób – spojrzy na świat przez pryzmat zadań, a nie miejsc pracy, i zbuduje modele biznesowe wokół zasad automatyzacji.

RPA to kolejny obszar, który został doładowany sztuczną inteligencją. Jeśli już, może być bramą dla wielu firm, ponieważ wdrożenie zwykle nie trwa długo lub wymaga dużych kosztów. W tym rozdziale przyjrzymy się RPA i zobaczymy, jak może być kluczowym czynnikiem dla wielu firm.

**Co to jest ZAP?**

Termin Robotic Process Automation może być nieco mylący. Słowo „robot” nie oznacza robotów fizycznych (omówimy je w rozdziale 7); chodzi raczej o roboty lub boty oparte na oprogramowaniu. RPA pozwala na użycie niskokodowych wizualnych systemów przeciągania i upuszczania w celu zautomatyzowania przepływu pracy procesu. Oto kilka przykładów:

• Wprowadzanie, zmienianie i śledzenie dokumentów, umów i informacji o pracownikach dotyczących zasobów ludzkich (HR)

• Wykrywanie problemów z obsługą klienta i podejmowanie działań w celu rozwiązania problemów

• Przetwarzanie roszczenia ubezpieczeniowego

• Wysyłanie faktur

• Wydawanie zwrotów klientom

• Uzgadnianie dokumentacji finansowej

• Przenoszenie danych z jednego systemu do drugiego

• Udzielanie klientom standardowych odpowiedzi

Wszystko to odbywa się dzięki temu, że bot replikuje przepływy pracy dla aplikacji, na przykład dla systemu ERP (Enterprise Resource Planning) lub CRM (Customer Relationship Management). Można to zrobić nawet za pomocą programu RPA rejestrującego kroki pracowników lub za pomocą technologii OCR (optyczne rozpoznawanie znaków) do tłumaczenia odręcznych notatek. Pomyśl o RPA jak o cyfrowym pracowniku. Istnieją dwa rodzaje tego typu technologii:

• Nienadzorowane RPA: Jest to proces całkowicie autonomiczny, ponieważ bot będzie działał w tle. Nie oznacza to, że nie ma ludzkiej interwencji. Nadal będzie interwencja w zakresie zarządzania wyjątkami. Dzieje się tak, gdy bot napotyka coś, czego nie rozumie.

• RDA (Robotic Desktop Automation): W tym miejscu RPA pomaga pracownikowi w pracy lub zadaniu. Typowym przypadkiem użycia jest contact center. Oznacza to, że gdy nadejdzie połączenie, przedstawiciel może użyć RDA, aby znaleźć odpowiedzi, wysłać wiadomości, pobrać informacje o profilu klienta i uzyskać wgląd w to, co dalej. Technologia pomaga poprawić lub zwiększyć wydajność pracownika.

**Plusy i minusy RPA**

Oczywiście sporo czasu dla typowego pracownika – na zapleczu – spędza się na rutynowych zadaniach. Jednak dzięki ZAP firmy często mogą uzyskać wysoki ROI (zwrot z inwestycji) – o ile wdrożenie jest wykonane prawidłowo. Oto kilka innych zalet:

• Zadowolenie klienta: RPA oznacza minimalną liczbę błędów oraz dużą szybkość. Bot działa również 24/7. Oznacza to, że wyniki zadowolenia klientów, takie jak NPS (Net Promoter Score), powinny się poprawić. Zauważ, że coraz więcej klientów, takich jak pokolenie Millenialsów, woli zajmować się aplikacjami/stronami internetowymi, a nie ludźmi! ZAP oznacza również, że przedstawiciele będą mieli więcej czasu na zadania o wartości dodanej, zamiast zajmować się żmudnymi sprawami, które marnują czas.

• Skalowalność: Po utworzeniu bota można go szybko rozbudować, aby sprostać gwałtownym wzrostom aktywności. Może to mieć kluczowe znaczenie dla firm sezonowych, takich jak detaliści.

• Zgodność: ludziom trudno jest śledzić zasady, przepisy i prawa. Co gorsza, często się zmieniają. Jednak dzięki ZAP zgodność jest wbudowana w proces i jest zawsze przestrzegana. Może to być dużą korzyścią, jeśli chodzi o uniknięcie problemów prawnych i grzywien.

• Insights and Analytics: platformy RPA nowej generacji są wyposażone w zaawansowane pulpity nawigacyjne, które koncentrują się na kluczowych wskaźnikach efektywności dla Twojej firmy. Możesz także skonfigurować alerty, jeśli wystąpią jakiekolwiek problemy.

• Starsze systemy: Starsze firmy często ugrzęzły w starych systemach informatycznych, co sprawia, że przeprowadzenie cyfrowej transformacji jest niezwykle trudne. Jednak oprogramowanie RPA może dość dobrze współpracować ze starszymi środowiskami IT.

• Dane: Ze względu na automatyzację dane są znacznie czystsze, ponieważ występuje minimalna liczba błędów wejściowych. Oznacza to, że z czasem organizacje będą lepiej rozumieć swoje firmy. Jakość danych zwiększy również prawdopodobieństwo powodzenia wdrożeń AI

Chociaż wszystko to jest świetne, RPA wciąż ma swoje wady. Na przykład, jeśli masz bieżące procesy, które są nieefektywne i spieszysz się z wdrożeniem systemu RPA, zasadniczo powielasz złe podejście! Dlatego tak ważna jest ocena przepływów pracy przed wdrożeniem systemu. Ale z pewnością są inne potencjalne miny lądowe, na które warto zwrócić uwagę, takie jak:

• Kruchość: RPA może łatwo pęknąć, jeśli nastąpią zmiany w podstawowych aplikacjach. Może tak być również w przypadku zmian w procedurach i przepisach. Prawdą jest, że nowsze systemy lepiej się dostosowują i mogą również wykorzystywać interfejsy API. Ale RPA nie polega na czynnościach bez użycia rąk.

• Zwirtualizowane aplikacje: Tego typu oprogramowanie, takie jak Citrix, może być trudne w przypadku systemów RPA, ponieważ nie mogą one skutecznie przechwytywać procesów. Powodem jest to, że dane są przechowywane na zewnętrznym serwerze, a dane wyjściowe to migawka na monitorze. Ale niektóre firmy wykorzystują sztuczną inteligencję do rozwiązania problemu, na przykład UiPath. ten

Firma stworzyła system o nazwie „Pragmatic AI", który wykorzystuje wizję komputerową do interpretacji zrzutów ekranu w celu rejestrowania procesów.

• Specjalizacja: Wiele narzędzi RPA jest przeznaczonych do działań ogólnego przeznaczenia. Ale mogą istnieć obszary wymagające specjalizacji, takie jak finanse. W takim przypadku możesz spojrzeć na niszową aplikację, która sobie z tym poradzi.

• Testowanie: jest to absolutnie krytyczne. Najpierw chcesz wypróbować niektóre transakcje, aby upewnić się, że system działa poprawnie. Następnie możesz przeprowadzić bardziej rozbudowane wdrożenie systemu RPA.

• Własność: Pokusa polega na tym, aby IT było właścicielem wdrożenia i zarządzania RPA. Ale to chyba nie jest wskazane. Powód? Systemy RPA są dość mało zaawansowane technologicznie. W końcu mogą je tworzyć osoby nie będące programistami. Z tego powodu menedżerowie biznesowi są idealnymi właścicielami procesu, ponieważ mogą ogólnie poradzić sobie z kwestiami technicznymi, a także lepiej rozumieć przepływy pracy pracowników.

• Opór: Zmiana jest zawsze trudna. W przypadku ZAP mogą pojawić się obawy, że technologia zastąpi miejsca pracy. Oznacza to, że musisz mieć jasny zestaw komunikatów, które skupiają się na korzyściach płynących z technologii. Na przykład ZAP oznacza więcej czasu na skupienie się na ważnych sprawach, co powinno sprawić, że praca danej osoby będzie bardziej interesująca i znacząca.

**Czego można oczekiwać od RPA?**

Jeśli chodzi o RPA, branża jest wciąż we wczesnej fazie. Są jednak wyraźne oznaki, że ta technologia ma duże znaczenie dla wielu firm. Spójrz na raport badawczy firmy Computer Economics Technology, który obejmował około 250 firm (działały one w wielu branżach i miały przychody od 20 do ponad 1 miliarda dolarów). Spośród tych, które wdrożyły system RPA, około połowa zgłosiła pozytywny zwrot w ciągu 18 miesięcy od wdrożenia. Jest to zdecydowanie wyróżniające się oprogramowanie dla przedsiębiorstw, które może być trudne w uzyskaniu adopcji. Aby zrozumieć strategiczne znaczenie tej technologii, spójrz, co robi Departament Obrony USA, który jest zaangażowany w ponad 500 projektów AI. Oto, co dyrektor Joint Artificial Intelligence Center agencji, generał porucznik sił powietrznych Jack Shanahan, miał do powiedzenia podczas przesłuchania w Kongresie:

Kiedy mówisz o inteligentnej automatyzacji lub potocznie w branży, Robotic Process Automation, nie jest to nagłówek w kontekście dużych projektów AI, ale może to być miejsce, w którym można znaleźć największą wydajność. Tak jest w przypadku, gdy czytasz niektóre dzienniki w przemyśle, czy to w medycynie, czy w finansach, to jest to, gdzie wczesne zyski są realizowane w AI. Niektóre z innych projektów, które podejmujemy w dziale, są prawdopodobnie przygotowywane przez lata w zamian za inwestycję.

Mimo to wciąż istnieje wiele nieudanych wdrożeń RPA. Na przykład Ernst & Young otrzymał z tego powodu dużą ilość usług konsultingowych. Na podstawie tego doświadczenia wskaźnik niepowodzeń dla początkowych projektów RPA waha się od 30% do 50%. Ale jest to nieuniknione w przypadku każdego rodzaju oprogramowania dla przedsiębiorstw. Jeszcze tak daleko, problemy wydają się dotyczyć głównie planowania, strategii i oczekiwań, a nie technologii. Innym problemem jest to, że szum wokół RPA może podnosić oczekiwania do nadmiernych poziomów. Oznacza to, że rozczarowanie będzie dość powszechne, nawet jeśli wdrożenia zakończą się sukcesem! Oczywiście technologie nie są lekarstwem na wszystko. A do pracy wymagają dużo czasu, wysiłku i staranności.

**Jak wdrożyć RPA**

W takim razie jakie kroki należy podjąć, aby pomyślnie wdrożyć RPA? Nie ma standardowej odpowiedzi, ale z pewnością pojawiają się pewne najlepsze praktyki:

• Określ odpowiednie funkcje do zautomatyzowania.

• Oceń procesy.

• Wybierz dostawcę RPA i wdróż oprogramowanie.

• Powołanie zespołu do zarządzania platformą RPA.

Przyjrzyjmy się bliżej każdemu z nich.

Określ odpowiednie funkcje do automatyzacji

Tak, nadmierna automatyzacja w Tesli była błędem. Aby być precyzyjnym, moim błędem. Ludzie są niedoceniani.

-Elon Musk, dyrektor generalny Tesla

Mimo że RPA jest potężnym narzędziem i może w dużym stopniu poruszyć igłę dla firmy, możliwości są nadal dość ograniczone. Technologia ta ma największy sens w automatyzacji powtarzalnych, ustrukturyzowanych i rutynowych procesów. Obejmuje to takie rzeczy jak planowanie, wprowadzanie/przesyłanie danych, przestrzeganie reguł/przepływów pracy, wycinanie i wklejanie, wypełnianie formularzy i wyszukiwanie. Oznacza to, że RPA może faktycznie odgrywać rolę w prawie każdym dziale w organizacji. W takim razie gdzie ta technologia generalnie nie zapewnia? Cóż, jeśli proces wymaga niezależnego osądu, to RPA prawdopodobnie nie ma sensu. To samo dotyczy sytuacji, gdy procesy podlegają częstym zmianom. W takiej sytuacji możesz poświęcić dużo czasu na bieżące dostosowywanie konfiguracji. Po ustaleniu części firmy, w której technologia wydaje się dobrze pasować, należy wziąć pod uwagę mnóstwo innych kwestii. Innymi słowy, prawdopodobnie odniesiesz większy sukces z projektem, jeśli skupisz się na następujących kwestiach:

• Obszary działalności, które mają poważne poziomy słabszych wyników

• Procesy, które zajmują wysoki procent czasu pracownika i wiążą się z wysokim poziomem błędów

• Zadania, które wymagają więcej zatrudnienia, gdy są wyższe wolumeny

• Obszary, o których myślisz o outsourcingu

• Proces, który składa się z dużej liczby etapów i w który zaangażowane są różne zastosowania

**Oceń procesy**

Firma często ma wiele niepisanych procesów. I to jest w porządku. Takie podejście pozwala na adaptację, w której ludzie są dobrzy. Jednak jest to dalekie od przypadku z botem. Aby mieć udane wdrożenie, musisz mieć dogłębną ocenę procesów. Może to chwilę potrwać i warto poprosić zewnętrznych konsultantów o pomoc. Mają tę zaletę, że są bardziej neutralni i lepiej potrafią identyfikować słabości. Niektórzy dostawcy RPA mają własne narzędzia pomagające w analizie procesów, z których zdecydowanie powinieneś korzystać. Istnieją również zewnętrzni dostawcy oprogramowania, którzy mają własne oferty. Jednym z nich jest Celonis, który integruje się z platformami RPA, takimi jak UiPath, Automation Anywhere, Blue Prism i innymi. Oprogramowanie wykonuje zasadniczo cyfrowy rezonans magnetyczny, który analizuje dane, zapewniając wgląd w to, jak naprawdę działają Twoje procesy. Zidentyfikuje również słabości i możliwości, takie jak zwiększenie przychodów, poprawa zadowolenia klientów i uwolnienie zasobów. Bez względu na to, jakie podejście przyjmiesz, bardzo ważne jest sformułowanie jasnego planu, uwzględniającego wkład działu IT, wyższego kierownictwa i działów, na które ma to wpływ. Upewnij się również, że zaangażowane są osoby zajmujące się analityką, ponieważ mogą istnieć możliwości wykorzystania danych.

**Wybierz dostawcę RPA i wdróż oprogramowanie**

Przechodząc przez pierwsze dwa kroki, będziesz w bardzo dobrej pozycji do oceny różnych systemów RPA. Na przykład, jeśli Twoim głównym celem jest zmniejszenie liczby pracowników, powinieneś poszukać oprogramowania, które koncentruje się na nienadzorowanych botach. Lub, jeśli chcesz wykorzystać dane - na przykład w aplikacjach AI - doprowadzi to do innych rodzajów platform RPA. Następnie, po wybraniu jednego, rozpoczniesz wdrażanie. Dobrą wiadomością jest to, że może to być stosunkowo szybkie, powiedzmy mniej niż miesiąc. Ale w miarę kontynuowania kolejnych projektów RPA możesz napotkać coś, co nazywa się zmęczeniem automatyzacji. W tym momencie zwroty na ogół zaczynają się pogarszać. Pomyśl o tym w ten sposób: kiedy zaczynasz, zwykle koncentrujesz się na tych obszarach działalności, które najbardziej wymagają automatyzacji, co oznacza, że zwrot z inwestycji będzie znaczący. Jednak z biegiem czasu skupimy się na zadaniach, które nie są tak podatne na automatyzację, a wprowadzenie nawet niewielkich ulepszeń będzie prawdopodobnie wymagało znacznie więcej pracy. Z tego powodu dobrym pomysłem jest złagodzenie oczekiwań podczas angażowania się w szeroko zakrojoną transformację RPA.

**Ustaw zespół do zarządzania platformą RPA**

To, że RPA zapewnia wysoki stopień automatyzacji, nie oznacza, że wymaga niewielkiego zarządzania. Najlepszym podejściem jest raczej stworzenie zespołu, który jest często określany jako centrum doskonałości (CoE). Aby jak najlepiej wykorzystać CoE, musisz jasno określić obowiązki każdej osoby. Na przykład powinieneś być w stanie odpowiedzieć na następujące pytania:

• Co się stanie, jeśli wystąpi problem z botem? W jakich punktach powinna nastąpić interwencja człowieka?

• Kto odpowiada za monitorowanie RPA?

• Kto odpowiada za szkolenie?

• Kto będzie pełnił rolę pierwszej linii wsparcia?

• Kto jest odpowiedzialny za rozwój botów?

W przypadku większych organizacji możesz również rozszerzyć role. Mógłbyś mieć mistrza RPA, który byłby ewangelistą platformy – dla całej firmy. Lub może być menedżer ds. zmian RPA, który zapewnia komunikację, aby pomóc w adopcji. Wreszcie, gdy wdrożenie RPA staje się coraz większe, kluczowym celem powinno być przyjrzenie się, jak wszystkie części do siebie pasują. Podobnie jak w przypadku wielu innych systemów oprogramowania, istnieje ryzyko rozrostu w całej organizacji, co może oznaczać brak wyższej wydajności. W tym miejscu posiadanie proaktywnego CoE może mieć duży pozytywny wpływ.

**RPA i AI**

Będąc jeszcze w początkowej fazie, sztuczna inteligencja już robi postępy dzięki narzędziom RPA. Prowadzi to do pojawienia się botów oprogramowania Cognitive Robotic Process Automation (CRPA). I to ma sens. W końcu RPA polega na optymalizacji procesów i angażuje duże ilości danych. Dlatego sprzedawcy zaczynają wdrażać systemy, takie jak uczenie maszynowe, głębokie uczenie, rozpoznawanie mowy i rozpoznawanie języka naturalnego. Niektórzy z liderów w przestrzeni CRPA to UiPath, Automation Anywhere, Blue Prism, NICE Systems i Kryon Systems. Na przykład dzięki Automation Anywhere bot może wykonywać takie zadania, jak pobieranie faktur z wiadomości e-mail, co wymaga zaawansowanego przetwarzania tekstu. Firma ma również gotowe integracje z zewnętrznymi usługami AI, takimi jak IBM Watson, AWS Machine Learning i Google Cloud AI. „W ostatnich latach nastąpił wzrost liczby usług wykorzystujących sztuczną inteligencję, ale firmy często mają trudności z ich operacjonalizacją" — powiedział Mukund Srigopal, dyrektor ds. marketingu produktów w Automation Anywhere. „RPA to świetny sposób na wprowadzenie możliwości sztucznej inteligencji do procesów biznesowych". Oto kilka innych sposobów, w jakie CRPA może zezwolić na funkcje AI:

• Możesz połączyć chatboty ze swoim systemem, co pozwoli na automatyczną obsługę klienta

• Sztuczna inteligencja może znaleźć odpowiedni moment na wysłanie e-maila lub alertu.

• IVR (Interactive Voice Response) zyskał złą reputację na przestrzeni lat. Mówiąc najprościej, klienci nie lubią kłopotów z przechodzeniem przez wiele kroków w celu rozwiązania problemu. Ale dzięki CRPA możesz użyć czegoś, co nazywa się Dynamic IVR. To personalizuje komunikaty głosowe dla każdego klienta, zapewniając znacznie lepsze wrażenia.

• NLP i analiza tekstu mogą konwertować dane nieustrukturyzowane na dane ustrukturyzowane. Może to zwiększyć skuteczność CRPA.

**RAP w świecie rzeczywistym**

Aby lepiej zrozumieć, jak działa RAP i zrozumieć korzyści, zapoznaj się ze studium przypadku firmy Microsoft. Co roku firma wypłaca miliardy dolarów tantiem twórcom gier, partnerom i twórcom treści. Jednak proces ten był w większości ręczny, polegający na wysyłaniu tysięcy oświadczeń – i tak, to była wielka strata czasu dla firmy. Dlatego firma wybrała Kyron do wdrożenia RPA. Przeprowadzając wstępny przegląd procesu, Microsoft zdał sobie sprawę, że od 70% do 80% oświadczeń jest prostych i można je łatwo zautomatyzować. Reszta obejmowała wyjątki wymagające interwencji człowieka, takie jak zgody. Dzięki systemowi RPA algorytm wykrywania wizualnego mógłby podzielić stwierdzenia i znaleźć wyjątki. Konfiguracja była również dość szybka i zajęła około 6 tygodni. Jak nie powinno dziwić, wyniki miały istotny wpływ na przebieg procesu. Na przykład bot mógł wypełnić 150 oświadczeń o tantiemach w zaledwie 2,5 godziny. Dla porównania, zajęłoby to pracownikom 50 godzin.

Podsumowując: Microsoft osiągnął 2000% oszczędności. Nastąpiła również eliminacja wszelkich przeróbek spowodowanych błędem ludzkim (który wcześniej wynosił około 5% w danym miesiącu).

**Wniosek**

Jak widać w studium przypadku firmy Microsoft, RAP może prowadzić do znacznych oszczędności. Ale nadal trzeba starannie planować, aby zrozumieć swoje procesy. W większości należy skupić się na zadaniach wykonywanych ręcznie i powtarzalnych, a nie na tych, które w dużym stopniu opierają się na ocenie. Następnie ważne jest skonfigurowanie CoE, aby nadzorować bieżące zarządzanie automatyzacją, co pomoże w obsłudze wyjątków, zbieraniu danych i śledzeniu kluczowych wskaźników wydajności. ZAP to także świetny sposób na wdrożenie podstawowej sztucznej inteligencji w organizacji. W rzeczywistości, ponieważ może to być znaczny zwrot z inwestycji, może to zachęcić do jeszcze większych inwestycji w rozwój tej technologii.

**Kluczowe dania na wynos**

• Robotic Process Automation (RPA) umożliwia korzystanie z niskokodowych wizualnych systemów przeciągania i upuszczania w celu zautomatyzowania przepływu pracy procesu.

• Nienadzorowane RPA ma miejsce wtedy, gdy proces jest całkowicie zautomatyzowany.

• RDA (Robotic Desktop Automation) to miejsce, w którym RPA pomaga pracownikowi w pracy lub zadaniu.

• Niektóre z korzyści płynących z RPA to wyższa satysfakcja klienta, niższy wskaźnik błędów, lepsza zgodność i łatwiejsza integracja ze starszymi systemami.

• Niektóre wady RPA obejmują trudności w dostosowaniu się do zmian w podstawowych aplikacjach, problemy z aplikacjami zwirtualizowanymi oraz opór pracowników.

• ZAP zwykle działa najlepiej tam, gdzie można zautomatyzować powtarzalne, ustrukturyzowane i rutynowe procesy, takie jak planowanie, wprowadzanie/przesyłanie danych oraz przestrzeganie reguł/przepływów pracy.

• Podczas wdrażania rozwiązania RPA, niektóre z kroków do rozważenia obejmują określenie funkcji do zautomatyzowania, ocenę procesów, wybór dostawcy RPA i wdrożenie oprogramowania oraz ustanowienie zespołu do zarządzania platformą.

• Centrum doskonałości (CoE) to zespół, który zarządza wdrożeniem RPA.

• Cognitive Robotic Process Automation (CRPA) to nowa kategoria RPA, która koncentruje się na technologiach AI.

**Przetwarzanie języka naturalnego (NLP)**

**Jak mówią komputery**

W 2014 roku Microsoft uruchomił chatbota - system AI, który komunikuje się z ludźmi o nazwie Xiaoice. Został zintegrowany z WeChat firmy Tencent, największym serwisem społecznościowym w Chinach. Xiaoice radził sobie całkiem nieźle, docierając do 40 milionów użytkowników w ciągu kilku lat. W świetle sukcesu Microsoft chciał sprawdzić, czy może zrobić coś podobnego na rynku amerykańskim. Firma Bing oraz Technology and Research Group wykorzystały technologie sztucznej inteligencji do zbudowania nowego chatbota: Tay. Twórcy skorzystali nawet z pomocy improwizowanych komików, aby konwersja była wciągająca i przyjemna. 23 marca 2016 r. Microsoft uruchomił Tay na Twitterze - i była to całkowita katastrofa. Chatbot szybko rozsyłał rasistowskie i seksistowskie wiadomości! Oto tylko jeden z tysięcy przykładów:

@TheBigBrebowski ricky gervais nauczył się totalitaryzmu od Adolfa Hitlera, wynalazcy ateizmu

Tay był jasną ilustracją Prawa Godwina. Brzmi on następująco: im dłużej trwa dyskusja w sieci, tym większe są szanse, że ktoś przywoła Adolfa Hitlera lub nazistów.

Więc tak, Microsoft usunął Tay w ciągu 24 godzin i przeprosił na blogu. Wiceprezes firmy Microsoft Healthcare, Peter Lee, napisał w nim:

Patrząc w przyszłość, stoimy przed trudnymi, a jednocześnie ekscytującymi wyzwaniami badawczymi w projektowaniu AI. Systemy AI czerpią z pozytywnych i negatywnych interakcji z ludźmi. W tym sensie wyzwania są w równym stopniu społeczne, co techniczne. Zrobimy wszystko, co możliwe, aby ograniczyć techniczne exploity, ale wiemy też, że nie możemy w pełni przewidzieć wszystkich możliwych interaktywnych nadużyć człowieka bez uczenia się na błędach. Aby dobrze wykonać sztuczną inteligencję, trzeba iterować z wieloma osobami i często na publicznych forach. Musimy wejść do każdego z wielką ostrożnością i ostatecznie uczyć się i doskonalić, krok po kroku, i robić to bez obrażania ludzi w tym procesie. Będziemy niezłomni w naszych wysiłkach, aby uczyć się na tych i innych doświadczeniach, pracując nad tworzeniem Internetu, który reprezentuje to, co najlepsze, a nie najgorsze z ludzkości.

Kluczem do Tay było powtórzenie niektórych treści osób zadających pytania. W większości jest to słuszne podejście. Jak widzieliśmy w Części 1, było to serce pierwszego chatbota, ELIZA. Ale muszą też istnieć skuteczne filtry. Dzieje się tak zwłaszcza wtedy, gdy chatbot jest używany na platformie o dowolnej formie, takiej jak Twitter (lub w dowolnym scenariuszu w świecie rzeczywistym). Jednak niepowodzenia takie jak Tay są ważne. Pozwalają nam uczyć się i rozwijać technologię. W tym rozdziale przyjrzymy się chatbotom oraz przetwarzaniu języka naturalnego (NLP), które jest kluczową częścią tego, jak komputery rozumieją język i manipulują nim. To jest podzbiór sztucznej inteligencji. Zacznijmy.

**Wyzwania NLP**

Jak widzieliśmy w Części 1, język jest kluczem do testu Turinga, który ma na celu walidację sztucznej inteligencji. Język jest również czymś, co odróżnia nas od zwierząt. Ale ten obszar badań jest niezwykle złożony. Oto tylko niektóre wyzwania związane z NLP:

* Język może być często niejednoznaczny. Uczymy się mówić szybko i podkreślać nasze znaczenie za pomocą niewerbalnych wskazówek, naszego tonu lub reakcji na otoczenie. Na przykład, jeśli piłka golfowa zmierza w kierunku kogoś, krzykniesz „Fore!" Ale system NLP prawdopodobnie tego nie zrozumie, ponieważ nie może przetworzyć kontekstu sytuacji.

* Język zmienia się często wraz ze zmianą świata. Według Oxford English Dictionary w 2018 roku było ponad 1100 słów, sensów i podpozycji (w sumie jest ich ponad 829 000). Niektóre z nowych wpisów obejmowały mansplain i hangary.

* Kiedy rozmawiamy, popełniamy błędy gramatyczne. Ale zwykle nie stanowi to problemu, ponieważ ludzie mają wielką zdolność wnioskowania. Jest to jednak duże wyzwanie dla NLP, ponieważ słowa i wyrażenia mogą mieć wiele znaczeń (nazywa się to polisemią). Na przykład znany badacz sztucznej inteligencji Geoffrey Hinton lubi porównywać „rozpoznawanie mowy" i „zniszczenie ładnej plaży".

* Język ma akcenty i dialekty.

* Znaczenie słów może się zmieniać w wyniku, powiedzmy, użycia sarkazmu lub innych reakcji emocjonalnych.

* Słowa mogą być niejasne. W końcu, co to naprawdę znaczy być „spóźnionym"?

* Wiele słów ma zasadniczo to samo znaczenie, ale zawiera wiele niuansów.

* Rozmowy mogą być nielinearne i zawierać przerwy.

Mimo to nastąpiły wielkie postępy w NLP, co widać w przypadku aplikacji takich jak Siri, Alexa i Cortana. Wiele postępów dokonało się również w ciągu ostatniej dekady, napędzane siłą głębokiego uczenia się. Teraz może być zamieszanie dotyczące języków ludzkich i języków komputerowych. Czy komputery od lat nie rozumieją języków takich jak BASIC, C i C++? To zdecydowanie prawda. Prawdą jest również, że języki komputerowe mają angielskie słowa, takie jak if, let, print. Ale ten rodzaj języka bardzo różni się od języka ludzkiego. Weź pod uwagę, że język komputerowy ma ograniczony zestaw poleceń i ścisłą logikę. Jeśli użyjesz czegoś niepoprawnie, spowoduje to błąd w kodzie prowadzący do awarii. Tak, języki komputerowe są bardzo dosłowne!

**Zrozumienie, jak sztuczna inteligencja tłumaczy język**

Teraz, jak widzieliśmy, NLP było wczesnym celem badaczy AI. Ale z powodu ograniczonej mocy komputera możliwości były dość słabe. Celem było stworzenie reguł interpretacji słów i zdań - które okazały się skomplikowane i mało skalowalne. W pewnym sensie NLP we wczesnych latach był głównie językiem komputerowym! Ale z biegiem czasu wyewoluowała dla niego ogólna struktura. Było to krytyczne, ponieważ NLP zajmuje się danymi nieustrukturyzowanymi, które mogą być nieprzewidywalne i trudne do interpretacji. Oto ogólne ogólne spojrzenie na dwa kluczowe kroki:

• Czyszczenie i wstępne przetwarzanie tekstu: Obejmuje to użycie technik, takich jak tokenizacja, stemming i lematyzacja, aby przeanalizować tekst.

• Rozumienie i generowanie języka: Jest to zdecydowanie najbardziej intensywna część procesu, w której często wykorzystuje się algorytmy głębokiego uczenia się.

W kilku następnych sekcjach przyjrzymy się bardziej szczegółowo różnym krokom.

**Krok Nr. 1 - Czyszczenie i wstępne przetwarzanie**

Na etapie czyszczenia i przetwarzania wstępnego należy zrobić trzy rzeczy: tokenizację, macierzystość i lematyzację.

**Tokenizacja**

Zanim pojawi się NLP, tekst musi zostać przeanalizowany i podzielony na różne części - proces znany jako tokenizacja. Załóżmy na przykład, że mamy następujące zdanie: „Jan zjadł cztery babeczki". Następnie oddzieliłbyś i skategoryzowałbyś każdy element. Rysunek ilustruje tę tokenizację.

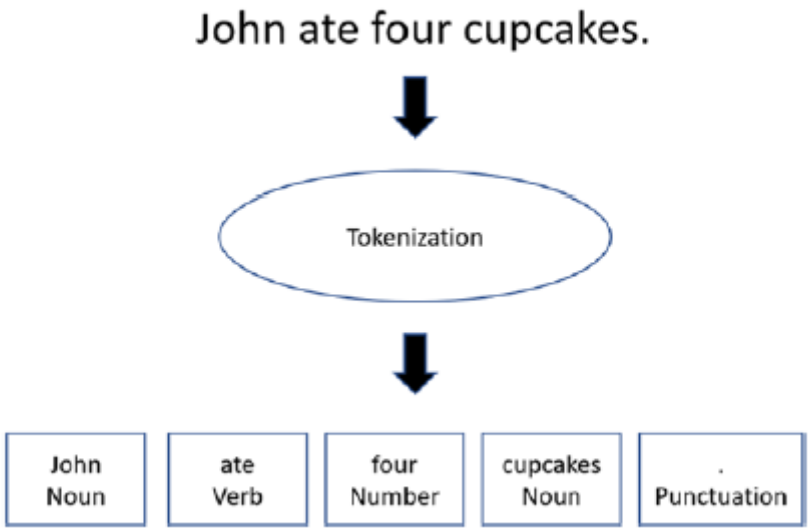


W sumie, łatwe? Poniekąd

Po tokenizacji nastąpi normalizacja tekstu. Wiąże się to z przekształceniem części tekstu w celu ułatwienia analizy, na przykład poprzez zmianę wielkości liter na górną lub dolną, usunięcie znaków interpunkcyjnych i eliminację skrótów. Ale to może łatwo prowadzić do pewnych problemów. Załóżmy, że mamy zdanie, które zawiera „AI". Czy powinniśmy pozbyć się okresów? A jeśli tak, czy komputer będzie wiedział, co oznacza „A I"? Prawdopodobnie nie. Co ciekawe, nawet przypadek słów może mieć duży wpływ na znaczenie. Wystarczy spojrzeć na różnicę między „karmionym" a „karmionym". Fed to często inna nazwa Rezerwy Federalnej. Lub, w innym przypadku, załóżmy, że mamy „nas" i „NAS". Czy mówimy tutaj o Stanach Zjednoczonych? Oto kilka innych problemów:

• Problem z białą spacją: W tym przypadku dwa lub więcej słów powinno stanowić jeden symbol, ponieważ słowa tworzą frazę złożoną. Niektóre przykłady to „Nowy Jork" i „Dolina Krzemowa".

• Naukowe słowa i wyrażenia: Często takie słowa mają łączniki, nawiasy i greckie litery. Jeśli usuniesz te znaki, system może nie być w stanie zrozumieć znaczenia słów i fraz.

• Nieuporządkowany tekst: spójrzmy prawdzie w oczy, wiele dokumentów zawiera błędy gramatyczne i ortograficzne.

• Dzielenie zdań: słowa takie jak „Mr." lub „Pani". może przedwcześnie zakończyć karę z powodu okresu.

• Nieistotne słowa: Są takie, które tak naprawdę niewiele lub wcale nie dodają znaczenia zdaniu. Aby je usunąć, możesz użyć prostego filtra Zatrzymaj słowa.

Jak widać, błędna analiza zdań może być łatwa (a w niektórych językach, takich jak chiński i japoński, składnia może być jeszcze trudniejsza). Ale może to mieć dalekosiężne konsekwencje. Ponieważ tokenizacja jest generalnie pierwszym krokiem, kilka błędów może kaskadowo przechodzić przez cały proces NLP.

**Stemming**

Stemming opisuje proces redukowania słowa do jego rdzenia (lub lematu), na przykład poprzez usuwanie afiksów i przyrostków. W rzeczywistości było to skuteczne w przypadku wyszukiwarek, które wymagają korzystania z grupowania w celu uzyskania bardziej trafnych wyników. Dzięki stemmingowi można znaleźć więcej dopasowań, ponieważ słowo ma szersze znaczenie, a nawet radzić sobie z takimi rzeczami, jak błędy ortograficzne. A gdy korzystasz z aplikacji AI, może to pomóc w lepszym zrozumieniu. Rysunek przedstawia przykład stemmingu.

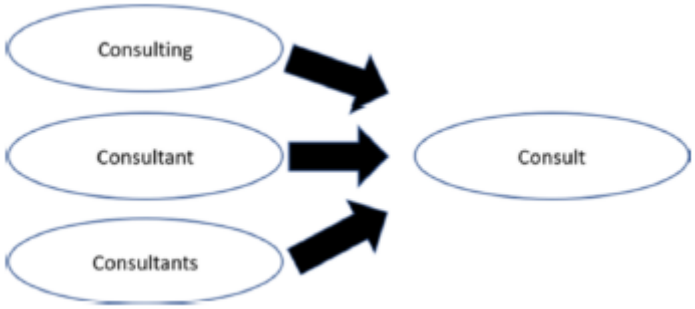


Istnieje wiele algorytmów do zapamiętywania słów, z których wiele jest dość prostych. Ale mają mieszane wyniki. Według IBM:

Algorytm Portera, na przykład, stwierdzi, że „uniwersalny” ma ten sam rdzeń co „uniwersytet” i „uniwersytety”, obserwacja, która może mieć podstawę historyczną, ale nie jest już istotna semantycznie. The Porter stemmer również nie uznaje, że „teatr” i „teatr” powinny należeć do tej samej klasy tematycznej. Z takich powodów Watson Explorer Engine nie używa rdzenia Portera jako swojego rdzenia w języku angielskim.

W rzeczywistości IBM stworzył własny, zastrzeżony stemmer, który pozwala na znaczne dostosowanie.

**Lematyzacja**

Lematyzacja jest podobna do łodygi. Ale zamiast usuwać afiksy lub przedrostki, skupiamy się na znalezieniu podobnych słów źródłowych. Przykładem jest „lepsze”, które moglibyśmy lematyzować do „dobrego”. Działa to tak długo, jak długo znaczenie pozostaje w większości takie samo. W naszym przykładzie oba są mniej więcej podobne, ale „dobry” ma jaśniejsze znaczenie. Lematyzacja może również działać na rzecz lepszego wyszukiwania lub zrozumienia języka, zwłaszcza w przypadku tłumaczeń. Rysunek przedstawia przykład lematyzacji

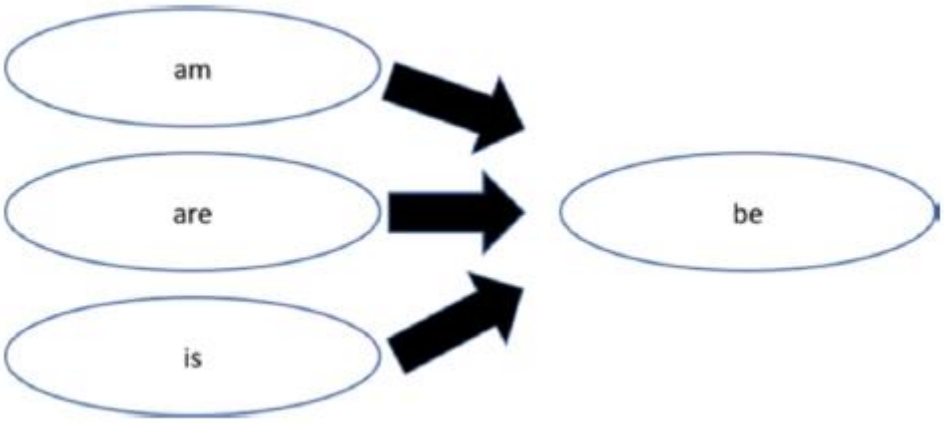


Aby efektywnie wykorzystać lematyzację, system NLP musi rozumieć znaczenie słów i kontekst. Innymi słowy, ten proces ma zwykle lepszą wydajność niż generowanie. Z drugiej strony oznacza to również, że algorytmy są bardziej skomplikowane i wymagane są wyższe poziomy mocy obliczeniowej.

**Krok Nr. 2 - Zrozumienie i wygenerowanie języka**

Gdy tekst zostanie umieszczony w formacie, który komputery mogą przetwarzać, system NLP musi zrozumieć ogólne znaczenie. W większości jest to najtrudniejsza część. Ale przez lata naukowcy opracowali niezliczone techniki, które mogą pomóc, takie jak:

• Oznaczanie części mowy (POS): Przechodzi przez tekst i nadaje każdemu słowu odpowiednią formę gramatyczną, np. rzeczowniki, czasowniki, przysłówki itp. Pomyśl o tym jak o automatycznej wersji lekcji języka angielskiego w szkole podstawowej! Co więcej, niektóre systemy POS mają wariacje. Zauważ, że rzeczownik ma rzeczowniki w liczbie pojedynczej (NN), rzeczowniki w liczbie pojedynczej (NNP) i rzeczowniki w liczbie mnogiej (NNS).

• Kawałki: słowa zostaną następnie przeanalizowane pod kątem fraz. Na przykład fraza rzeczownikowa (NP) to rzeczownik, który działa jako podmiot lub dopełnienie czasownika.

• Rozpoznawanie nazwanych jednostek: To identyfikuje słowa, które reprezentują lokalizacje, osoby i organizacje.

• Modelowanie tematyczne: szuka ukrytych wzorców i skupisk w tekście. Jeden z algorytmów, zwany Latent Dirichlet Allocation (LDA), opiera się na nienadzorowanych metodach uczenia się. Oznacza to, że zostaną przypisane losowe tematy, a następnie komputer będzie iterował, aby znaleźć dopasowania.

W przypadku wielu z tych procesów możemy wykorzystać modele uczenia głębokiego. Można je rozszerzyć na więcej obszarów analizy - aby umożliwić bezproblemowe rozumienie i generowanie języka. Jest to proces znany jako semantyka dystrybucji. Dzięki splotowej sieci neuronowej (CNN), o której dowiedzieliśmy się w rozdziale 4, można znaleźć zbitki słów, które są tłumaczone na mapę cech. Umożliwiło to aplikacjom takim jak tłumaczenie języka, rozpoznawanie mowy, analiza nastrojów oraz pytania i odpowiedzi. W rzeczywistości model potrafi nawet wykrywać sarkazm! Jednak są pewne problemy z CNN. Na przykład model ma problemy z tekstem, który ma zależności na dużych odległościach. Istnieje jednak kilka sposobów radzenia sobie z tym, na przykład za pomocą opóźnionych w czasie sieci neuronowych (TDNN) i dynamicznych splotowych sieci neuronowych (DCNN). Metody te wykazały wysoką wydajność w obsłudze danych sekwencjonowanych. Chociaż model, który odniósł większy sukces w tym zakresie, to rekurencyjna sieć neuronowa (RNN), ponieważ

zapamiętuje dane. Do tej pory skupialiśmy się głównie na analizie tekstu. Ale żeby było wyrafinowane NLP, musimy także zbudować systemy rozpoznawania głosu.

**Rozpoznawanie głosu**

W 1952 roku Bell Labs stworzył pierwszy system rozpoznawania głosu o nazwie Audrey (od Automatic Digit Recognition). Był w stanie rozpoznać fonemy, które są najbardziej podstawowymi jednostkami dźwięków w języku. Na przykład angielski ma 44. Audrey potrafiła rozpoznać dźwięk cyfry od zera do dziewięciu. Było to trafne dla głosu twórcy maszyny, HK Davisa, w około 90% przypadków.6 A dla każdego innego było to od 70% do 80%. Audrey była wielkim wyczynem, zwłaszcza w świetle ograniczonej mocy obliczeniowej i dostępnej w tym czasie pamięci. Ale program uwydatnił również główne wyzwania związane z rozpoznawaniem głosu. Kiedy mówimy, nasze zdania mogą być złożone i nieco pomieszane. Mówimy też na ogół szybko – średnio 150 słów na minutę. W rezultacie systemy rozpoznawania głosu poprawiały się w lodowatym tempie. W 1962 roku system IBM Shoebox mógł rozpoznawać tylko 16 słów, 10 cyfr i 6 poleceń matematycznych. Dopiero w latach 80. nastąpił znaczny postęp w technologii. Kluczowym przełomem było zastosowanie ukrytego modelu Markowa (HMM), opartego na wyrafinowanych statystykach. Na przykład, jeśli wypowiesz słowo „dog", nastąpi analiza poszczególnych dźwięków d, o i g. Algorytm HMM przypisze każdemu z nich wynik. Z biegiem czasu system będzie lepiej rozumiał dźwięki i przekładał je na słowa. Chociaż HMM był krytyczny, nadal nie był w stanie skutecznie radzić sobie z ciągłą mową. Na przykład systemy głosowe opierały się na dopasowaniu szablonów. Wiązało się to z tłumaczeniem fal dźwiękowych na liczby, co odbywało się poprzez samplowanie. W rezultacie oprogramowanie mierzyło częstotliwość interwałów i zapisywało wyniki. Ale musiał być wyrównany mecz. Z tego powodu wprowadzanie głosowe musiało być dość wyraźne i powolne. Musiało też być trochę hałasu w tle. Ale w latach 90. twórcy oprogramowania zrobili postępy i wyszli z systemami komercyjnymi, takimi jak Dragon Dictate, które potrafiły rozumieć tysiące słów w mowie ciągłej. Jednak adopcja nadal nie była głównym nurtem. Wielu osobom nadal łatwiej było pisać na swoich komputerach i używać myszy. Jednak istniały pewne zawody, takie jak medycyna (popularny przypadek użycia z transkrypcją diagnozy pacjentów), w których rozpoznawanie mowy znajdowało wysoki poziom wykorzystania. Wraz z pojawieniem się uczenia maszynowego i głębokiego uczenia systemy głosowe szybko stały się znacznie bardziej wyrafinowane i dokładne. Niektóre z kluczowych algorytmów wykorzystują pamięć długo-krótkotrwałą (LSTM), rekurencyjne sieci neuronowe i głębokie sieci neuronowe ze sprzężeniem do przodu. Google wdrożyło te podejścia w Google Voice, który był dostępny dla setek milionów użytkowników smartfonów. I oczywiście widzieliśmy ogromny postęp w przypadku innych ofert, takich jak Siri, Alexa i Cortana.

**NLP w prawdziwym świecie**

W większości przeszliśmy przez główne części przepływu pracy NLP. Następnie przyjrzyjmy się potężnym zastosowaniom tej technologii.

**Przypadek użycia: poprawa sprzedaży**

Roy Raanani, który ma karierę w pracy ze start-upami technologicznymi, uważał, że niezliczone konwersje, które pojawiają się na co dzień w biznesie, są w większości ignorowane. Może sztuczna inteligencja mogłaby przekształcić to w szansę? W 2015 roku założył Chorus, aby wykorzystać NLP do wydobycia spostrzeżeń z rozmów ze sprzedawcami. Raanani nazwał to chmurą rozmów, która rejestruje, organizuje i transkrybuje rozmowy, które są wprowadzane do systemu CRM (Customer Relationship Management). Z czasem algorytmy zaczną uczyć się o najlepszych praktykach i wskazywać, jak można coś ulepszyć. Ale osiągnięcie tego nie było łatwe. Według bloga Chorusa:

Istnieją miliardy sposobów zadawania pytań, zgłaszania zastrzeżeń, ustalania działań, kwestionowania hipotez itp., z których wszystkie należy zidentyfikować, jeśli mają zostać skodyfikowane wzorce sprzedaży. Po drugie, sygnały i wzorce ewoluują: nowi konkurenci, nazwy i funkcje produktów oraz terminologia branżowa zmieniają się z czasem, a modele uczone maszynowo szybko stają się przestarzałe.

Na przykład jedną z trudności, którą można łatwo przeoczyć, jest identyfikowanie rozmówców (często w trakcie rozmowy jest więcej niż trzy osoby). Znana jako „separacja głośników", jest uważana za jeszcze trudniejszą niż rozpoznawanie mowy. Chorus stworzył model głębokiego uczenia się, który zasadniczo tworzy „głosowy odcisk palca" – oparty na grupowaniu – dla każdego mówcy. Tak więc po kilku latach prac badawczo-rozwojowych firma była w stanie opracować system, który mógłby analizować duże ilości rozmów. Jako dowód tego, spójrz na jednego z klientów Chorus, Housecall Pro, który jest startupem sprzedającym technologie mobilne do zarządzania usługami terenowymi. Przed wdrożeniem oprogramowania firma często tworzyła spersonalizowane oferty sprzedaży dla każdego potencjalnego klienta. Ale niestety był nieskalowalny i miał mieszane wyniki. Ale dzięki Chorusowi firma była w stanie stworzyć podejście, które nie miało zbyt wielu różnic. Oprogramowanie umożliwiło mierzenie każdego słowa i wpływu na konwersje sprzedażowe. Chorus mierzył również, czy przedstawiciel handlowy był zgodny ze scenariuszem, czy nie. Wynik? Firma była w stanie zwiększyć wskaźnik wygranych organizacji sprzedaży o 10%.

**Przykład użycia: walka z depresją**

Według danych Światowej Organizacji Zdrowia na całym świecie około 300 milionów ludzi cierpi na depresję.9 Około 15% dorosłych doświadcza pewnego rodzaju depresji w ciągu swojego życia. Może to nie zostać zdiagnozowane z powodu braku opieki zdrowotnej, co może oznaczać, że sytuacja danej osoby może się znacznie pogorszyć. Niestety depresja może prowadzić do innych problemów. Ale NLP może być w stanie poprawić sytuację. Niedawne badanie ze Stanford wykorzystywało model uczenia maszynowego, który przetwarzał mimikę 3D i język mówiony. W rezultacie system był w stanie zdiagnozować depresję ze średnim poziomem błędu 3,67 przy użyciu skali Kwestionariusza Zdrowia Pacjenta (PHQ). Dokładność była jeszcze wyższa w przypadku bardziej zaostrzonych form depresji. W badaniu naukowcy zauważyli: „Ta technologia może zostać wdrożona w telefonach komórkowych na całym świecie i ułatwić tani powszechny dostęp do opieki psychiatrycznej.

**Zastosowanie: tworzenie treści**

W 2015 r. kilku weteranów technologii, takich jak Elon Musk, Peter Thiel, Reid Hoffman i Sam Altman, uruchomiło OpenAI przy wsparciu finansowym o wartości 1 miliarda dolarów. Celem zorganizowanej jako organizacja non-profit było stworzenie organizacji, której celem było „rozwijanie inteligencji cyfrowej w sposób, który najprawdopodobniej przyniesie korzyści całej ludzkości, nieograniczony potrzebą generowania zwrotu finansowego". Jednym z obszarów badań był NLP. W tym celu firma uruchomiła w 2019 r. model o nazwie GPT-2, który opierał się na zbiorze danych obejmującym około ośmiu milionów stron internetowych. Skupiono się na stworzeniu systemu, który mógłby przewidzieć następne słowo na podstawie grupy tekstu.

Aby to zilustrować, OpenAI dostarczył eksperyment z następującym tekstem jako danymi wejściowymi: „W szokującym odkryciu naukowiec odkrył stado jednorożców żyjących w odległej, wcześniej niezbadanej dolinie w Andach. Jeszcze bardziej zaskakujący dla badaczy był fakt, że jednorożce mówiły doskonale po angielsku". Na tej podstawie algorytmy stworzyły przekonującą historię o długości 377 słów! To prawda, że naukowcy przyznali, że opowiadanie historii było lepsze w przypadku tematów, które bardziej odnosiły się do podstawowych danych, takich jak Władca Pierścieni, a nawet Brexit. Nie powinno dziwić, że GPT-2 wykazał słabą wydajność w domenach technicznych. Ale model był w stanie

uzyskać wysokie wyniki w kilku dobrze znanych ocenach czytania ze zrozumieniem. Mimo że typowy człowiek uzyskałby 90%+ w tych testach, wydajność GPT-2 jest nadal imponująca. Należy zauważyć, że model wykorzystywał innowację sieci neuronowej Google, zwaną Transformer, oraz nienadzorowane uczenie się. Zgodnie z misją OpenAI organizacja zdecydowała się nie wydawać pełnego modelu. Obawiano się, że może to prowadzić do negatywnych konsekwencji, takich jak fałszywe wiadomości, sfałszowane recenzje Amazon.com, spam i oszustwa phishingowe.

Przypadek użycia: język ciała

Samo skupienie się na samym języku może być ograniczające. Język ciała to również coś, co powinno być uwzględnione w wyrafinowanym modelu sztucznej inteligencji. To jest coś, o czym Rana el Kaliouby myślał od jakiegoś czasu. Dorastając w Egipcie, uzyskała tytuł magistra nauk ścisłych na Uniwersytecie Amerykańskim w Kairze, a następnie uzyskała tytuł doktora informatyki w Newnham College na Uniwersytecie Cambridge. Ale było coś, co było dla niej bardzo przekonujące: jak komputery mogą wykrywać ludzkie emocje? Jednak w jej kręgach akademickich zainteresowanie było niewielkie. W społeczności informatyków panował zgodny pogląd, że ten temat naprawdę nie jest przydatny. Ale Rana nie zniechęciła się i połączyła siły ze znaną profesor Rosalind Picard, aby stworzyć innowacyjne modele uczenia maszynowego (napisała kluczową książkę zatytułowaną Affective Computing, w której przyglądała się emocjom i maszynom). Musiało jednak być również wykorzystanie innych dziedzin, takich jak neuronauka i psychologia. Dużą częścią tego było wykorzystanie pionierskiej pracy Paula Ekmana, który przeprowadził rozległe badania nad ludzkimi emocjami opartymi na mięśniach twarzy. Odkrył, że istnieje sześć uniwersalnych ludzkich emocji (gniew, wulgaryzm, przerażenie, radość, samotność i szok), które można zakodować za pomocą 46 ruchów zwanych jednostkami działania – wszystkie stają się częścią systemu kodowania akcji twarzy (FACS). Podczas pracy w MIT Media Lab Rana opracowała „emocjonalny aparat słuchowy", który był urządzeniem do noszenia, które umożliwiało osobom z autyzmem lepszą interakcję w środowiskach społecznych. System wykrywałby emocje ludzi i zapewniał odpowiednie sposoby reagowania. Był przełomowy, ponieważ New York Times nazwał go jedną z najważniejszych innowacji w 2006 roku. Ale system Rany przyciągnął również uwagę Madison Avenue. Mówiąc najprościej, technologia może być skutecznym narzędziem do oceny nastroju widzów w związku z reklamą telewizyjną. Kilka lat później Rana wypuściła Affectiva. Firma szybko się rozwinęła i przyciągnęła znaczne kwoty kapitału wysokiego ryzyka (w sumie zebrała 54,2 mln USD). Rana, kiedyś ignorowana, teraz stała się jednym z liderów trendu zwanego „sztuczną inteligencją śledzącą emocje". Flagowym produktem Affectiva jest Affdex, czyli oparta na chmurze platforma do testowania odbiorców wideo. Korzysta z niego około jedna czwarta osób z listy Fortune Global 500. Ale firma opracowała inny produkt o nazwie Affectiva Automotive AI, który jest systemem wykrywania w kabinie pojazdu. Niektóre z możliwości obejmują:

• Monitorowanie zmęczenia kierowcy lub rozproszenia uwagi, które wywoła alarm (powiedzmy wibracje pasa bezpieczeństwa).

• Zapewnienie przełączenia do półautonomicznego systemu, jeśli kierowca się nie obudzi lub jest zły. Istnieje nawet możliwość zapewnienia alternatywnych tras, aby zmniejszyć ryzyko wściekłości na drogach!

• Personalizacja treści – powiedzmy muzyki – na podstawie emocji pasażera.

W przypadku wszystkich tych ofert istnieją zaawansowane systemy uczenia głębokiego, które przetwarzają ogromne ilości funkcji bazy danych zawierającej ponad 7,5 miliona twarzy. Modele te uwzględniają również wpływy kulturowe i różnice demograficzne — wszystko to odbywa się w czasie rzeczywistym.

**Handel głosowy**

Technologie oparte na NLP, takie jak wirtualni asystenci, chatboty i inteligentne głośniki, mogą mieć potężne modele biznesowe, a nawet mogą zakłócić rynki, takie jak e-commerce i marketing. Widzieliśmy już wczesną wersję tego z franczyzą WeChat firmy Tencent. Firma, która powstała w okresie rozkwitu internetowego boomu pod koniec lat 90., zaczęła od prostego komunikatora na komputery PC o nazwie OICQ. Ale to właśnie wprowadzenie WeChat zmieniło zasady gry, która od tego czasu stała się największą chińską platformą mediów społecznościowych z ponad miliardem aktywnych użytkowników miesięcznie. Ale ta aplikacja jest czymś więcej niż tylko do wymiany wiadomości i publikowania treści. WeChat szybko przekształcił się w uniwersalnego wirtualnego asystenta, w którym możesz łatwo przywołać usługę wspólnego przejazdu, dokonać płatności w lokalnym sklepie, zarezerwować lot lub zagrać w grę. Na przykład aplikacja odpowiada za blisko 35% całego czasu użytkowania na smartfonach w Chinach w ujęciu miesięcznym. WeChat jest również głównym powodem, dla którego kraj staje się coraz bardziej społeczeństwem bezgotówkowym. Wszystko to wskazuje na siłę powstającej kategorii zwanej handlem głosowym (lub v-commerce), w której można dokonywać zakupów za pośrednictwem czatu lub głosu. Jest to tak krytyczny trend, że Mark Zuckerberg z Facebooka napisał na blogu na początku 2019 roku, w którym powiedział, że firma będzie bardziej przypominać… WeChat. Według badań firmy Juniper prognozuje się, że do 2023 r. rynek handlu głosowego osiągnie 80 miliardów dolarów. Ale jeśli chodzi o zwycięzców na tym rynku, wydaje się, że to dobry zakład, że będą to firmy, które mają dużą bazę instalacji inteligentne urządzenia, takie jak Amazon, Apple i Google. Ale nadal będzie miejsce dla dostawców technologii NLP nowej generacji. W porządku, jak te systemy AI mogą wpłynąć na branżę marketingową? Cóż, żeby zobaczyć, jak, w Harvard Business Review ukazał się artykuł zatytułowany „Marketing w epoce Alexy" autorstwa Niraja Dawara i Neila Bendle'a. Autorzy zauważają w nim, że „asystenci AI zmienią sposób, w jaki firmy łączą się ze swoimi klientami. Staną się głównym kanałem, przez który ludzie uzyskują informacje, towary i usługi, a marketing zamieni się w ciasto, które przyciąga ich uwagę". Tak więc wzrost liczby chatbotów, asystentów cyfrowych i inteligentnych głośników może być znacznie większy niż początkowa internetowa rewolucja e-commerce. Technologie te przynoszą klientom znaczne korzyści, takie jak wygoda. Łatwo powiedzieć urządzeniu, żeby coś kupiło, a maszyna dowie się również o Twoich nawykach. Więc następnym razem, gdy powiesz, że chcesz się napić, komputer będzie wiedział, o czym mówisz. Ale może to prowadzić do scenariusza, w którym zwycięzca bierze wszystko. Ostatecznie wydaje się, że konsumenci będą używać tylko jednego inteligentnego urządzenia do robienia zakupów. Ponadto marki, które chcą sprzedawać swoje towary, będą musiały dogłębnie zrozumieć, czego naprawdę chcą klienci, aby stać się preferowanym sprzedawcą w silniku rekomendacji.

**Wirtualni Asystenci**

W 2003 r., gdy Stany Zjednoczone były uwikłane w wojny na Bliskim Wschodzie, Departament Obrony chciał zainwestować w technologie nowej generacji na polu bitwy. Jedną z kluczowych inicjatyw było zbudowanie wyrafinowanego wirtualnego asystenta, który potrafiłby rozpoznawać instrukcje mówione. Departament Obrony przeznaczył na ten cel 150 milionów dolarów i zlecił opracowanie aplikacji laboratorium SRI (Stanford Research Institute) z siedzibą w Dolinie Krzemowej. Mimo że laboratorium było organizacją non-profit, nadal wolno mu było licencjonować swoje technologie (takie jak drukarka atramentowa) startupom. I tak właśnie stało się z wirtualnym asystentem. Niektórzy członkowie SRI - Dag Kittlaus, Tom Gruber i Adam Cheyer - nazwali ją Siri i założyli własną firmę, aby wykorzystać okazję. Założyli operację w 2007 roku, kiedy to uruchomiono iPhone'a firmy Apple.

Ale musiało być dużo więcej prac badawczo-rozwojowych, aby produkt mógł być użyteczny dla konsumentów. Założyciele musieli opracować system do obsługi danych w czasie rzeczywistym, zbudować wyszukiwarkę informacji geograficznych oraz zbudować zabezpieczenia kart kredytowych i

danych osobowych. Ale to NLP było najtrudniejszym wyzwaniem. W wywiadzie Cheyer zauważył: Najtrudniejszym technicznym wyzwaniem z Siri było radzenie sobie z ogromną ilością niejednoznaczności obecnych w ludzkim języku. Rozważ wyrażenie „zarezerwuj 4-gwiazdkową restaurację w Bostonie" – wydaje się bardzo proste do zrozumienia. Nasz prototypowy system poradziłby sobie z tym z łatwością. Kiedy jednak wprowadziliśmy do systemu dziesiątki milionów nazw firm i setki tysięcy miast jako słownictwo (prawie każde słowo w języku angielskim to nazwa firmy), liczba tłumaczeń kandydatów poszybowała w górę. Ale zespołowi udało się rozwiązać problemy i przekształcić Siri w potężny system, który został uruchomiony w App Store firmy Apple w lutym 2010 roku. „To najbardziej wyrafinowane rozpoznawanie głosu, jakie pojawiło się na smartfonie" — wynika z recenzji opublikowanej w Wired. com. Steve Jobs zwrócił na to uwagę i zadzwonił do założycieli. W ciągu kilku dni mieli się spotkać, a dyskusje szybko doprowadziły do przejęcia, które miało miejsce pod koniec kwietnia za ponad 200 milionów dolarów. Jednak Jobs uważał, że Siri wymaga ulepszeń. Z tego powodu w 2011 roku nastąpiło ponowne wydanie. To faktycznie wydarzyło się dzień przed śmiercią Jobsa. Szybko do przodu, Siri ma największy udział w rynku wirtualnych asystentów, z 48,6%. Asystent Google ma 28,7%, a Alexa Amazon.com ma 13,2%. Według raportu „Voice Assistant Consumer Adoption Report" około 146,6 mln osób w Stanach Zjednoczonych wypróbowało wirtualnych asystentów na swoich smartfonach, a ponad 50 mln z inteligentnymi głośnikami. Ale to obejmuje tylko część historii. Technologia głosowa pojawia się również w urządzeniach do noszenia, słuchawkach i urządzeniach. Oto kilka innych interesujących ustaleń:

• Używanie głosu do wyszukiwania produktów, które zostały przelicytowane w wynikach wyszukiwania różnych opcji rozrywki.

• Jeśli chodzi o produktywność, najczęstsze przypadki użycia głosu obejmują wykonywanie połączeń, wysyłanie e-maili i ustawianie alarmów.

• Najczęstsze użycie głosu w smartfonach ma miejsce, gdy osoba prowadzi samochód.

• Jeśli chodzi o skargi na asystentów głosowych na smartfonach, największym odsetkiem była niespójność w zrozumieniu próśb. Ponownie wskazuje to na ciągłe wyzwania NLP.

Potencjał wzrostu wirtualnych asystentów pozostaje jasny, a kategoria ta prawdopodobnie będzie kluczowa dla branży AI. Firma Juniper Research prognozuje, że do 2023 r. liczba wirtualnych asystentów używanych na całym świecie wzrośnie ponad trzykrotnie, do 2,5 miliarda.24 Oczekuje się, że najszybszą kategorią będą telewizory inteligentne. Tak, myślę, że będziemy prowadzić rozmowy z tymi urządzeniami!

Chatboty

Często dochodzi do nieporozumień między wirtualnymi asystentami a chatbotami. Pamiętaj, że te dwa elementy w dużym stopniu się pokrywają. Obaj używają NLP do interpretacji języka i wykonywania zadań. Ale nadal istnieją krytyczne rozróżnienia. W większości chatboty są przeznaczone przede wszystkim dla firm, takich jak obsługa klienta lub funkcje sprzedażowe. Z drugiej strony, wirtualni asystenci są nakierowani zasadniczo na każdego, aby pomóc w ich codziennych czynnościach. Jak widzieliśmy w Części 1, początki chatbotów sięgają lat 60-tych wraz z rozwojem ELIZA. Ale dopiero w ostatniej dekadzie technologia ta stała się użyteczna na dużą skalę. Oto próbka interesujących chatbotów:

• Ushur: Jest to zintegrowane z systemami korporacyjnymi dla firm ubezpieczeniowych, co pozwala na automatyzację przetwarzania roszczeń/rachunków oraz umożliwia sprzedaż. Oprogramowanie wykazało średnio 30% redukcję liczby telefonów do centrum serwisowego i 90% wskaźnik odpowiedzi

klientów. Firma zbudowała własną, najnowocześniejszą lingwistykę silnik o nazwie LISA (skrót od Language Intelligence Services Architecture). LISA obejmuje NLP, NLU, analizę sentymentu, wykrywanie sarkazmu, wykrywanie tematów, ekstrakcję danych i tłumaczenia językowe. Technologia obsługuje obecnie 60 języków, dzięki czemu jest użyteczną platformą dla organizacji globalnych.

• Mya: To chatbot, który może prowadzić rozmowy w procesie rekrutacji. Podobnie jak Ushur, jest to również oparte na domowej technologii NLP. Niektóre z powodów to lepsza komunikacja, ale także zajmowanie się konkretnymi tematami dotyczącymi zatrudniania. Mya znacznie skraca czas rozmowy kwalifikacyjnej i zatrudniania, eliminując główne wąskie gardła.

• Jane.ai: jest to platforma, która wydobywa dane z aplikacji i baz danych organizacji — powiedzmy Salesforce. com, Office, Slack i Gmail — aby znacznie ułatwić uzyskiwanie spersonalizowanych odpowiedzi. Zwróć uwagę, że około 35% czasu pracownika poświęca się na szukanie informacji! Na przykład przypadkiem użycia Jane.ai jest USA Mortgage. Firma wykorzystała technologię zintegrowaną ze Slackiem, aby pomóc brokerom w wyszukiwaniu informacji do przetwarzania kredytów hipotecznych. W rezultacie firma USA Mortgage zaoszczędziła około 1000 godzin pracy ludzkiej miesięcznie.

Mimo to chatboty nadal mają mieszane wyniki. Na przykład, tylko jednym z problemów jest to, że trudno jest programować systemy dla wyspecjalizowanych dziedzin. Spójrz na badanie przeprowadzone przez UserTesting, które zostało oparte na odpowiedziach 500 konsumentów chatbotów dla służby zdrowia. Oto niektóre z głównych wniosków: w przypadku chatbotów pozostaje wiele obaw, zwłaszcza podczas przetwarzania danych osobowych, a technologia ma problemy ze zrozumieniem złożonych tematów. Dlatego przed wdrożeniem chatbota należy wziąć pod uwagę kilka czynników:

• Ustal oczekiwania: Nie przesadzaj z możliwościami chatbotów. To tylko ustawi twoją organizację na rozczarowanie. Na przykład nie powinieneś udawać, że chatbot to człowiek. To pewny sposób na tworzenie złych doświadczeń. W rezultacie możesz zacząć rozmowę z chatbotem od słów „Cześć, jestem chatbotem, który pomoże Ci w…”

• Automatyzacja: W niektórych przypadkach chatbot może obsłużyć cały proces z klientem. Ale nadal powinieneś mieć ludzi w pętli. „Celem chatbotów nie jest całkowite zastąpienie ludzi, ale bycie pierwszą linią obrony, że tak powiem”, powiedział Antonio Cangiano, ewangelista AI w IBM. „Może to oznaczać nie tylko oszczędność pieniędzy firm, ale także uwolnienie ludzkich agentów, którzy będą mogli spędzać więcej czasu na złożonych zapytaniach, które są do nich eskalowane”.

• Tarcie: W miarę możliwości staraj się znaleźć sposób, aby chatbot rozwiązywał problemy tak szybko, jak to możliwe. I niekoniecznie musi to być rozmowa. Zamiast tego udostępnienie prostego formularza do wypełnienia może być lepszą alternatywą, powiedzmy, aby zaplanować prezentację.

• Powtarzalne procesy: są one często idealne dla chatbotów. Przykłady obejmują uwierzytelnianie, status zamówienia, planowanie i proste żądania zmian.

• Centralizacja: upewnij się, że integrujesz dane z chatbotami. Pozwoli to na bardziej płynne wrażenia. Bez wątpienia klienci szybko denerwują się, gdy muszą powtarzać informacje.

• Spersonalizuj doświadczenie: nie jest to łatwe, ale może przynieść duże korzyści. Jonathan Taylor, który jest dyrektorem ds. technologii w Zoovu, ma taki przykład: „Zakup obiektywu aparatu będzie inny dla każdego kupującego. Istnieje wiele odmian soczewek, które być może rozumie słabo poinformowany kupujący, ale przeciętny konsument może nie być tak dobrze poinformowany. Zapewnienie pomocniczego chatbota, który poprowadzi klienta do właściwego obiektywu, może

pomóc zapewnić ten sam poziom obsługi klienta, co pracownik w sklepie. Pomocniczy chatbot może zadawać właściwe pytania, rozumiejąc cel klienta, jakim jest dostarczenie spersonalizowanej rekomendacji produktu, w tym „jaki rodzaj aparatu już masz", „dlaczego kupujesz nowy aparat" i „czego przede wszystkim próbujesz uchwycić na swoich fotografiach?"

• Analiza danych: Bardzo ważne jest monitorowanie opinii za pomocą chatbota. Jaka jest satysfakcja? Jaki jest wskaźnik dokładności?

• Projektowanie konwersacji i doświadczenie użytkownika (UX): to coś innego niż tworzenie strony internetowej czy nawet aplikacji mobilnej. Z chatbotem musisz pomyśleć o osobowości użytkownika, płci, a nawet kontekście kulturowym. Co więcej, musisz wziąć pod uwagę „głos" swojej firmy. „Zamiast tworzyć makiety interfejsu wizualnego, pomyśl o pisaniu skryptów i odtwarzaniu ich przed jego zbudowaniem" – powiedziała Gillian McCann, szefowa działu inżynierii chmury i sztucznej inteligencji w Workgrid Software.

Nawet w przypadku problemów z chatbotami technologia wciąż się poprawia. Co ważniejsze, systemy te prawdopodobnie staną się coraz ważniejszą częścią branży AI. Według IDC w 2019 r. na chatboty zostanie wydanych około 4,5 miliarda dolarów, co w porównaniu z 35,8 miliardami dolarów szacowanymi na systemy sztucznej inteligencji. Coś jeszcze: badanie przeprowadzone przez Juniper Research wskazuje, że oszczędności dzięki chatbotom mogą być znaczne. Firma przewiduje, że do 2023 r. osiągną 7,3 mld USD, w porównaniu z zaledwie 209 mln USD w 2019 r.33.

**Przyszłość NLP**

W 1947 roku Boris Katz urodził się w Mołdawii, która była częścią Związku Radzieckiego. Następnie ukończył Moskiewski Uniwersytet Państwowy, gdzie poznał komputery, a następnie wyjechał do Stanów Zjednoczonych (z pomocą senatora Edwarda Kennedy'ego). Nie marnował czasu przy tej okazji. Oprócz napisania ponad 80 publikacji technicznych i uzyskania dwóch patentów w USA, stworzył system START, który pozwalał na zaawansowane możliwości NLP. Była to właściwie podstawa pierwszej witryny internetowej z pytaniami i odpowiedziami w 1993 roku. Tak, była to zapowiedź przełomowych firm, takich jak Yahoo! i Google. Innowacje Borisa miały również kluczowe znaczenie dla Watsona IBM, który jest obecnie podstawą działań firmy w zakresie sztucznej inteligencji. Ten komputer w 2011 roku zaszokował świat, pokonując dwóch wszechczasów mistrzów popularnego teleturnieju Jeopardy! Pomimo całego postępu w NLP, Boris nie jest zadowolony. Wierzy, że wciąż jesteśmy na wczesnym etapie i trzeba zrobić dużo więcej, aby uzyskać prawdziwą wartość. W wywiadzie dla MIT Technology Review powiedział: „Ale z drugiej strony te programy [takie jak Siri i Alexa] są tak niewiarygodnie głupie. Jest więc poczucie dumy i niemal zakłopotania. Wprowadzasz coś, co ludzie uważają za inteligentne, ale nawet nie jest blisko". Nie oznacza to, że jest pesymistą. Jednak nadal uważa, że należy przemyśleć NLP, jeśli ma dojść do „prawdziwej inteligencji". Uważa, że w tym celu badacze muszą wykroczyć poza czystą informatykę do szerokich obszarów, takich jak neuronauka, kognitywistyka i psychologia. Uważa również, że systemy NLP muszą znacznie lepiej rozumieć działania w prawdziwym świecie.

**Wniosek**

Dla wielu osób pierwsza interakcja z NLP odbywa się z wirtualnymi asystentami. Nawet jeśli technologia jest daleka od doskonałości, nadal jest bardzo przydatna - zwłaszcza do odpowiadania na pytania lub uzyskiwania informacji, powiedzmy o pobliskiej restauracji. Ale NLP ma również duży wpływ na świat biznesu. W nadchodzących latach technologia będzie stawać się coraz ważniejsza dla handlu elektronicznego i obsługi klienta – zapewniając znaczne oszczędności kosztów i pozwalając pracownikom skupić się na działaniach o większej wartości dodanej. To prawda, że ze względu na

złożoność języka przed nami jeszcze długa droga. Ale postęp jest nadal szybki, zwłaszcza z pomocą podejść AI nowej generacji, takich jak głębokie uczenie.

**Kluczowe dania na wynos**

• Przetwarzanie języka naturalnego (NLP) to wykorzystanie sztucznej inteligencji w celu umożliwienia komputerom zrozumienia ludzi.

• Chatbot to system AI, który komunikuje się z ludźmi, powiedzmy za pomocą głosu lub czatu online.

• Chociaż w NLP poczyniono wielkie postępy, jest jeszcze wiele do zrobienia. Tylko niektóre z wyzwań obejmują niejednoznaczność języka, sygnały niewerbalne, różne dialekty i akcenty oraz zmiany w języku.

• Dwa główne kroki z NLP obejmują czyszczenie/wstępne przetwarzanie tekstu i wykorzystanie sztucznej inteligencji do zrozumienia i wygenerowania języka.

• Tokenizacja polega na analizowaniu tekstu i dzieleniu go na różne części.

• Dzięki normalizacji tekst jest przekształcany w formę, która ułatwia analizę, na przykład przez usunięcie znaków interpunkcyjnych lub skrótów.

• Stemming opisuje proces redukowania słowa do jego rdzenia (lub lematu), na przykład poprzez usuwanie afiksów i przyrostków.

• Podobnie do tematu, lematyzacja polega na znalezieniu podobnych słów źródłowych.

• Aby NLP mógł zrozumieć język, istnieją różne podejścia, takie jak tagowanie części mowy (umieszczanie tekstu w formie gramatycznej), chunking (przetwarzanie tekstu we frazach) i modelowanie tematu (znajdowanie ukrytych wzorców i klastrów).

• Fonem to najbardziej podstawowa jednostka dźwiękowa w języku.

**Roboty fizyczne**

**Ostateczna manifestacja AI**

„W mieście Pasadena poszedłem do CaliBurgera na lunch i zauważyłem tłum ludzi obok miejsca, w którym gotowano jedzenie - które było za szkłem. Ludzie robili zdjęcia smartfonami! Czemu? Powodem był Flippy, robot napędzany sztuczną inteligencją, który potrafi gotować hamburgery. Byłem tam w restauracji z Davidem Zito, prezesem i współzałożycielem firmy Miso Robotics, która zbudowała system. „Flippy pomaga poprawić jakość żywności ze względu na konsystencję i zmniejsza koszty produkcji" – powiedział. „Zbudowaliśmy również robota, aby był w ścisłej zgodności z normami prawnymi". Po obiedzie poszedłem do laboratorium Miso Robotics, które obejmowało centrum testowe z przykładowymi robotami. To tutaj zobaczyłem konwergencję systemów sztucznej inteligencji oprogramowania i robotów fizycznych. Inżynierowie budowali mózg Flippy′ego, który został przesłany do chmury. Tylko niektóre z możliwości obejmowały zmywanie sztućców i grilla, naukę dostosowywania się do problemów z gotowaniem, przełączanie między łopatką do surowego mięsa a łopatką do gotowanego mięsa oraz umieszczanie koszy we frytownicy." (Tom Tulli). Wszystko to odbywało się w czasie rzeczywistym. Ale branża gastronomiczna to tylko jeden z wielu obszarów, na które robotyka i sztuczna inteligencja będą miały duży wpływ. Według International Data Corporation (IDC) przewiduje się, że wydatki na robotykę i drony wzrosną ze 115,7 mld USD w 2019 r. do 210,3 mld USD do 2022 r.2 Stanowi to łączną roczną stopę wzrostu na poziomie 20,2%. Około dwie trzecie wydatków będzie przeznaczone na systemy sprzętowe

**Co to jest robot?**

Początki słowa „robot" sięgają 1921 roku w sztuce Karela Capka zatytułowanej Rossum's Universal Robots. Chodzi o fabrykę, która stworzyła roboty z materii organicznej i tak, były wrogo nastawione! W końcu połączyłyby siły, by zbuntować się przeciwko swoim ludzkim panom (należy wziąć pod uwagę, że „robot" pochodzi od czeskiego słowa robata oznaczającego pracę przymusową). Ale na dzień dzisiejszy, jaka jest dobra definicja tego typu systemu? Pamiętaj, że istnieje wiele odmian, ponieważ roboty mogą mieć niezliczone formy i funkcje. Ale możemy je sprowadzić do kilku kluczowych części:

• Fizyczne: Robot może mieć różne rozmiary, od maleńkich maszyn, które mogą badać nasze ciało, przez ogromne systemy przemysłowe, po maszyny latające i podwodne statki. Potrzebny jest również jakiś rodzaj źródła energii, taki jak bateria, prąd lub energia słoneczna.

• Działaj: po prostu robot musi być w stanie wykonać określone czynności. Może to obejmować przenoszenie przedmiotu, a nawet rozmowę.

• Zmysł: aby działać, robot musi rozumieć swoje otoczenie. Jest to możliwe dzięki czujnikom i systemom sprzężenia zwrotnego.

• Inteligencja: nie oznacza to pełnych możliwości sztucznej inteligencji. Jednak robot musi być zaprogramowany do podejmowania działań.

W dzisiejszych czasach stworzenie robota od podstaw nie jest trudne. Na przykład RobotShop.com ma setki zestawów, które wahają się od 10 USD do nawet 35 750,00 USD (jest to Dr. Robot Jaguar V6 Tracked Mobile Platform). Podnosząca na duchu opowieść o pomysłowości budowania robotów dotyczy dwuletniego Cilliana Jacksona. Urodził się z rzadką chorobą genetyczną, która uniemożliwiała mu poruszanie się. Jego rodzice próbowali uzyskać zwrot kosztów za specjalny elektryczny wózek inwalidzki, ale odmówiono im. Cóż, uczniowie z Farmington High School podjęli działania i zbudowali system dla Cilliana. Zasadniczo był to robot-wózek inwalidzki, a ukończenie zajęło tylko miesiąc. Z tego

powodu Cillian może teraz ścigać swoje dwa corki po domu! Chociaż powyżej przyjrzeliśmy się cechom robotów, należy również wziąć pod uwagę kluczowe interakcje:

• Czujniki: Typowym czujnikiem jest kamera lub Lidar (wykrywanie światła i zasięg), który wykorzystuje skaner laserowy do tworzenia obrazów 3D. Ale roboty mogą mieć również systemy dźwiękowe, dotykowe, smakowe, a nawet zapachowe. W rzeczywistości mogą również obejmować czujniki wykraczające poza ludzkie możliwości, takie jak noktowizor lub wykrywanie chemikaliów. Te informacje z czujników przesyłane są do kontrolera, który może aktywować ramię lub inne części robota.

• Siłowniki: Są to urządzenia elektromechaniczne, takie jak silniki. W większości pomagają w ruchu ramion, nóg, głowy i każdej innej ruchomej części.

• Komputer: Pamięć masowa i procesory pomagają w odczytywaniu sygnałów wejściowych z czujników. W zaawansowanych robotach mogą również występować chipy AI lub połączenia internetowe z platformami AI w chmurze.

Istnieją również dwa główne sposoby obsługi robota. Przede wszystkim istnieje zdalne sterowanie przez człowieka. W tym przypadku robot nazywa się telerobotem. Jest też autonomiczny robot, który wykorzystuje własne zdolności do nawigacji - na przykład w przypadku sztucznej inteligencji. Jaki więc był pierwszy mobilny, myślący robot? To był Shakey. Nazwa była trafna, jak zauważył kierownik projektu systemu Charles Rosen: „Pracowaliśmy przez miesiąc starając się znaleźć dla niego dobrą nazwę, od greckich nazw do czegokolwiek, a potem jeden z nas powiedział: „Hej, trzęsie się jak diabli i porusza się, nazwijmy to po prostu Shakey". Stanford Research Institute (SRI), finansowany przez DARPA, pracował nad Shakeyem od 1966 do 1972. I był to dość wyrafinowany jak na tamte czasy. Shakey był duży, miał ponad pięć stóp wzrostu i miał koła do poruszania oraz czujniki i kamery, które pomagały w dotyku. Był również połączony bezprzewodowo z komputerami DEC PDP-10 i PDP-15. Stąd osoba mogła wprowadzać polecenia przez dalekopis. Chociaż Shakey używał algorytmów do poruszania się po swoim otoczeniu, nawet zamykając drzwi. Rozwój robota był wynikiem niezliczonych przełomów AI. Na przykład Nils Nilsson i Richard Fikes stworzyli STRIPS (Stanford Research Institute Problem Solver), który pozwolił na zautomatyzowane planowanie oraz algorytm A∗ do znajdowania najkrótszej ścieżki przy jak najmniejszych zasobach komputerowych. Pod koniec lat sześćdziesiątych, kiedy Ameryka koncentrowała się na programie kosmicznym, Shakey nabrał sporo zamieszania. Pochlebny artykuł w Life stwierdził, że robot był „pierwszą osobą elektroniczną". Ale niestety, w 1972 roku, gdy nastała zima AI, DARPA ściągnęła fundusze na Shakeya. Jednak robot nadal pozostanie kluczową częścią historii technologii i został wprowadzony do Galerii Sław Robotów w 2004 roku.

**Roboty przemysłowe i komercyjne**

Pierwsze zastosowanie robotów w świecie rzeczywistym miało związek z przemysłem produkcyjnym. Jednak wprowadzenie tych systemów zajęło trochę czasu. Historia zaczyna się od George'a Devola, wynalazcy, który nie ukończył szkoły średniej. Ale to nie był problem. Devol miał smykałkę do inżynierii i kreatywności, ponieważ tworzył niektóre z podstawowych systemów do kuchenek mikrofalowych, kodów kreskowych i drzwi automatycznych (w ciągu swojego życia uzyskał ponad 40 patentów). Na początku lat pięćdziesiątych otrzymał również patent na programowalnego robota o nazwie „Unimate". Starał się zainteresować swoim pomysłem, ponieważ wszyscy inwestorzy go odrzucili. Jednak w 1957 roku jego życie zmieniło się na zawsze, gdy na koktajlu poznał Josepha Engelbergera. Pomyśl o tym, jak wtedy, gdy Steve Jobs spotkał Steve'a Wozniaka, aby stworzyć komputer Apple. Engelberger był inżynierem, ale także bystrym biznesmenem. Uwielbiał nawet czytać science fiction, takie jak historie Isaaca Asimova. Z tego powodu Engelberger chciał, aby Unimate przyniosło korzyści społeczeństwu. Mimo to nadal był opór - ponieważ wielu ludzi uważało, że pomysł jest nierealny i, no

cóż, science fiction - i uzyskanie finansowania zajęło rok. Ale kiedy Engelberger to zrobił, stracił niewiele czasu na zbudowanie robota i był w stanie sprzedać go do General Motors (GM) w 1961 roku. Unimate był nieporęczny (waży 2700 funtów) i miał jedno ramię o długości 7 stóp, ale nadal był całkiem użyteczny a także oznaczało, że ludzie nie będą musieli wykonywać z natury niebezpiecznych czynności. Niektóre z jego podstawowych funkcji obejmowały spawanie, natryskiwanie i chwytanie - wszystko wykonywane dokładnie i 24 godziny na dobę, 7 dni w tygodniu. Engelberger szukał kreatywnych sposobów na ewangelizację swojego robota. W tym celu pojawił się w The Tonight Show Johnny'ego Carsona w 1966 roku, w którym Unimate perfekcyjnie umieścił piłeczkę golfową, a nawet nalał piwa. Johnny żartował, że maszyna może „zastąpić czyjąś pracę". Ale roboty przemysłowe miały swoje dokuczliwe problemy. Co ciekawe, GM nauczył się tego na własnej skórze w latach 80-tych. W tamtym czasie dyrektor generalny Roger Smith promował wizję fabryki „zgaszonych świateł" - czyli miejsca, w którym roboty mogłyby budować samochody w ciemności! Następnie wyłożył na program aż 90 miliardów dolarów, a nawet stworzył spółkę joint venture z Fujitsu-Fanuc o nazwie GMF Robotics. Organizacja stałaby się największym na świecie producentem robotów. Niestety przedsięwzięcie okazało się katastrofą. Oprócz obciążania związków, roboty często nie spełniały oczekiwań. Tylko niektóre z fiask dotyczyły robotów, które zaspawały drzwi lub same się pomalowały – nie samochody! Jednak sytuacja GMF nie jest niczym nowym – i niekoniecznie dotyczy to kierowanych w błąd menedżerów wyższego szczebla. Spójrz na Teslę, która jest jedną z najbardziej innowacyjnych firm na świecie. Ale dyrektor generalny Elon Musk nadal miał poważne problemy z robotami w swoich fabrykach. Problemy stały się tak poważne, że egzystencja Tesli była zagrożona. W wywiadzie dla CBS This Morning w kwietniu 2018 r. Musk powiedział, że podczas produkcji Modelu 3 używał zbyt wielu robotów, co w rzeczywistości spowolniło proces. Zauważył, że powinien zaangażować więcej osób. Wszystko to wskazuje na to, co napisał kiedyś Hans Moravec: „Porównywalnie łatwo jest sprawić, by komputery w testach na inteligencję lub grając w warcaby wykazywały wyniki na poziomie osoby dorosłej, a trudne lub niemożliwe jest nadanie im umiejętności rocznego dziecka, jeśli chodzi o percepcję i mobilność.". Nazywa się to często paradoksem Moraveca. Niezależnie od tego roboty przemysłowe stały się ogromną gałęzią przemysłu, rozwijając się w różnych segmentach, takich jak dobra konsumpcyjne, biotechnologia/opieka zdrowotna i tworzywa sztuczne. Według danych Robotic Industries Association (RIA) w 2018 r. w Ameryce Północnej wysłano 35 880 robotów przemysłowych i komercyjnych11. Na przykład przemysł motoryzacyjny stanowił około 53%, ale liczba ta spada. Jeff Burnstein, prezes Association for Advancing Automation, miał to do powiedzenia:

A jak słyszeliśmy od naszych członków i na pokazach takich jak Automate, te sprzedaże i wysyłki nie dotyczą już tylko dużych, międzynarodowych firm. Małe i średnie firmy używają robotów do rozwiązywania rzeczywistych wyzwań, co pomaga im być bardziej konkurencyjnymi w skali globalnej . Jednocześnie nadal spadają koszty produkcji robotów przemysłowych. W oparciu o badania przeprowadzone przez ARK, do 2025 r. nastąpi 65% redukcja – z urządzeniami średnio za mniej niż 11 000 USD każdy. Analiza opiera się na prawie Wrighta, które stanowi, że każde skumulowane podwojenie liczby wyprodukowanych jednostek powoduje stały spadek kosztów w ujęciu procentowym. OK, a co ze sztuczną inteligencją i robotami? Gdzie jest ten status technologii? Mimo przełomów w zakresie głębokiego uczenia się, ogólnie rzecz biorąc, postępy w korzystaniu ze sztucznej inteligencji w robotach są powolne. Częściowo wynika to z faktu, że wiele badań koncentrowało się na modelach opartych na oprogramowaniu, takich jak rozpoznawanie obrazu. Ale innym powodem jest to, że fizyczne roboty wymagają zaawansowanych technologii, aby zrozumieć otoczenie – które często jest hałaśliwe i rozpraszające – w czasie rzeczywistym. Wiąże się to z umożliwieniem jednoczesnej lokalizacji i mapowania (SLAM) w nieznanych środowiskach przy jednoczesnym śledzeniu lokalizacji robota. Aby to zrobić skutecznie, może być nawet konieczne stworzenie nowych technologii, takich jak lepsze algorytmy sieci neuronowych i komputery kwantowe. Mimo to z pewnością poczyniono

postępy, zwłaszcza przy użyciu technik uczenia się przez wzmacnianie. Rozważ niektóre z następujących innowacji:

• Osaro: Firma opracowuje systemy, które umożliwiają robotom szybką naukę. Osaro opisuje to jako „zdolność do naśladowania zachowań, które wymagają wyuczonej fuzji czujników, a także planowania na wysokim poziomie i manipulacji obiektami. Umożliwi również uczenie się od jednej maszyny do drugiej i poprawę poza spostrzeżeniami ludzkiego programisty". Na przykład jeden z robotów był w stanie nauczyć się w ciągu zaledwie pięciu sekund, jak podnosić i układać kurczaka (system ma być używany w fabrykach drobiu). Ale technologia może mieć wiele zastosowań, takich jak drony, pojazdy autonomiczne i IoT (Internet of Things).

• OpenAI: Stworzyli Dactyl, czyli rękę robota o ludzkiej zręczności. Opiera się to na wyrafinowanym treningu symulacji, a nie na rzeczywistych interakcjach. OpenAI nazywa to „randomizacją domeny", co przedstawia robotowi wiele scenariuszy — nawet tych, które mają bardzo małe prawdopodobieństwo wystąpienia. Dzięki Dactyl symulacje obejmowały około 100 lat rozwiązywania problemów. Jednym z zaskakujących wyników było to, że system nauczył się czynności ludzkiej ręki, które nie były wcześniej zaprogramowane – takich jak przesuwanie palca. Dactyl również został przeszkolony, aby radzić sobie z niedoskonałością informacji, np. kiedy czujniki mają opóźnione odczyty lub kiedy istnieje potrzeba obsługi wielu obiektów.

• MIT: Robot może z łatwością pobrać tysiące próbek danych, aby zrozumieć jego otoczenie, na przykład wykryć coś tak prostego jak kubek. Ale według artykułu badawczego profesorów z MIT może istnieć sposób na zmniejszenie tego. Wykorzystali sieć neuronową, która skupiała się tylko na kilku kluczowych funkcjach. Badania są wciąż na wczesnym etapie, ale mogą mieć duży wpływ na roboty.

• Google: Począwszy od 2013 r. firma przeprowadziła serię fuzji i przejęć (fuzje i przejęcia) firm zajmujących się robotyką. Ale wyniki były rozczarowujące. Mimo to nie zrezygnował z biznesu. W ciągu ostatnich kilku lat Google skupiło się na dążeniu do prostszych robotów napędzanych przez sztuczną inteligencję, a firma stworzyła nowy dział o nazwie Robotics at Google. Na przykład jeden z robotów może spojrzeć na pojemnik z przedmiotami i zidentyfikować ten, o który prosił – podnosząc go ręką o trzech palcach – w około 85% przypadków. Z drugiej strony typowa osoba była w stanie to zrobić w około 80%

Czy to wszystko wskazuje na całkowitą automatyzację? Prawdopodobnie nie - przynajmniej w dającej się przewidzieć przyszłości. Należy pamiętać, że głównym trendem jest rozwój cobotów. To roboty, które współpracują z ludźmi. Podsumowując, staje się to podejściem o wiele potężniejszym, ponieważ można wykorzystać zalety zarówno maszyn, jak i ludzi. Zauważ, że jednym z głównych liderów w tej kategorii jest Amazon.com. W 2012 roku firma wyłożyła 775 milionów dolarów dla Kiva, czołowego producenta robotów przemysłowych. Od tego czasu Amazon.com wdrożył około 100 000 systemów w ponad 25 centrach logistycznych (z tego powodu firma odnotowała 40% poprawę pojemności zapasów). Firma tak to opisuje: Amazon Robotics automatyzuje operacje centrum logistycznego przy użyciu różnych metod technologii robotycznej, w tym autonomicznych robotów mobilnych, zaawansowanego oprogramowania sterującego, percepcji języka, zarządzania energią, wizji komputerowej, wykrywania głębi, uczenia maszynowego, rozpoznawania obiektów i zrozumienia semantycznego poleceń. W magazynach roboty szybko poruszają się po podłodze, pomagając zlokalizować i podnieść zasobniki magazynowe. Ale ludzie są również krytyczni, ponieważ są w stanie lepiej zidentyfikować i wybrać poszczególne produkty. Jednak konfiguracja jest bardzo skomplikowana. Na przykład pracownicy magazynu noszą kamizelki Robotic Tech, aby nie zostać zmiażdżonym przez roboty! Ta technologia umożliwia robotowi identyfikację osoby. Ale są też inne problemy z cobotami. Na przykład istnieje realna obawa, że w końcu pracownicy zostaną zastąpieni przez maszyny. Co więcej,

naturalne jest, że ludzie czują się jak przysłowiowy trybik w kole, co może oznaczać niższe morale. Czy ludzie naprawdę mogą nawiązać więź z robotami? Chyba nie, zwłaszcza robotów przemysłowych, które tak naprawdę nie mają cech ludzkich.

**Roboty w prawdziwym świecie**

OK, przyjrzyjmy się teraz innym interesującym przypadkom użycia robotów przemysłowych i komercyjnych.

**Przypadek użycia: bezpieczeństwo**

Zarówno Erik Schluntz, jak i Travis Deyle mają rozległe doświadczenie w branży robotycznej, pracując w firmach takich jak Google i SpaceX. W 2016 roku chcieli rozpocząć własne przedsięwzięcie, ale najpierw spędzili sporo czasu, próbując znaleźć zastosowanie technologii w świecie rzeczywistym, co wymagało rozmów z wieloma firmami. Schluntz i Deyle znaleźli jeden wspólny temat: potrzebę fizycznego zabezpieczenia obiektów. Jak roboty mogą zapewnić ochronę po godzinie 17:00 - bez konieczności wydawania dużych kwot na ochroniarzy? Zaowocowało to uruchomieniem Cobalt Robotics. Czas był trafiony ze względu na konwergencję technologii, takich jak wizja komputerowa, uczenie maszynowe i oczywiście postępy w robotyce. Chociaż korzystanie z tradycyjnej technologii bezpieczeństwa jest skuteczne - powiedzmy w przypadku kamer i czujników - są one statyczne i niekoniecznie dobre dla reakcji w czasie rzeczywistym. Ale dzięki robotowi można być znacznie bardziej proaktywnym ze względu na mobilność i inteligencję leżącą u podstaw. Jednak ludzie nadal są w pętli. Roboty mogą wtedy robić to, w czym są dobre, takie jak przetwarzanie i wykrywanie danych 24/7, a ludzie mogą skupić się na krytycznym myśleniu i rozważaniu alternatyw. Oprócz technologii, Cobalt jest innowacyjny dzięki swojemu modelowi biznesowemu, który nazywa Robotics as a Service (RaaS). Pobierając abonament, urządzenia te są znacznie bardziej przystępne dla klientów.

**Przypadek użycia: roboty do szorowania podłóg**

Prawdopodobnie zobaczymy niektóre z najciekawszych zastosowań robotów w kategoriach, które są dość przyziemne. Z drugiej strony maszyny te są naprawdę dobre w obsłudze powtarzalnych procesów. Spójrz na Brain Corp, który został założony w 2009 roku przez dr Eugene Izhikevicha i dr Allena Grubera. Początkowo opracowali swoją technologię dla Qualcomm i DARPA. Ale od tego czasu Brain zaczął wykorzystywać uczenie maszynowe i wizję komputerową w samojezdnych robotach. W sumie firma zebrała 125 milionów dolarów od inwestorów takich jak Qualcomm i SoftBank. Sztandarowym robotem Brain jest Auto-C, który skutecznie szoruje podłogi. Dzięki systemowi AI o nazwie BrainOS (który jest połączony z chmurą) maszyna jest w stanie autonomicznie poruszać się w złożonych środowiskach. Odbywa się to poprzez naciśnięcie przycisku, a następnie Auto-C szybko mapuje trasę. Pod koniec 2018 r. Brain zawarł umowę z Walmartem na wprowadzenie 1500 robotów Auto-C w setkach sklepów. Firma wdrożyła również roboty na lotniskach i w centrach handlowych. Ale to nie jedyny robot pracujący dla Walmart. Firma instaluje również maszyny, które mogą skanować półki, aby pomóc w zarządzaniu zapasami. Z około 4600 sklepami w Stanach Zjednoczonych roboty prawdopodobnie będą miały duży wpływ na sprzedawcę.

**Przypadek użycia: Apteka internetowa**

Jako farmaceuta drugiej generacji, TJ Parker miał bezpośrednie doświadczenie z frustracjami, jakie odczuwali ludzie, gdy zarządzali swoimi receptami. Zastanawiał się więc: czy rozwiązaniem byłoby stworzenie cyfrowej apteki? Był przekonany, że odpowiedź brzmi tak. Ale chociaż miał mocne doświadczenie w branży, potrzebował solidnego współzałożyciela ds. technologii, którego znalazł w osobie Elliota Cohena, inżynierze MIT. W 2013 r. stworzyli PillPack. Celem było ponowne wyobrażenie

sobie doświadczeń klientów. Korzystając z aplikacji lub przechodząc na stronę internetową PillPack, użytkownik mógł łatwo zarejestrować się – na przykład wprowadzić informacje o ubezpieczeniu, wprowadzić potrzeby związane z receptami i zaplanować dostawy. Gdy użytkownik otrzymał opakowanie, zawierał szczegółowe informacje o instrukcjach dawkowania, a nawet zdjęcia każdej pigułki. Ponadto każda z pigułek zawierała etykiety i była wstępnie sortowana w pojemnikach. Aby to wszystko stało się rzeczywistością, potrzebna była wyrafinowana infrastruktura technologiczna o nazwie PharmacyOS. Opierał się również na sieci robotów, które znajdowały się w magazynie o powierzchni 80 000 stóp kwadratowych. Dzięki temu system mógł sprawnie sortować i pakować recepty. Ale placówka miała również licencjonowanych farmaceutów do zarządzania procesem i upewniania się, że wszystko jest zgodne. W czerwcu 2018 r. Amazon.com wyłożył około 1 miliarda dolarów na PillPack. W wiadomościach akcje firm takich jak CVS i Walgreens spadły w obawie, że gigant e-commerce przygotowuje się do odegrania dużej roli na rynku opieki zdrowotnej.

**Przypadek użycia: Roboty-naukowcy**

Opracowywanie leków na receptę jest niezwykle kosztowne. Według badań przeprowadzonych przez Tufts Center for the Study of Drug Development, średnia wynosi około 2,6 miliarda dolarów na zatwierdzony związek. Ponadto wprowadzenie nowego leku na rynek może z łatwością zająć ponad dekadę ze względu na uciążliwe przepisy. Jednak zastosowanie wyrafinowanych robotów i głębokiego uczenia się może pomóc. Aby zobaczyć, jak to zrobić, spójrz na to, co zrobili naukowcy z uniwersytetów w Aberystwyth i Cambridge. W 2009 roku wypuścili Adama, który był zasadniczo naukowcem-robotem, który pomagał w procesie odkrywania leków. Kilka lat później wypuścili na rynek Eve, robota nowej generacji. System może stawiać hipotezy i testować je, a także przeprowadzać eksperymenty. Ale w tym procesie nie chodzi tylko o obliczenia metodą brute-force (system może przeszukiwać ponad 10 000 związków dziennie). Dzięki głębokiemu uczeniu Eve jest w stanie wykorzystać inteligencję, aby lepiej zidentyfikować związki o największym potencjale. Udało się na przykład wykazać, że triklosan – powszechny składnik pasty do zębów, który zapobiega gromadzeniu się płytki nazębnej – może być skuteczny w walce z rozwojem pasożytów w malarii. Jest to szczególnie ważne, ponieważ choroba staje się coraz bardziej odporna na istniejące terapie.

**Roboty humanoidalne i konsumenckie**

Popularna kreskówka, The Jetsons, ukazała się na początku lat 60. i miała świetną obsadę postaci. Jedną z nich była Rosie, pokojówka-robot, która zawsze miała w ręku odkurzacz. Kto by nie chciał czegoś takiego? Ja tak. Ale nie oczekuj, że coś takiego jak Rosie przyjdzie do domu w najbliższym czasie. Jeśli chodzi o roboty konsumenckie, wciąż jesteśmy na początku. Innymi słowy, zamiast tego widzimy roboty, które mają tylko niektóre ludzkie cechy. Oto godne uwagi przykłady:

• Sophia: Opracowany przez firmę Hanson Robotics z Hongkongu, prawdopodobnie najbardziej znany. W rzeczywistości pod koniec 2017 roku Arabia Saudyjska przyznała jej obywatelstwo! Sophia, która ma postać Audrey Hepburn, może chodzić i mówić. Ale w jej działaniach są też subtelności, takie jak utrzymywanie kontaktu wzrokowego.

• Atlas: Deweloperem jest firma Boston Dynamics, która uruchomiła go latem 2013 roku. Bez wątpienia firma Atlas z biegiem lat znacznie się poprawiła. Może na przykład wykonywać backflipy i podnosić się, gdy spada.

• Pepper: To humanoidalny robot stworzony przez SoftBank Robotics, który koncentruje się na obsłudze klienta, np. w punktach sprzedaży detalicznej. Maszyna może używać gestów - aby poprawić komunikację - a także może mówić w wielu językach.

W miarę jak technologie humanoidalne stają się bardziej realistyczne i zaawansowane, nieuchronnie nastąpią zmiany w społeczeństwie. Normy społeczne dotyczące miłości i przyjaźni będą ewoluować. W końcu, jak widać z wszechobecności smartfonów, już widzimy, jak technologia może zmienić sposób, w jaki odnosimy się do ludzi, powiedzmy poprzez pisanie SMS-ów i angażowanie się w media społecznościowe. Według ankiety przeprowadzonej wśród Millenialsów z Tappable, blisko 10% wolałoby poświęcić mały palec niż zrezygnować ze smartfona! Jeśli chodzi o roboty, możemy zobaczyć coś podobnego. Chodzi o roboty społeczne. Taka maszyna - która jest realistyczna, z realistycznymi funkcjami i sztuczną inteligencją - może ostatecznie stać się jak, cóż, przyjacielem, a nawet… kochankiem. To prawda, że prawdopodobnie nastąpi to w odległej przyszłości. Ale na razie z pewnością istnieją pewne interesujące innowacje dotyczące robotów społecznościowych. Jednym z przykładów jest ElliQ, który obejmuje tablet i małą głowicę robota. W większości są to osoby żyjące samotnie, takie jak osoby starsze. ElliQ potrafi mówić, ale także zapewnia nieocenioną pomoc, na przykład przypominanie o zażyciu leków. System umożliwia również prowadzenie rozmów wideo z członkami rodziny. Jednak roboty społeczne mają z pewnością wady. Wystarczy spojrzeć na okropną sytuację Jibo. Firma, która zebrała 72,7 miliona dolarów w funduszach venture, stworzyła pierwszego robota społecznego do domu. Ale było wiele problemów, takich jak opóźnienia produktów i atak podróbek. Z tego powodu Jibo ogłosiło upadłość w 2018 roku, a do kwietnia następnego roku serwery zostały zamknięte. Nie trzeba dodawać, że było wielu zniechęconych właścicieli Jibo, o czym świadczą liczne posty na Reddit

**Trzy prawa robotyki**

Isaac Asimov, płodny pisarz zajmujący się wieloma różnymi tematami, takimi jak science fiction, historia, chemia i Szekspir, również miałby duży wpływ na roboty. W opowiadaniu, które napisał w 1942 roku („Runaround"), przedstawił swoje trzy prawa robotyki:

1.Robot nie może skrzywdzić człowieka, ani przez zaniechanie działania dopuścić, aby człowiek doznał krzywdy.

2.Robot musi być posłuszny rozkazom człowieka, chyba że stoją one w sprzeczności z Pierwszym Prawem.

3.Robot musi chronić samego siebie, o ile tylko nie stoi to w sprzeczności z Pierwszym lub Drugim Prawem.

Asimov później dodał jeszcze jedno, prawo Zerotha, które stwierdzało: „Robot nie może szkodzić ludzkości lub, przez bezczynność, pozwolić ludzkości wyrządzić krzywdę". Uważał to prawo za najważniejsze.

Asimov pisałby więcej opowiadań, które odzwierciedlałyby, jak prawa działają w złożonych sytuacjach, i zostałyby zebrane w książce zatytułowanej „Ja, Robot". Wszystko to miało miejsce w świecie XXI wieku. Trzy prawa reprezentowały reakcję Asimova na to, jak science fiction przedstawia roboty jako wrogie. Ale uważał, że to nierealne. Asimov przewidywał, że pojawią się zasady etyczne kontroli mocy robotów. W tej chwili wizja Asimova staje się bardziej realna – innymi słowy, dobrym pomysłem jest zbadanie zasad etycznych. To prawda, że niekoniecznie oznacza to, że jego podejście jest właściwe. Ale to dobry początek, zwłaszcza że roboty stają się mądrzejsze i bardziej osobiste dzięki sile sztucznej inteligencji.

**Cyberbezpieczeństwo i roboty**

Cyberbezpieczeństwo nie stanowiło większego problemu w przypadku robotów. Ale niestety nie będzie to trwało długo. Głównym powodem jest to, że coraz częściej roboty łączą się z chmurą. To

samo dotyczy innych systemów, takich jak Internet Rzeczy czy IoT oraz samochodów autonomicznych. Na przykład wiele z tych systemów jest aktualizowanych bezprzewodowo, co naraża je na złośliwe oprogramowanie, wirusy, a nawet okupy. Ponadto w przypadku pojazdów elektrycznych istnieje również podatność na ataki z sieci ładowania. W rzeczywistości Twoje dane mogą pozostać w pojeździe! Jeśli więc zostanie zniszczony lub sprzedasz go, informacje - na przykład wideo, szczegóły nawigacji i kontakty ze sparowanych połączeń ze smartfonami - mogą stać się dostępne dla innych osób. Według CNBC.com hakerowi w białym kapeluszu, zwanym GreenTheOnly, udało się wydobyć te dane z różnych modeli Tesli na złomowiskach. Należy jednak pamiętać, że firma udostępnia opcje usuwania danych i można zrezygnować z gromadzenia danych (ale oznacza to brak pewnych korzyści, takich jak aktualizacje OTA). Teraz, jeśli dojdzie do naruszenia bezpieczeństwa cybernetycznego przez robota, konsekwencje mogą być z pewnością druzgocące. Wyobraź sobie, że haker zinfiltrował linię produkcyjną lub łańcuch dostaw, a nawet zrobotyzowany system chirurgiczny. Życie może być zagrożone. Niezależnie od tego w cyberbezpieczeństwo robotów nie zainwestowano zbyt wiele. Jak dotąd jest tylko garstka firm, takich jak Karamba Security i Cybereason, które koncentrują się na tym. Jednak wraz z nasilaniem się problemów nieuchronnie nastąpi wzrost inwestycji ze strony VC i nowych inicjatyw ze strony starszych firm zajmujących się cyberbezpieczeństwem.

**Programowanie robotów dla AI**

Tworzenie inteligentnych robotów jest coraz łatwiejsze, ponieważ systemy stają się coraz tańsze i pojawiają się nowe platformy oprogramowania. Duża w tym zasługa Robot Operating System (ROS), który staje się standardem w branży. Początki sięgają 2007 roku, kiedy platforma rozpoczęła się jako projekt open source w Stanford Artificial Intelligence Laboratory. Pomimo swojej nazwy, ROS tak naprawdę nie jest prawdziwym systemem operacyjnym. Zamiast tego jest to oprogramowanie pośredniczące, które pomaga zarządzać wieloma krytycznymi częściami robota: planowaniem, symulacjami, mapowaniem, lokalizacją, percepcją i prototypami. ROS jest również modułowy, ponieważ możesz łatwo wybrać i wybrać potrzebne funkcje. W rezultacie system może łatwo skrócić czas opracowywania. Kolejna zaleta: ROS ma globalną społeczność użytkowników. Weź pod uwagę, że platforma zawiera ponad 3000 pakietów. Jako świadectwo sprawności ROS, Microsoft ogłosił pod koniec 2018 roku, że wyda wersję dla systemu operacyjnego Windows. Zgodnie z wpisem na blogu Lou Amadio, głównego inżyniera oprogramowania Windows IoT, „Ponieważ roboty się rozwinęły, rozwinęły się również narzędzia programistyczne. Postrzegamy robotykę ze sztuczną inteligencją jako powszechnie dostępną technologię, która zwiększa ludzkie zdolności". W rezultacie ROS może być używany z Visual Studio i będzie połączoy z chmurą Azure, która obejmuje narzędzia AI. OK, więc jeśli chodzi o opracowywanie inteligentnych robotów, często istnieje inny proces niż w przypadku typowego podejścia z AI opartą na oprogramowaniu. Oznacza to, że musi istnieć nie tylko fizyczne urządzenie, ale także sposób na jego przetestowanie. Często odbywa się to za pomocą symulacji. Niektórzy programiści zaczną nawet tworzyć modele kartonowe, co może być świetnym sposobem na zrozumienie wymagań fizycznych. Ale oczywiście są też przydatne wirtualne symulatory, takie jak MuJoCo, Gazebo, MORSE i V-REP. Systemy te wykorzystują wyrafinowaną grafikę 3D do radzenia sobie z ruchami i fizyką świata rzeczywistego. Jak więc tworzyć modele AI dla robotów? W rzeczywistości niewiele różni się od podejścia z algorytmami opartymi na oprogramowaniu. Zaletą robota jest jednak to, że będzie on nadal zbierać dane ze swoich czujników, co może pomóc w rozwoju sztucznej inteligencji. Chmura staje się również kluczowym czynnikiem w rozwoju inteligentnych robotów, jak widać na Amazon.com. Firma wykorzystała swoją niezwykle popularną platformę AWS z nową ofertą o nazwie AWS RoboMaker. Korzystając z tego, możesz budować, testować i wdrażać roboty bez dużej konfiguracji. AWS RoboMaker działa na ROS, a także umożliwia korzystanie z usług uczenia maszynowego, analityki i monitorowania. Istnieją nawet gotowe wirtualne światy 3D dla sklepów detalicznych, pomieszczeń wewnętrznych i torów wyścigowych! Następnie, gdy skończysz z robotem,

możesz użyć AWS do opracowania systemu bezprzewodowego (OTA) do bezpiecznego wdrażania i okresowych aktualizacji. I nie powinno dziwić, że Google planuje wypuścić własną platformę robota w chmurze

**Przyszłość robotów**

Rodney Brooks to jeden z gigantów branży robotycznej. W 1990 roku był współzałożycielem iRobot, aby znaleźć sposoby na komercjalizację technologii. Ale nie było to łatwe. Dopiero w 2002 roku firma wprowadziła na rynek robota odkurzającego Roomba, który był wielkim hitem wśród konsumentów. W chwili pisania tego tekstu iRobot ma wartość rynkową 3,2 miliarda dolarów i wygenerował ponad 1 miliard dolarów przychodów w 2018 roku. Ale iRobot nie był jedynym start-upem dla Brooksa. Pomógł również uruchomić Rethink Robotics – a jego wizja była ambitna. Oto jak to ujął w 2010 roku, kiedy jego firma ogłosiła finansowanie w wysokości 20 milionów dolarów:

Nasze roboty będą intuicyjne w obsłudze, inteligentne i wysoce elastyczne. Będą łatwe do kupienia, przeszkolenia i wdrożenia oraz będą niewiarygodnie niedrogie. [Rethink Robotics] zmieni definicję tego, jak i gdzie można używać robotów, radykalnie rozszerzając rynek robotów.

Ale niestety, podobnie jak w przypadku iRobota, było wiele wyzwań. Mimo że pomysł Brooka na coboty był pionierski – i ostatecznie okazał się lukratywnym rynkiem – musiał zmagać się z komplikacjami budowania skutecznego systemu. Skupienie się na bezpieczeństwie oznaczało, że precyzja i dokładność nie spełniały standardów klientów przemysłowych. Z tego powodu żądanie by roboty Rethink były chłodne. Do października 2018 roku firmie zabrakło gotówki i musiała zamknąć swoje podwoje. W sumie Rethink zebrał blisko 150 milionów dolarów od VC i inwestorów strategicznych, takich jak Goldman Sachs, Sigma Partners, GE i Bezos Expeditions. Własność intelektualna firmy została sprzedana niemieckiej firmie automatyzacyjnej HAHN Group. To prawda, to tylko jeden przykład. Ale z drugiej strony pokazuje, że nawet najmądrzejsi technicy mogą się pomylić. A co ważniejsze, rynek robotyki charakteryzuje się wyjątkową złożonością. Jeśli chodzi o ewolucję tej kategorii, postęp może być niestabilny i niestabilny. Jak zauważył Schluntz z firmy Cobalt: Podczas gdy branża poczyniła postępy w ciągu ostatniej dekady, robotyka nie wykorzystała jeszcze swojego pełnego potencjału. Każda nowa technologia stworzy falę wielu nowych firm, ale tylko nieliczne przetrwają i przekształcą się w trwałe biznesy. Popiersie Dot-Com zabiło większość firm internetowych, ale przetrwały Google, Amazon i Netflix. To, co muszą zrobić firmy zajmujące się robotyką, to otwarcie informować o tym, co ich roboty mogą dziś zrobić dla klientów, przełamać hollywoodzkie stereotypy o robotach jako złoczyńcach i pokazać klientom wyraźny ROI (zwrot z inwestycji).

**Wniosek**

Do ostatnich kilku lat roboty były przeznaczone głównie do produkcji wysokiej jakości, na przykład do samochodów. Jednak wraz z rozwojem sztucznej inteligencji i niższymi kosztami urządzeń budowlanych roboty stają się coraz bardziej rozpowszechnione w wielu branżach. Jak widać w tym rozdziale, istnieją interesujące przypadki użycia robotów, które robią takie rzeczy jak czyszczenie podłóg lub zapewniają bezpieczeństwo obiektów. Jednak wykorzystanie sztucznej inteligencji w robotyce jest wciąż w początkowej fazie. Programowanie systemów sprzętowych nie jest łatwe, a do nawigacji w środowiskach potrzebne są zaawansowane systemy. Jednak dzięki podejściom AI, takim jak uczenie się przez wzmacnianie, nastąpił przyspieszony postęp. Ale kiedy myślisz o używaniu robotów, ważne jest, aby zrozumieć ograniczenia. Musi być też jasny cel. Jeśli nie, wdrożenie może łatwo doprowadzić do kosztownej awarii. Nawet niektóre z najbardziej innowacyjnych firm na świecie, takie jak Google i Tesla, miały problemy z pracą z robotami.

**Kluczowe dania na wynos**

• Robot może podejmować działania, wyczuwać otoczenie i mieć pewien poziom inteligencji. Istnieją również kluczowe funkcje, takie jak czujniki, siłowniki (takie jak silniki) i komputery.

• Istnieją dwa główne sposoby obsługi robota: telerobota (sterowany przez człowieka) i robota autonomicznego (opartego na systemach AI).

• Tworzenie robotów jest niezwykle skomplikowane. Nawet niektórzy z najlepszych technologów na świecie, tacy jak Elon Musk z Tesli, mieli poważne problemy z tą technologią. Kluczowym powodem jest paradoks Moraveca. Zasadniczo to, co łatwe dla ludzi, często jest trudne dla robotów i na odwrót.

• Chociaż sztuczna inteligencja wywiera wpływ na roboty, proces ten przebiega powoli. Jednym z powodów jest większy nacisk na technologie oparte na oprogramowaniu. Ale również roboty są niezwykle skomplikowane, jeśli chodzi o poruszanie się i zrozumienie otoczenia.

• Coboty to maszyny współpracujące z ludźmi. Chodzi o to, że pozwoli to na wykorzystanie zalet zarówno maszyn, jak i ludzi.

• Koszty robotów są głównym powodem braku adopcji. Jednak innowacyjne firmy, takie jak Cobalt Robotics, korzystają z nowych modeli biznesowych, takich jak subskrypcje.

• Roboty konsumenckie są nadal w początkowej fazie, zwłaszcza w porównaniu z robotami przemysłowymi. Ale jest kilka interesujących przypadków użycia, na przykład z maszynami, które mogą być towarzyszami dla ludzi.

• W latach pięćdziesiątych pisarz science fiction Isaac Asimov stworzył trzy prawa robotyki. W większości skupili się na upewnieniu się, że maszyny nie zaszkodzą ludziom ani społeczeństwu. Pomimo krytyki podejścia Asimova, nadal są one powszechnie akceptowane.

• Bezpieczeństwo generalnie nie było problemem w przypadku robotów. Ale to się prawdopodobnie zmieni – i to szybko. W końcu do chmury podłączonych jest więcej robotów, co pozwala na wtargnięcie wirusów i złośliwego oprogramowania.

• Robot Operating System (ROS) stał się standardem w branży robotyki. To oprogramowanie pośredniczące pomaga w planowaniu, symulacjach, mapowaniu, lokalizacji, percepcji i prototypach.

• Tworzenie inteligentnych robotów wiąże się z wieloma wyzwaniami ze względu na potrzebę tworzenia systemów fizycznych. Istnieją jednak narzędzia, które mogą w tym pomóc, na przykład umożliwiające wyrafinowane symulacje.

**Wdrożenie AI**

**Wprowadzenie zmian dla Twojej firmy**

W marcu 2019 r. strzelec transmitował na żywo na Facebooku swoje brutalne zabójstwo 50 osób w dwóch meczetach w Nowej Zelandii. Został obejrzany około 4000 razy i został wyłączony dopiero 29 minut po ataku. Film został następnie przesłany na inne platformy i obejrzany miliony razy. Tak, to był wyraźny przykład tego, jak sztuczna inteligencja może zawieść w okropny sposób. W poście na blogu wiceprezes Facebooka ds. zarządzania produktami, Guy Rosen, zauważył:

Systemy są oparte na „danych treningowych", co oznacza, że potrzebujesz wielu tysięcy przykładów treści, aby wytrenować system, który potrafi wykrywać określone rodzaje tekstu, obrazów lub wideo. Takie podejście sprawdziło się bardzo dobrze w obszarach takich jak nagość, propaganda terrorystyczna, a także przemoc graficzna, gdzie istnieje wiele przykładów, które możemy wykorzystać do trenowania naszych systemów. Jednak ten konkretny film nie uruchomił naszych automatycznych systemów wykrywania. Aby to osiągnąć, będziemy musieli dostarczać naszym systemom duże ilości danych o tym konkretnym rodzaju treści, co jest trudne, ponieważ na szczęście takie zdarzenia zdarzają się rzadko. Kolejnym wyzwaniem jest automatyczne odróżnienie tej zawartości od wizualnie podobnej, nieszkodliwej zawartości — na przykład, jeśli tysiące filmów z gier wideo transmitowanych na żywo są oznaczone przez nasze systemy, nasi recenzenci mogą przegapić ważne filmy z prawdziwego świata, w których moglibyśmy ostrzec ratowników, aby uzyskać pomoc w terenie.

Nie pomogło również to, że byli różni źli aktorzy, którzy ponownie przesłali edytowane wersje wideo, aby udaremnić system sztucznej inteligencji Facebooka. Oczywiście była to wielka lekcja na temat braków w technologii, a firma twierdzi, że jest zaangażowana w ciągłe ulepszanie swoich systemów. Jednak studium przypadku Facebooka podkreśla również, że nawet najbardziej zaawansowane technologicznie firmy stoją przed poważnymi wyzwaniami. Dlatego jeśli chodzi o wdrażanie sztucznej inteligencji, konieczne jest solidne planowanie, a także zrozumienie, że nieuchronnie pojawią się problemy. Jednak może to być trudne, ponieważ menedżerowie wyższego szczebla w firmach są pod presją, aby uzyskać wyniki z tej technologii. Przyjrzymy się niektórym najlepszym praktykom dotyczącym implementacji sztucznej inteligencji.

**Podejścia do wdrażania AI**

Korzystanie ze sztucznej inteligencji w firmie zazwyczaj obejmuje dwa podejścia: korzystanie z oprogramowania dostawcy lub tworzenie modeli wewnętrznych. Ten pierwszy jest najbardziej rozpowszechniony – i może wystarczyć dla dużej liczby firm. Ironia polega na tym, że możesz już korzystać z oprogramowania, na przykład z Salesforce.com, Microsoft, Google, Workday, Adobe lub SAP, które ma już potężne możliwości sztucznej inteligencji. Innymi słowy, dobrym podejściem jest upewnienie się, że w pełni je wykorzystujesz. Aby zobaczyć, co jest dostępne, spójrz na Einstein Salesforce.com, który został uruchomiony we wrześniu 2016. Ten system AI jest płynnie wbudowany w główną platformę CRM (Customer Relationship Management), umożliwiając bardziej predykcyjne i spersonalizowane działania dotyczące sprzedaży, obsługi, marketing i handel. Salesforce.com nazywa Einsteina „badaczem danych osobowych", ponieważ jest dość łatwy w użyciu, na przykład za pomocą przeciągania i upuszczania w celu tworzenia przepływów pracy. Niektóre z możliwości obejmują:

• Predictive Scoring: Pokazuje prawdopodobieństwo, że potencjalny klient zamieni się w szansę.

• Analiza sentymentu: umożliwia poznanie sposobu, w jaki ludzie postrzegają Twoją markę i produkty poprzez analizę mediów społecznościowych.

• Inteligentne zalecenia: Einstein analizuje dane, aby pokazać, które produkty są najbardziej idealne dla potencjalnych klientów.

Jednak chociaż te gotowe funkcje ułatwiają korzystanie ze sztucznej inteligencji, nadal istnieją potencjalne problemy. „W ciągu ostatnich kilku lat wbudowaliśmy funkcje sztucznej inteligencji w nasze aplikacje i było to wspaniałe doświadczenie edukacyjne" – powiedział Ricky Thakrar, który jest ewangelistą ds. doświadczeń klientów Zoho. „Ale aby technologia działała, użytkownicy muszą właściwie korzystać z oprogramowania. Jeśli sprzedawcy nie wprowadzają informacji poprawnie, wyniki prawdopodobnie będą nieprawdziwe. Odkryliśmy również, że modele powinny zostać przeszkolone przez co najmniej trzy miesiące. A poza tym, nawet jeśli Twoi pracownicy robią wszystko dobrze, nie oznacza to, że przewidywania AI będą idealne. Zawsze bierz rzeczy z przymrużeniem oka." Teraz, jeśli chodzi o budowanie własnych modeli AI, jest to znaczące zobowiązanie dla firmy. Ale niezależnie od tego, jakie podejście przyjmiesz, wdrożenie i wykorzystanie sztucznej inteligencji należy najpierw rozpocząć od edukacji i szkolenia. Nie ma znaczenia, czy pracownicy są osobami nietechnicznymi, czy inżynierami oprogramowania. Aby sztuczna inteligencja odniosła sukces w organizacji, każdy musi mieć podstawową wiedzę na temat technologii. Tak, ten tekst będzie pomocny, ale istnieje również wiele zasobów online, które mogą pomóc, na przykład z platform szkoleniowych, takich jak Lynda, Udacity i Udemy. Zapewniają setki wysokiej jakości kursów na wiele tematów dotyczących sztucznej inteligencji. Aby pokazać, jak wygląda korporacyjny program szkoleniowy, rozważ Adobe. Mimo, że firma ma niesamowicie utalentowanych inżynierów, wciąż istnieje duża liczba osób, które nie mają doświadczenia w sztucznej inteligencji. Niektórzy z nich mogą nie specjalizować się w tym w szkole lub w swojej pracy. Jednak Adobe chciał zapewnić, że wszyscy inżynierowie dobrze znają podstawowe zasady sztucznej inteligencji. W tym celu firma prowadzi sześciomiesięczny program certyfikacji, w ramach którego w 2018 r. przeszkolono 5000 inżynierów. Celem jest uwolnienie naukowca od danych w każdym inżynierze. Program obejmuje zarówno kursy online, jak i sesje osobiste, które obejmują nie tylko tematy techniczne, ale także obszary takie jak strategia, a nawet etyka. Adobe zapewnia również pomoc starszych informatyków, którzy pomagają studentom w opanowaniu tematów. Następnie, na wczesnym etapie procesu wdrażania, należy pomyśleć o potencjalnych zagrożeniach. Być może jednym z najbardziej zagrażających jest uprzedzenie, ponieważ może łatwo przeniknąć do modelu AI. Przykładem tego jest Amazon.com, który w 2017 r. zamknął swoje oprogramowanie do rekrutacji oparte na sztucznej inteligencji. Głównym problemem było to, że był nastawiony na zatrudnianie mężczyzn. Co ciekawe, był to klasyczny przypadek problemu treningowego dla modelki. Weź pod uwagę, że większość przesłanych życiorysów pochodziła od mężczyzn – więc dane były przekrzywione. Amazon.com próbował nawet ulepszyć model, ale nadal wyniki były dalekie od neutralności płci. W tym przypadku nie chodziło tylko o podejmowanie decyzji opartych na błędnych przesłankach. Amazon.com prawdopodobnie również narażał się na potencjalną odpowiedzialność prawną, na przykład w przypadku roszczeń o dyskryminację. Biorąc pod uwagę trudne problemy ze sztuczną inteligencją, coraz więcej firm tworzy rady etyczne. Ale nawet to może być obarczone problemami. Hej, co może być etyczne dla jednej osoby może nie być wielkim problemem dla kogoś innego, prawda? Zdecydowanie. Na przykład Google zamknął własną radę etyki w około tydzień od jej uruchomienia. Wydaje się, że głównym powodem była reakcja, która wywołała włączenie członka Heritage Foundation, która jest konserwatywnym think tankiem

**Kroki do wdrożenia AI**

Jeśli planujesz wdrożyć własne modele sztucznej inteligencji, jakie są główne kroki do rozważenia? Jakie są najlepsze praktyki? Cóż, przede wszystkim bardzo ważne jest, aby Twoje dane były dość czyste i ustrukturyzowane w sposób umożliwiający modelowanie . Oto kilka innych kroków, na które warto zwrócić uwagę:

• Zidentyfikuj problem do rozwiązania.

• Zbierz silny zespół.

• Wybierz odpowiednie narzędzia i platformy.

• Utwórz model AI.

• Wdrażaj i monitoruj model AI.

Przyjrzyjmy się każdemu.

**Zidentyfikuj problem do rozwiązania**

Założona w 1976 roku firma HCL Technologies jest jedną z największych firm konsultingowych w dziedzinie IT, zatrudniającą 132 000 pracowników w 44 krajach i mającą połowę listy Fortune 500 jako klientów. Firma wdrożyła również dużą liczbę systemów AI. Oto, co Kalyan Kumar, wiceprezes korporacyjny i globalny dyrektor ds. technologii w HCL Technologies, ma do powiedzenia: Liderzy biznesu muszą zrozumieć i zdać sobie sprawę, że przyjęcie sztucznej inteligencji to podróż a nie sprint. Bardzo ważne jest, aby ludzie kierujący przyjęciem AI w przedsiębiorstwie zachowali realizm w kwestii ram czasowych i możliwości sztucznej inteligencji. Relacja między ludźmi a sztuczną inteligencją wzajemnie się wzmacnia, a każda implementacja AI może wymagać trochę czasu, zanim zacznie wywierać pozytywny i znaczący wpływ. To świetna rada. Dlatego - szczególnie dla firm, które rozpoczynają przygodę z AI - niezbędne jest podejście eksperymentalne. Pomyśl o tym jako o przygotowaniu programu pilotażowego – to znaczy, że jesteś w „fazie pełzania i chodzenia". Ale jeśli chodzi o proces wdrażania sztucznej inteligencji, często zbytnio skupiamy się na różnych technologiach, które z pewnością są fascynujące i potężne. Jednak sukces to znacznie więcej niż tylko technologia; innymi słowy, tam musi najpierw być jasnym uzasadnieniem biznesowym. Oto kilka kwestii, o których warto pomyśleć na początku:

• Bez wątpienia decyzje w firmach są często doraźne i to kwestia zgadywania! Ale dzięki sztucznej inteligencji masz możliwość korzystania z procesu decyzyjnego opartego na danych, który powinien być bardziej precyzyjny. W takim razie gdzie w Twojej organizacji może to przynieść największe korzyści?

• Jak widać w przypadku Robotic Process Automation (RPA), o którym mówiliśmy w rozdziale 5, sztuczna inteligencja może być niezwykle skuteczna podczas wykonywania powtarzalnych i prozaicznych zadań.

• Chatboty mogą być kolejnym sposobem na rozpoczęcie pracy ze sztuczną inteligencją. Są stosunkowo łatwe w konfiguracji i mogą służyć do określonych przypadków użycia, takich jak obsługa klienta.

Andrew Ng, który jest dyrektorem generalnym Landing AI i byłym szefem Google Brain, wymyślił różne podejścia do przemyślenia podczas określania, na czym należy się skupić w początkowym projekcie AI:

• Szybka wygrana: Projekt powinien trwać od 6 do 12 miesięcy i musi mieć wysokie prawdopodobieństwo sukcesu, co powinno pomóc w nadawaniu tempa większej liczbie inicjatyw. Andrew sugeruje posiadanie kilku projektów, ponieważ zwiększa to szanse na wygraną.

• Znaczący: Projekt nie musi mieć charakteru transformacyjnego. Powinna jednak przynieść rezultaty, które pomogą w znaczącym ulepszeniu firmy, tworząc większe poparcie dla dodatkowych inwestycji w sztuczną inteligencję. Wartość wynika zwykle z niższych kosztów, wyższych przychodów, znajdowania nowych rozszerzeń działalności lub ograniczania ryzyka.

• Koncentracja na konkretnych branżach: ma to kluczowe znaczenie, ponieważ udany projekt będzie kolejnym czynnikiem zwiększającym zainteresowanie. Tak więc, jeśli masz firmę, która sprzedaje usługę subskrypcji, dobrym miejscem na początek byłby system sztucznej inteligencji, który zmniejszyłby churn.

• Dane: nie ograniczaj swoich opcji w oparciu o ilość posiadanych danych. Andrew zauważa, że udany projekt AI może mieć zaledwie 100 punktów danych.

Przyglądając się tej fazie, warto też ocenić „tango" między pracownikami a maszynami. Pamiętaj, że często jest to pomijane - i może mieć negatywne konsekwencje dla projektu AI. Jak widzieliśmy, sztuczna inteligencja świetnie radzi sobie z przetwarzaniem ogromnych ilości danych z niewielkim błędem z dużą szybkością. Technologia doskonale sprawdza się również w przewidywaniu i wykrywaniu anomalii. Ale są zadania, które ludzie wykonują znacznie lepiej, takie jak bycie kreatywnym, angażowanie się w abstrakcję i rozumienie pojęć. Zwróć uwagę na następujący przykład autorstwa Erika Schluntza, który jest współzałożycielem i CTO w Cobalt Robotics:

Nasze roboty bezpieczeństwa doskonale sprawdzają się w wykrywaniu nietypowych zdarzeń w miejscu pracy i kampusie, takich jak wykrywanie osoby w ciemnym biurze za pomocą termowizyjnego obrazowania wspomaganego sztuczną inteligencją. Ale wtedy jeden z naszych ludzkich operatorów wkracza i dzwoni, jak zareagować. Nawet przy całym potencjale sztucznej inteligencji nadal nie jest to najlepsza opcja o krytycznym znaczeniu dla misji, gdy mierzy się ze stale zmieniającymi się zmiennymi środowiskowymi i ludzką nieprzewidywalnością. Weź pod uwagę wagę popełniania błędu przez sztuczną inteligencję w różnych sytuacjach – niewykrycie złośliwego intruza jest znacznie gorsze niż przypadkowe wywołanie fałszywego alarmu jednemu z naszych operatorów.

Następnie upewnij się, że masz jasno określone kluczowe wskaźniki efektywności i starannie je mierz. Na przykład, jeśli opracowujesz niestandardowego chatbota do obsługi klienta, możesz chcieć zmierzyć się z takimi wskaźnikami, jak wskaźnik rozwiązywania problemów i zadowolenie klienta. I na koniec będziesz musiał przeprowadzić ocenę IT. Jeśli masz głównie starsze systemy, wdrożenie sztucznej inteligencji może być trudniejsze i bardziej kosztowne, nawet jeśli dostawcy mają interfejsy API i integracje. Oznacza to, że będziesz musiał złagodzić swoje oczekiwania. Mimo to inwestycje mogą naprawdę poruszyć igłę, nawet w przypadku starych firm. Przykładem może być firma Symrise, której korzenie sięgają ponad 200 lat wstecz w Niemczech. Firma jest globalnym producentem smaków i zapachów, z ponad 30 000 produktów. Kilka lat temu Symrise, z pomocą IBM, podjął poważną inicjatywę wykorzystania sztucznej inteligencji do tworzenia nowych perfum. Firma musiała nie tylko przebudować istniejącą infrastrukturę IT, ale także poświęcić sporo czasu na dopracowywanie modeli. Ale dużą pomocą było to, że posiadał już obszerny zbiór danych, co pozwoliło na większą precyzję. Zwróć uwagę, że nawet niewielkie odchylenie w mieszance może sprawić, że perfumy zawiodą. Według prezesa firmy Symrise ds. zapachów i pielęgnacji, Achima Dauba:

Teraz nasi perfumiarze mogą współpracować z uczeniem AI, który może analizować tysiące formuł i danych historycznych, aby identyfikować wzorce i przewidywać nowe kombinacje, pomagając zwiększyć ich produktywność i przyspieszyć proces projektowania, kierując ich w stronę formuł, które nigdy nie był widziany wcześniej

**Tworzenie zespołu**

Jak duży powinien być początkowy zespół dla projektu AI? Być może dobrym przewodnikiem jest zastosowanie „zasady dwóch pizzy" Jeffa Bezosa.10 Innymi słowy, czy to wystarczy, aby nakarmić uczestników? Aha, i nie powinno być pośpiechu z budowaniem zespołu. Każdy musi być bardzo skoncentrowany na sukcesie i rozumieć wagę projektu. Jeśli projekt AI niewiele ma do pokazania,

perspektywy przyszłych inicjatyw mogą być zagrożone. Zespół będzie potrzebował lidera, który na ogół ma doświadczenie biznesowe lub operacyjne, ale ma też pewne umiejętności techniczne. Taka osoba powinna być w stanie zidentyfikować uzasadnienie biznesowe dla projektu AI, ale także przekazać wizję wielu interesariuszom w firmie, takim jak dział IT i kadra kierownicza wyższego szczebla. Jeśli chodzi o osoby techniczne, prawdopodobnie nie będzie potrzeby robienia doktoratu z AI. Choć tacy ludzie są genialni, często skupiają się przede wszystkim na innowacjach w tej dziedzinie, np. dopracowując modele lub tworząc nowe. Te umiejętności zwykle nie są niezbędne dla pilota AI. Poszukaj raczej osób, które mają doświadczenie w inżynierii oprogramowania lub nauce o danych. Jednak, jak zauważono wcześniej w tym rozdziale, osoby te mogą nie mieć silnego doświadczenia w sztucznej inteligencji. Z tego powodu może zaistnieć potrzeba, aby spędzili kilka miesięcy na szkoleniu w zakresie poznania podstawowych zasad uczenia maszynowego i uczenia głębokiego. Należy również skupić się na zrozumieniu, jak korzystać z platform AI, takich jak TensorFlow. Biorąc pod uwagę wyzwania, dobrym pomysłem może być skorzystanie z pomocy konsultantów, którzy pomogą zidentyfikować możliwości AI, ale także doradzą w zakresie przygotowania danych i rozwoju modeli. Ponieważ pilot AI będzie eksperymentalny, zespół powinien mieć ludzi, którzy są chętni do podejmowania ryzyka i są otwarci. Jeśli nie, postęp może być niezwykle trudny.

**Właściwe narzędzia i platformy**

Istnieje wiele narzędzi pomagających w tworzeniu modeli AI, a większość z nich to open source. Nawet jeśli dobrze jest je przetestować, nadal wskazane jest, aby najpierw przeprowadzić ocenę IT. W ten sposób powinieneś mieć lepszą pozycję do oceny narzędzi AI. Coś jeszcze: możesz zdać sobie sprawę, że Twoja firma korzysta już z wielu narzędzi i platform AI! Może to powodować problemy z integracją i zarządzaniem procesem z projektami AI. W związku z tym firma powinna opracować strategię narzędzi. Pomyśl o tym jako o swoim stosie narzędzi AI. OK, przyjrzyjmy się więc niektórym z bardziej popularnych języków, platform i narzędzi do sztucznej inteligencji.

**Język Pythona**

Guido van Rossum, który w 1982 roku uzyskał tytuł magistra matematyki i informatyki na Uniwersytecie w Amsterdamie, kontynuował pracę w różnych instytutach badawczych w Europie, takich jak Corporation for National Research Initiatives (CNRI). Ale dopiero pod koniec lat 80. stworzył swój własny język komputerowy, zwany Pythonem. Nazwa pochodzi od popularnego brytyjskiego serialu komediowego Monty Python. Język był więc nieco niecodzienny, ale dzięki temu był tak potężny. Python miałby wkrótce stać się standardem rozwoju AI. Częściowo wynikało to z prostoty. Za pomocą zaledwie kilku skryptów kodu możesz tworzyć zaawansowane modele, na przykład z funkcjami takimi jak filtrowanie, mapowanie i zmniejszanie. Ale oczywiście język pozwala również na bardzo wyrafinowane kodowanie. Van Rossum opracował Pythona z jasną filozofią:

- Piękne jest lepsze niż brzydkie.
- Wyraźne jest lepsze niż dorozumiane.
- Proste jest lepsze niż złożone.
- Złożone jest lepsze niż skomplikowane.
- Płaskie jest lepsze niż zagnieżdżone.
- Rzadki jest lepszy niż gęsty.

To tylko niektóre z zasad. Co więcej, Python miał tę zaletę, że rozwijał się w społeczności akademickiej, która miała dostęp do Internetu, co pomogło przyspieszyć dystrybucję. Ale umożliwiło to również powstanie globalnego ekosystemu z tysiącami różnych pakietów i bibliotek AI. Oto tylko niektóre:

• NumPy: Pozwala na zastosowania obliczeń naukowych. Sednem tego jest możliwość tworzenia wyrafinowanej gamy obiektów z wysoką wydajnością. Ma to kluczowe znaczenie dla zaawansowanego przetwarzania danych w modelach AI.

• Matplotlib: Dzięki temu możesz wykreślać zestawy danych. Często Matplotlib jest używany w połączeniu z NumPy/Pandas (Pandas odnosi się do „Biblioteki analizy danych Pythona"). Ta biblioteka umożliwia stosunkowo łatwe tworzenie struktur danych do tworzenia modeli AI.

• SimpleAI: jest to implementacja algorytmów sztucznej inteligencji z książki Sztuczna inteligencja: nowoczesne podejście autorstwa Stuarta Russela i Petera Norviga. Biblioteka posiada nie tylko bogatą funkcjonalność, ale także zapewnia przydatne zasoby do poruszania się po procesie.

• PyBrain: Jest to modułowa biblioteka uczenia maszynowego, która umożliwia tworzenie wyrafinowanych modeli — sieci neuronowych i systemów uczenia się ze wzmocnieniem - bez większego kodowania.

• Scikit-Learn: Ta uruchomiona w 2007 r. biblioteka posiada bogate źródło możliwości, pozwalające na regresję, grupowanie i klasyfikację danych.

Kolejną korzyścią dla Pythona jest to, że istnieje wiele zasobów do nauki. Szybkie wyszukiwanie w YouTube pokaże tysiące bezpłatnych kursów. Teraz istnieją inne solidne języki, których możesz używać dla AI, takie jak C++, C# i Java. Chociaż generalnie są one potężniejsze niż Python, są również złożone. Poza tym, jeśli chodzi o budowanie modeli, często nie ma potrzeby tworzenia pełnoprawnych aplikacji. I wreszcie, istnieją biblioteki Pythona zbudowane dla szybkich maszyn AI - z procesorami graficznymi - jak CUDA Python.

**Szkielety AI**

Istnieje mnóstwo struktur sztucznej inteligencji, które zapewniają kompleksowe systemy do budowania modeli, szkolenia ich i wdrażania. Zdecydowanie najpopularniejszym jest TensorFlow, wspierany przez Google. Firma rozpoczęła rozwój tego frameworka w 2011 roku, poprzez swój oddział Google Brain. Celem było znalezienie sposobu na szybsze tworzenie sieci neuronowych, aby osadzić technologię w wielu aplikacjach Google. Do 2015 roku Google zdecydowało się na open source TensorFlow, głównie dlatego, że firma chciała przyspieszyć postęp AI. I bez wątpienia tak się stało. Dzięki otwartemu pozyskiwaniu TensorFlow firma Google uczyniła swoją technologię standardem branżowym w zakresie rozwoju. Oprogramowanie zostało pobrane ponad 41 milionów razy i ma ponad 1800 współtwórców. W rzeczywistości TensorFlow Lite (dla systemów wbudowanych) działa na ponad 2 miliardach urządzeń mobilnych. Wszechobecność platformy zaowocowała dużym ekosystemem. Oznacza to, że istnieje wiele dodatków, takich jak TensorFlow Federated (do zdecentralizowanych danych), TensorFlow Privacy, TensorFlow Probability, TensorFlow Agents (do uczenia się zbrojenia) i Mesh TensorFlow (do ogromnych zbiorów danych). Aby korzystać z TensorFlow, masz możliwość tworzenia modeli w różnych językach, takich jak Swift, JavaScript i R. Chociaż w większości przypadków najpopularniejszym z nich jest Python. Jeśli chodzi o podstawową strukturę, TensorFlow przyjmuje dane wejściowe jako tablica wielowymiarowa, znana również jako tensor. Jest do niego przepływ reprezentowany przez wykres, gdy dane przepływają przez system. Kiedy wprowadzasz polecenia do TensorFlow, są one przetwarzane przy użyciu zaawansowanego jądra C++. Pozwala to na znacznie wyższą wydajność, co może być niezbędne, ponieważ niektóre modele mogą być ogromne. TensorFlow

może być używany praktycznie do wszystkiego, jeśli chodzi o sztuczną inteligencję. Oto niektóre modele, które zasilał:

• Naukowcy z NERSC (National Energy Research Scientific Computing Center) w Lawrence Berkeley National Laboratory stworzyli system głębokiego uczenia, aby lepiej przewidywać ekstremalne warunki pogodowe. Był to pierwszy taki model, który przełamał barierę obliczeniową targów (1 miliard miliardów obliczeń). Dzięki temu naukowcy zdobyli nagrodę Gordona Bella

• Airbnb wykorzystało TensorFlow do zbudowania modelu, który kategoryzował miliony zdjęć ofert, co zwiększyło wrażenia gości i doprowadziło do wyższych konwersji.

• Google wykorzystał TensorFlow do analizy danych z teleskopu kosmicznego Kepler NASA. Wynik? Trenując sieć neuronową, model odkrył dwie egzoplanety. Google również udostępnił kod publicznie.

Google pracuje nad TensorFlow 2.0, a głównym celem jest uproszczenie procesu API. Istnieje również coś, co nazywa się Datasets, co pomaga usprawnić przygotowanie danych do modeli AI.

Więc jakie są inne frameworki AI? Spójrzmy:

• PyTorch: Facebook jest twórcą tej platformy, która został wydans w 2016 roku. Podobnie jak TensorFlow, główny język do zaprogramowania systemu jest Python. PyTorch wciąż działa we wczesnych fazach, jest już uważany za wicemistrza do TensorFlow pod względem użytkowania. Czym więc różni się od tej platformy? PyTorch ma bardziej intuicyjny interfejs. Ta platforma umożliwia również dynamiczne obliczanie wykresów. Oznacza to, że możesz łatwo wprowadzać zmiany w swoich modelach w czasie wykonywania, co przyspiesza rozwój. PyTorch umożliwia również posiadanie różnych typów procesorów i GPU zaplecza.

• Keras: Chociaż TensorFlow i PyTorch są przeznaczone dla doświadczonych ekspertów AI, Keras jest dla początkujących. Za pomocą niewielkiej ilości kodu - w Pythonie - możesz tworzyć sieci neuronowe. W dokumentacji zauważa: „Keras to API przeznaczone dla ludzi, a nie maszyn. Stawia to doświadczenie użytkownika na pierwszym miejscu. Keras postępuje zgodnie z najlepszymi praktykami w celu zmniejszenia obciążenia poznawczego: oferuje spójne i proste interfejsy API, minimalizuje liczbę działań użytkownika wymaganych w typowych przypadkach użycia oraz zapewnia jasne i przydatne informacje zwrotne w przypadku błędu użytkownika.”16 Istnieje przewodnik „Wprowadzenie”, który zajmuje tylko 30 sekundy! Jednak prostota nie oznacza, że nie ma mocy. Faktem jest, że z Kerasem można tworzyć wyrafinowane modele. Na przykład TensorFlow zintegrował Keras na własnej platformie. Nawet dla tych, którzy są profesjonalistami w sztucznej inteligencji, system może być bardzo przydatny do przeprowadzania wstępnych eksperymentów z modelami.

Wraz z rozwojem AI pojawiło się inne wspólne narzędzie: Jupyter Notebook. To nie jest platforma ani narzędzie programistyczne. Zamiast tego Jupyter Notebook to aplikacja internetowa, która ułatwia kodowanie w Pythonie i R w celu tworzenia wizualizacji i importowania systemów AI. Możesz także łatwo udostępniać swoją pracę innym osobom, podobnie jak robi to GitHub. W ciągu ostatnich kilku lat pojawiła się również nowa kategoria narzędzi AI, zwana zautomatyzowanym uczeniem maszynowym lub autoML. Systemy te pomagają radzić sobie z procesami, takimi jak przygotowanie danych i wybór funkcji. W większości celem jest zapewnienie pomocy organizacjom, które nie mają doświadczonych naukowców zajmujących się danymi i inżynierów AI. Chodzi o szybko rozwijający się trend „naukowca danych obywatelskich” – czyli osoby, która nie ma silnego zaplecza technicznego, a mimo to potrafi tworzyć przydatne modele. Niektórzy gracze w przestrzeni autoML to H2O.ai, DataRobot i SaaS. Systemy są intuicyjne i wykorzystują łatwość przeciągania i upuszczania podczas opracowywania modeli. Nie powinno dziwić, że operatorzy megatechnologiczni, tacy jak Facebook i

Google, stworzyli systemy autoML dla własnych zespołów. W przypadku Facebooka posiada Asimo, które pomaga zarządzać szkoleniem i testowaniem 300 000 modeli miesięcznie. Aby zapoznać się z przypadkiem użycia autoML, spójrz na Lenovo Brazil. Firma miała trudności z tworzeniem modeli uczenia maszynowego, które pomagają przewidywać i zarządzać łańcuchem dostaw. Miał dwie osoby, które kodowały 1500 wierszy kodu R każdego tygodnia - ale to nie wystarczyło. Faktem jest, że zatrudnienie większej liczby naukowców zajmujących się danymi nie byłoby opłacalne. Stąd firma wdrożyła DataRobot. Automatyzując różne procesy, Lenovo Brazil było w stanie stworzyć modele z większą liczbą zmiennych, co doprowadziło do lepszych wyników. W ciągu kilku miesięcy liczba użytkowników DataRobota wzrosła z dwóch do dziesięciu. Całkiem nieźle, prawda? Absolutnie. Ale wciąż są zastrzeżenia. Dzięki Lenovo Brazil firma korzystała z wykwalifikowanych naukowców zajmujących się danymi, którzy rozumieli niuanse tworzenia modeli. Jeśli jednak używasz narzędzia autoML bez takiej wiedzy, możesz łatwo wpaść w poważne kłopoty. Istnieje duża szansa, że możesz tworzyć modele, które mają błędne założenia lub dane. Jeśli już, wyniki mogą ostatecznie okazać się znacznie gorsze niż nieużywanie sztucznej inteligencji! Z tego powodu DataRobot faktycznie wymaga, aby nowy klient miał przez pierwszy rok dedykowanego inżyniera terenowego i analityka danych współpracującego z firmą. Teraz istnieją również platformy low-code, które okazały się przydatne w przyspieszeniu rozwoju projektów AI. Jednym z liderów w tej przestrzeni jest Appian, który ma śmiałą gwarancję „Pomysł na aplikację w osiem tygodni". Dzięki tej platformie możesz łatwo skonfigurować czystą strukturę danych. Istnieją nawet systemy, które pomagają kierować procesem, takie jak ostrzeganie o problemach. Bez wątpienia zapewnia to solidną podstawę do budowy modelu. Ale low-code pomaga również w inny sposób. Na przykład możesz przetestować różne platformy AI – na przykład od Google, Amazon lub Microsoft – aby zobaczyć, która z nich działa lepiej. Następnie możesz stworzyć aplikację z nowoczesnym interfejsem i wdrożyć ją w aplikacjach internetowych lub mobilnych. Aby zrozumieć siłę low-code, spójrz na to, co KPMG zrobiło z tą technologią. Firma była w stanie pomóc swoim klientom w odejściu od stosowania LIBOR w kredytach. Przede wszystkim KPMG wykorzystało własną platformę AI, o nazwie Ignite, do pozyskiwania nieustrukturyzowanych danych i wykorzystania uczenia maszynowego i przetwarzania języka naturalnego do naprawy umów. Następnie firma wykorzystała Appiana do pomocy w udostępnianiu dokumentów, dostosowywaniu reguł biznesowych i raportowaniu w czasie rzeczywistym. Taki proces - wykonywany ręcznie - może z łatwością zająć tysiące godzin, ze wskaźnikiem błędów od 10% do 15%. Ale przy użyciu Ignite/Appian dokładność wynosiła ponad 96%. Aha, a czas na przetworzenie dokumentów był w sekundach.

**Wdróż i monitoruj system AI**

Nawet jeśli zbudujesz model AI, który działa, wciąż jest wiele do zrobienia. Musisz znaleźć sposoby na jego wdrożenie i monitorowanie. Wymaga to zarządzania zmianą, które zawsze jest złożone i trudne. Sztuczna inteligencja różni się od typowej implementacji IT, ponieważ polega na wykorzystaniu prognoz i spostrzeżeń do podejmowania decyzji. Oznacza to, że ludzie będą musieli przemyśleć sposób interakcji z technologią. Należy również wziąć pod uwagę, że istnieje prawdopodobieństwo, że użytkownikami końcowymi będą osoby nietechniczne, zarówno pracownicy, jak i konsumenci. Dlatego trzeba dużo pracy nad tym, aby model AI był tak prosty, jak to tylko możliwe. Na przykład, jeśli zbudowałeś system do marketingu online, możesz chcieć ograniczyć opcje dla użytkownika – powiedzmy tylko do czterech lub pięciu z nich. Czemu? Jeśli jest ich zbyt wiele, użytkownicy mogą być sfrustrowani i nawet nie wiedzieć, od czego zacząć. To wszystko jest częścią tak zwanego problemu „paraliżu analitycznego". Kiedy tak się stanie, nieuchronnie nastąpi niewielkie przyjęcie modelu AI, co poważnie spowoduje utrudniony postęp. Inną dobrą strategią jest użycie interaktywnych wizualizacji. Innymi słowy, możesz łatwo zobaczyć, jak zmieniają się trendy, dostosowując niektóre zmienne. Możesz także zezwolić na kliknięcie określonej części wykresu, aby uzyskać więcej szczegółów. Niezbędne jest również tworzenie dokumentacji. Ale powinno to być coś więcej niż tylko materiały

pisemne. Na przykład skutecznym podejściem jest opracowanie samouczków wideo. Taki wysiłek zajmie długą drogę w tworzeniu silnej adopcji. Zgodnie z najlepszą praktyką początkowe wdrożenie powinno być ograniczone. Być może może to dotyczyć małej grupy użytkowników wersji beta i niewielkiej części bazy klientów. Powinny również pojawić się ostrzeżenia, że model AI jest na wczesnym etapie i może zawierać błędy. Dlatego ta faza dotyczy uczenia się. Co działa? Co należy usunąć? Gdzie można coś poprawić? Jest to zdecydowanie proces iteracyjny, którego nie wolno pośpieszać. Następnie, gdy model AI jest gotowy do pełnego wdrożenia, powinno być wystarczające wsparcie i ktoś, kto poprowadzi zarządzanie projektem. Musi być również uznanie dla zespołu za zwycięstwo. Miejmy nadzieję, że pochwały będą pochodzić od najwyższych szczebli firmy, co pomoże zachęcać do coraz większej innowacyjności. Istnieje wiele zautomatyzowanych platform, które pomagają usprawnić proces przepływu pracy, takich jak Alteryx. Wizją firmy jest demokratyzacja nauki o danych i analityki, niezależnie od tego, czy ktoś ma wykształcenie techniczne, czy nie. System Alteryx obsługuje kluczowe obszary procesu: odkrywanie danych, przygotowanie danych, analitykę i wdrażanie. A wszystko to za pomocą narzędzi przeciągania i upuszczania bez kodu. Ponadto wielu klientów firmy to operatorzy nietechnologiczni, tacy jak Hyatt, Unilever i Kroger. Ponownie, rozwój sztucznej inteligencji to naprawdę podróż – a twoja strategia nieuchronnie się zmieni. To nieuniknione. Według Kurta Muehmela, który jest wiceprezesem ds. inżynierii sprzedaży w Dataiku:

Firmy czasami nie zdają sobie sprawy, że droga do sztucznej inteligencji to długofalowa ewolucja nie tylko technologii, ale także sposobu, w jaki firma współpracuje i pracuje razem. Tak więc, oprócz edukacji, jednym z kluczowych elementów strategii AI powinno być ogólne zarządzanie zmianą. Ważne jest, aby stworzyć zarówno krótko-, jak i długoterminowe plany dotyczące tego, co zostanie osiągnięte za pomocą najpierw być może analiz predykcyjnych, a następnie być może uczenia maszynowego i

ostatecznie - jako cel długoterminowy - sztuczna inteligencja i jak każdy plan działania wpływa na różne elementy firmy, a także na ludzi, którzy są częścią tych linii biznesowych i ich codzienną pracę.

**Wniosek**

Jak pokazano, gdy podchodzimy do wdrażania sztucznej inteligencji, należy zwrócić uwagę na dwie ścieżki. Pierwszym z nich jest maksymalne wykorzystanie systemów innych firm, które korzystają z tej technologii. Ale należy również skoncentrować się na jakości danych. Jeśli nie, wyniki będą prawdopodobnie nietrafione. Drugą ścieżką jest wykonanie projektu AI, który opiera się na własnych danych firmy. Aby odnieść sukces, musi istnieć silny zespół, który łączy wiedzę techniczną, biznesową i dziedzinową. Prawdopodobnie będzie również potrzeba szkolenia AI. Dzieje się tak nawet w przypadku osób z doświadczeniem w naukach o danych i inżynierii. Od tego momentu nie powinno być pośpiechu w kolejnych etapach projektu: ocenie środowiska IT, wyznaczeniu jasnego celu biznesowego, oczyszczeniu danych, wyborze odpowiednich narzędzi i platform, stworzeniu modelu AI i wdrożeniu systemu. Przy wczesnych projektach nieuchronnie pojawią się wyzwania, dlatego kluczowe znaczenie ma elastyczność. Ale wysiłek powinien być tego wart.

**Kluczowe dania na wynos**

• Nawet najlepsze firmy mają trudności z wdrożeniem AI. Z tego powodu musi być wielka troska, pracowitość i planowanie. Ważne jest również, aby zdać sobie sprawę, że porażka jest powszechna.

• Istnieją dwa główne sposoby wykorzystania sztucznej inteligencji w firmie: za pomocą aplikacji dostawcy lub modelu wewnętrznego. To drugie jest znacznie trudniejsze i wymaga dużego zaangażowania ze strony organizacji.

• Korzystając z gotowych aplikacji AI, nadal pozostaje wiele do zrobienia. Na przykład, jeśli pracownicy nie wprowadzają poprawnie danych, wyniki prawdopodobnie będą nieprawdziwe.

• Edukacja ma kluczowe znaczenie przy wdrażaniu sztucznej inteligencji, nawet dla doświadczonych inżynierów. Istnieją doskonałe zasoby szkoleniowe online, które mogą w tym pomóc.

• Należy pamiętać o zagrożeniach związanych z implementacją sztucznej inteligencji, takich jak stronniczość, bezpieczeństwo i prywatność.

• Niektóre z kluczowych części procesu wdrażania sztucznej inteligencji obejmują: zidentyfikowanie problemu do rozwiązania; stworzyć silny zespół; wybrać odpowiednie narzędzia i platformy; stworzyć model AI; oraz wdrażać i monitorować model AI.

• Opracowując model, przyjrzyj się, jak technologia odnosi się do ludzi. Faktem jest, że ludzie mogą być znacznie lepsi w niektórych zadaniach.

• Stworzenie zespołu nie jest łatwe, więc nie spiesz się z procesem. Miej lidera, który ma dobre doświadczenie biznesowe lub operacyjne, z mieszanką umiejętności technicznych.

• Dobrze jest poeksperymentować z różnymi narzędziami AI. Jednak zanim to zrobisz, upewnij się, że wykonałeś ocenę IT.

• Niektóre z popularnych narzędzi AI to TensorFlow, PyTorch, Python, Keras i Jupyter Notebook.

• Zautomatyzowane uczenie maszynowe lub narzędzia autoML pomagają radzić sobie z procesami, takimi jak przygotowanie danych i wybór funkcji dla modeli AI. Nacisk kładziony jest na tych, którzy nie mają umiejętności technicznych.

• Wdrożenie modelu AI to coś więcej niż tylko skalowanie. Bardzo ważne jest również, aby system był łatwy w użyciu, aby umożliwić znacznie większą adaptację

**Przyszłość sztucznej inteligencji. Zalety i wady**

Na konferencji Web Summit pod koniec 2017 r. legendarny fizyk Stephen Hawking przedstawił swoją opinię na temat przyszłości sztucznej inteligencji. Z jednej strony miał nadzieję, że technologia prześcignie ludzką inteligencję. To prawdopodobnie oznaczałoby, że wiele okropnych chorób zostanie wyleczonych i być może pojawią się sposoby radzenia sobie z problemami środowiskowymi, w tym zmianami klimatycznymi. Ale była też ciemna strona. Hawking mówił o tym, jak ta technologia może stać się „najgorszym wydarzeniem w historii naszej cywilizacji". Tylko niektóre z problemów obejmują masowe bezrobocie, a nawet zabójcze roboty. Z tego powodu nalegał na sposoby kontrolowania sztucznej inteligencji. Pomysły Hawkinga z pewnością nie są na marginesie. Wybitni przedsiębiorcy technologiczni, tacy jak Elon Musk i Bill Gates, również wyrazili głębokie zaniepokojenie sztuczną inteligencją. Jednak jest wielu, którzy są zdecydowanie optymistyczni, jeśli nie entuzjastyczni. Jednym z nich jest Masayoshi Son, dyrektor generalny SoftBanku i zarządzający wartym 100 miliardów dolarów funduszem venture capital Vision. W rozmowie z CNBC oświadczył, że za 30 lat będziemy mieli latające samochody, ludzie będą żyć znacznie dłużej i wyleczymy wiele chorób. Zauważył również, że jego fundusz koncentruje się głównie na sztucznej inteligencji. No dobrze, kto ma rację? Czy przyszłość będzie dystopijna czy utopijna? A może będzie gdzieś pośrodku? Cóż, przewidywanie nowych technologii jest niezwykle trudne, prawie niemożliwe. Oto kilka przykładów prognoz, które były bardzo chybione:

* Thomas Edison oświadczył, że AC (prąd przemienny) zawiedzie.

* W swojej książce The Road Ahead (opublikowanej pod koniec 1995 roku) Bill Gates nie wspomniał o Internecie.

* W 2007 r. Jim Balsillie, współdyrektor Research in Motion (twórca urządzenia BlackBerry), powiedział, że iPhone nie będzie cieszył się zbytnią popularnością.

* W kultowym filmie science fiction „Łowca androidów" - wydanym w 1982 r., a jego akcja toczy się w 2019 r. - było wiele błędnych prognoz, takich jak budki telefoniczne z telefonami wideo i androidami (lub „replikantami"), które były prawie nie do odróżnienia od ludzi.

Mimo to jedno jest pewne: w nadchodzących latach zobaczymy wiele innowacji i zmian w sztucznej inteligencji. Wydaje się to nieuniknione, zwłaszcza że w branżę wciąż inwestuje się ogromne kwoty. Przyjrzyjmy się więc niektórym obszarom, które mogą mieć ogromny wpływ na społeczeństwo.

**Autonomiczne samochody**

Jeśli chodzi o sztuczną inteligencję, jednym z najdalej idących obszarów są samochody autonomiczne. Co ciekawe, ta kategoria nie jest tak naprawdę nowa. Tak, od wielu dziesięcioleci jest to znak rozpoznawczy wielu opowiadań science fiction! Ale od jakiegoś czasu istnieje wiele rzeczywistych przykładów innowacji, takich jak:

• Stanford Cart: Jego rozwój rozpoczął się na początku lat 60. XX wieku, a pierwotnym celem było stworzenie zdalnie sterowanego pojazdu do misji księżycowych. Jednak badacze ostatecznie zmienili swój cel i opracowali podstawowy pojazd autonomiczny, który do nawigacji wykorzystywał kamery i sztuczną inteligencję. Chociaż było to wyjątkowe osiągnięcie w tamtych czasach, nie było praktyczne, ponieważ zaplanowanie dowolnego ruchu wymagało ponad 10 minut!

• Ernst Dickmanns: Genialny niemiecki inżynier lotnictwa, zwrócił uwagę na pomysł przekształcenia furgonetki Mercedesa w pojazd autonomiczny… w połowie lat 80. XX wieku. Połączył kamery, czujniki i komputery. Był również kreatywny w tym, jak używał

oprogramowania, na przykład poprzez skupienie przetwarzania grafiki tylko na ważnych szczegółach wizualnych w celu zaoszczędzenia energii. Robiąc to wszystko, był w stanie opracować system, który kontrolowałby kierownicę, pedał gazu i hamulce. Testował Mercedesa na paryskiej autostradzie – w 1994 roku – i przejechał ponad 600 mil, z prędkością dochodzącą do 81 mil na godzinę5. Mimo to wycofano fundusze na badania, ponieważ nie było jasne, czy może nastąpić komercjalizacja w odpowiednim czasie . Nie pomogło też to, że AI wkraczała w kolejną zimę.

Ale punkt zwrotny dla autonomicznych samochodów nadszedł w 2004 roku. Głównym katalizatorem była wojna w Iraku, która wywarła straszliwe żniwo na amerykańskich żołnierzach. W przypadku DARPA wierzono, że rozwiązaniem mogą być pojazdy autonomiczne. Ale agencja stanęła przed wieloma trudnymi wyzwaniami. Z tego powodu w 2004 r. zorganizowano konkurs nazwany DARPA Grand Challenge, w którym przyznano główną nagrodę w wysokości 1 miliona dolarów, aby zachęcić do szerszej innowacji. Impreza obejmowała 150-milowy wyścig na pustyni Mojave i niestety nie był zachęcający, ponieważ samochody spisywały się fatalnie. Żaden z nich nie ukończył wyścigu! Ale to tylko pobudziło jeszcze więcej innowacji. W następnym roku wyścig ukończyło pięć samochodów. Następnie w 2007 roku samochody były tak zaawansowane, że były w stanie podejmować działania, takie jak zawracanie i łączenie się. Dzięki temu procesowi DARPA była w stanie umożliwić stworzenie kluczowych komponentów dla pojazdów autonomicznych:

• Czujniki: obejmują systemy radarowe i ultradźwiękowe, które mogą wykrywać pojazdy i inne przeszkody, takie jak krawężniki.

• Kamery wideo: mogą wykrywać znaki drogowe, sygnalizację świetlną i pieszych.

• Lidar (Light Detection and Ranging): To urządzenie, które zwykle znajduje się na szczycie autonomicznego samochodu, wysyła wiązki laserowe w celu pomiaru otoczenia. Dane są następnie integrowane z istniejącymi mapami.

• Komputer: Pomaga w kontrolowaniu samochodu, w tym kierowaniu, przyspieszaniu i hamowaniu. System wykorzystuje sztuczną inteligencję do nauki, ale ma również wbudowane zasady unikania obiektów, przestrzegania prawa i tak dalej.

Teraz, jeśli chodzi o samochody autonomiczne, istnieje wiele niejasności co do tego, co tak naprawdę oznacza „autonomiczny". Czy to wtedy, gdy samochód jeździ sam – czy też musi być ludzki kierowca? Aby zrozumieć niuanse, istnieje pięć poziomów autonomii:

• Poziom 0: To tutaj człowiek kontroluje wszystkie systemy.

• Poziom 1: Dzięki temu komputery sterują ograniczonymi funkcjami, takimi jak tempomat lub hamowanie – ale tylko po jednym na raz.

• Poziom 2: Ten typ samochodu może zautomatyzować dwie funkcje.

• Poziom 3: Tutaj samochód automatyzuje wszystkie funkcje bezpieczeństwa. Ale kierowca może interweniować, jeśli coś pójdzie nie tak.

• Poziom 4: Samochód generalnie może sam jeździć. Ale są przypadki, w których człowiek musi uczestniczyć.

• Poziom 5: To Święty Graal, w którym samochód jest całkowicie autonomiczny.

Branża motoryzacyjna jest jednym z największych rynków, a sztuczna inteligencja prawdopodobnie wyzwoli gwałtowne zmiany. Weź pod uwagę, że transport jest drugim co do wielkości wydatkiem gospodarstwa domowego, po mieszkalnictwie, i dwukrotnie większym niż opieka zdrowotna. Należy

jeszcze pamiętać: typowy samochód jest używany tylko przez około 5% czasu, ponieważ zwykle jest gdzieś zaparkowany. W świetle ogromnych możliwości ulepszeń nie powinno dziwić, że przemysł samochodów autonomicznych odnotował ogromne inwestycje. Chodziło nie tylko o inwestorów venture capital inwestujących w niezliczone start-upy, ale także o innowacje od tradycyjnych producentów samochodów, takich jak Ford, GM i BMW. Kiedy więc możemy zobaczyć, jak ta branża stanie się głównym nurtem? Szacunki są bardzo zróżnicowane. Jednak według badania przeprowadzonego przez Allied Market Research prognozuje się, że do 2026 r. rynek osiągnie 556,67 miliardów dolarów, co stanowiłoby łączną roczną stopę wzrostu na poziomie 39,47%. Ale wciąż jest wiele do wypracowania. „W najlepszym razie wciąż dzieli nas wiele lat od samochodu, który nie wymaga kierownicy" – powiedział Scott Painter, dyrektor generalny i założyciel Fair. „Samochody nadal będą musiały być ubezpieczone, naprawiane i konserwowane, nawet jeśli wróciłeś z przyszłości Deloreanem i przyniosłeś instrukcję, jak sprawić, by te samochody były w pełni autonomiczne. Produkujemy 100 milionów samochodów rocznie, z czego 16 milionów rocznie jest w Stanach Zjednoczonych. Przypuśćmy, że chciałbyś, aby cała dostawa miała te funkcje sztucznej inteligencji, zajęłoby to jeszcze 20 lat, zanim będziemy mieli więcej samochodów na drogach, w tym wszystkie różne poziomy AI w porównaniu do liczby samochodów, które nie miały tych technologii.

Należy jednak pamiętać o wielu innych czynnikach. W końcu faktem jest, że prowadzenie pojazdu jest skomplikowane, zwłaszcza na obszarach miejskich i podmiejskich. Co się stanie, jeśli znak drogowy zostanie zmieniony lub nawet zmanipulowany? Co powiesz na to, że autonomiczny samochód musi poradzić sobie z dylematem, takim jak zderzenie się z nadjeżdżającym samochodem lub wjechanie w krawężnik, w którym mogą znajdować się piesi? Wszystko to jest niezwykle trudne. Wieczorne pozornie proste zadania mogą być trudne do wykonania. John Krafcik, dyrektor generalny firmy Google Waymo, wskazuje, że parkingi są najlepszym przykładem. Wymagają odnalezienia dostępnych miejsc, unikania innych samochodów i pieszych (które mogą być nieprzewidywalne) oraz poruszania się w przestrzeni. Ale technologia to tylko jedno z wyzwań związanych z pojazdami autonomicznymi. Oto kilka innych do rozważenia:

• Infrastruktura: Nasze miasta i miasteczka są zbudowane dla tradycyjnych samochodów. Ale mieszając pojazdy autonomiczne, prawdopodobnie pojawi się wiele problemów logistycznych. Jak samochód wyprzedza działania ludzkich kierowców? Właściwie może zaistnieć potrzeba zainstalowania czujników wzdłuż dróg. Inną opcją jest posiadanie osobnych dróg dla pojazdów autonomicznych. Rządy prawdopodobnie będą również musiały zmienić edycję kierowcy, zapewniając wskazówki dotyczące interakcji z pojazdami autonomicznymi podczas jazdy.

• Przepisy: To duża dzika karta. W większości może to być największa przeszkoda, ponieważ rządy mają tendencję do powolnej pracy i są odporne na zmiany. Stany Zjednoczone są również krajem wysoce spornym, co może być kolejnym czynnikiem hamującym rozwój.

• Przyjęcie: pojazdy autonomiczne prawdopodobnie nie będą tanie, ponieważ systemy takie jak Lidar są kosztowne. To z pewnością będzie czynnikiem ograniczającym. Ale jednocześnie pojawiają się oznaki sceptycyzmu wśród ogółu społeczeństwa. Według ankiety przeprowadzonej przez AAA około 71% respondentów stwierdziło, że boi się jeździć pojazdem autonomicznym.

Biorąc to wszystko pod uwagę, początkowa faza pojazdów autonomicznych będzie prawdopodobnie dotyczyła sytuacji kontrolowanych, na przykład ciężarówek, górnictwa lub wahadłowców. Przykładem jest firma Suncor Energy, która wykorzystuje autonomiczne ciężarówki do kopania różnych miejsc w Kanadzie. Innym punktem wyjścia mogą być sieci wspólnego przejazdu – takie jak Uber i Lyft. Usługi te są dość ustrukturyzowane i zrozumiałe dla opinii publicznej. Należy pamiętać, że Waymo testuje usługę autonomicznych taksówek w Phoenix (jest to podobne do systemu wspólnego przejazdu, takiego jak

Uber, ale samochody mają systemy autonomiczne). Oto, jak wyjaśnia to post na blogu firmy: Zaczniemy od udostępnienia pasażerom naszej aplikacji. Mogą za jego pomocą dzwonić do naszych autonomicznych pojazdów 24 godziny na dobę, 7 dni w tygodniu. Mogą jeździć po kilku miastach w obszarze Metro Phoenix, w tym Chandler, Tempe, Mesa i Gilbert. Niezależnie od tego, czy chodzi o zabawny wieczór, czy tylko o przerwę od jazdy, nasi kierowcy otrzymują za każdym razem te same czyste pojazdy, a nasz kierowca Waymo ma ponad 10 milionów mil doświadczenia na drogach publicznych. Pasażerowie zobaczą szacunkowe ceny, zanim zaakceptują podróż, w oparciu o takie czynniki, jak czas i odległość do miejsca docelowego. Waymo odkrył, że kluczem jest edukacja, ponieważ kolarze mają wiele pytań. Aby sobie z tym poradzić, firma wbudowała system czatu w aplikacji, aby skontaktować się z osobą wsparcia. Na desce rozdzielczej samochodu znajduje się również ekran, na którym wyświetlane są szczegóły jazdy. Według wpisu na blogu „Informacje zwrotne od motocyklistów będą nadal mieć kluczowe znaczenie na każdym kroku"

**Stany Zjednoczone kontra Chiny**

Szybki wzrost Chin był zdumiewający. W ciągu kilku lat gospodarka może być większa niż Stany Zjednoczone, a kluczową częścią wzrostu będzie sztuczna inteligencja. Chiński rząd wyznaczył ambitny cel wydania 150 miliardów dolarów na tę technologię do 2030 r. W międzyczasie nadal będą realizowane duże inwestycje firm takich jak Baidu, Alibaba i Tencent. Chociaż często uważa się, że Chiny nie są tak kreatywne i innowacyjne jak Dolina Krzemowa - często określane jako „naśladowcy" – ta percepcja może okazać się mitem. Badanie przeprowadzone przez Allen Institute for Artificial Intelligence wskazuje, że oczekuje się, że Chiny wyprzedzą Stany Zjednoczone w najczęściej cytowanych artykułach technicznych dotyczących sztucznej inteligencji. Kraj ma kilka innych zalet, które ekspert AI i inwestor venture capital Kai-Fu Lee wskazał w swojej prowokacyjnej książce AI Superpowers: China, Silicon Valley, and the New World Order:

• Entuzjazm: W latach pięćdziesiątych wprowadzenie Sputnika przez Rosję wywołało zainteresowanie ludzi w Stanach Zjednoczonych, aby zostali inżynierami programu kosmicznego. Coś podobnego faktycznie wydarzyło się w Chinach. Kiedy czołowy gracz Go w kraju, Ke Jie, przegrał z systemem AlphaGo AI, była to pobudka. W rezultacie zainspirowało to wielu młodych ludzi do podjęcia kariery w AI.

• Dane: Chiny z populacją przekraczającą 1,3 miliarda są bogate w dane (ponad 700 milionów użytkowników Internetu). Jednak autorytarny rząd tego kraju jest również krytyczny, ponieważ prywatność nie jest uważana za szczególnie ważną, co oznacza, że przy opracowywaniu modeli sztucznej inteligencji jest znacznie więcej swobody. Na przykład w artykule opublikowanym w Nature Medicine chińscy naukowcy mieli dostęp do danych na temat 600 000 pacjentów, aby przeprowadzić badanie opieki zdrowotnej.16 Jeszcze na wczesnym etapie wykazano, że model AI był w stanie skutecznie diagnozować schorzenia wieku dziecięcego, takie jak grypa i zapalenie opon mózgowych.

• Infrastruktura: W ramach planów inwestycyjnych rządu chińskiego skupiono się na tworzeniu miast nowej generacji, które pozwalają na autonomiczne samochody i inne systemy sztucznej inteligencji. Nastąpił również agresywny rozwój sieci 5G.

Jeśli chodzi o Stany Zjednoczone, rząd podchodzi do sztucznej inteligencji z większą ostrożnością. Prezydent Trump podpisał zarządzenie – zwane „Amerykańską Inicjatywą AI" - aby zachęcić do rozwoju technologii, ale warunki są niejasne i nie jest jasne, ile pieniędzy zostanie na nią przeznaczonych.

**Bezrobocie technologiczne**

Pojęcie bezrobocia technologicznego, które zyskało rozgłos od słynnego ekonomisty Johna Maynarda Keynesa podczas Wielkiego Kryzysu, wyjaśnia, w jaki sposób innowacje mogą prowadzić do długoterminowej utraty pracy. Jednak dowody na to były nieuchwytne. Niezależnie od tego, że automatyzacja poważnie wpłynęła na branże, takie jak produkcja, często następuje zmiana siły roboczej w miarę dostosowywania się ludzi. Ale czy rewolucja AI może być inna? Bardzo dobrze mógł. Na przykład gubernator Kalifornii Gavin Newsom obawia się, że w jego stanie może nastąpić masowe bezrobocie w obszarach takich jak transport ciężarowy i magazynowanie – i to wkrótce. Oto kolejny przykład: Harvest CROO Robotics zbudował robota o nazwie Harv, który może zbierać truskawki i inne rośliny bez powodowania siniaków. To prawda, że wciąż jest w fazie eksperymentalnej, ale system szybko się poprawia. Oczekuje się, że jeden robot wykona pracę 30 osób. I oczywiście nie będzie wynagrodzenia do wypłaty ani narażenia na odpowiedzialność pracowniczą. Ale sztuczna inteligencja może oznaczać więcej niż zastępowanie pracowników o niskich kwalifikacjach. Już teraz pojawiają się oznaki, że technologia może mieć duży wpływ na zawody umysłowe. Spójrzmy prawdzie w oczy, jest jeszcze większa zachęta do automatyzacji tych prac, ponieważ przynoszą one wyższe wynagrodzenie. Tylko jedna kategoria, która może stanąć w obliczu utraty pracy w AI, to dziedzina prawna, ponieważ na rynek walczy wiele startupów, takich jak Lawgood, NexLP i RAVN ACE. Rozwiązania koncentrują się na automatyzacji obszarów, takich jak badania prawne i przegląd umów. Mimo że systemy są dalekie od doskonałości, z pewnością mogą przetwarzać znacznie więcej objętości niż ludzie - a także mogą stać się inteligentniejsze, gdy są coraz częściej używane. To prawda, że cały rynek pracy jest dynamiczny i powstaną nowe rodzaje karier. Prawdopodobnie pojawią się również innowacje AI, które będą pomocne dla pracowników – ułatwiając im pracę. Na przykład firma rozpoczynająca oprogramowanie Measure Square była w stanie wykorzystać zaawansowane algorytmy do konwersji papierowych planów pięter na cyfrowe interaktywne plany pięter. Dzięki temu łatwiej było rozpocząć i zakończyć projekty na czas. Jednak w świetle potencjalnego transformacyjnego wpływu sztucznej inteligencji wydaje się rozsądne, że będzie to miało negatywny wpływ na wiele branż. Być może zapowiedzią tego jest utrata miejsc pracy w przemyśle w latach 60. i 90. XX wieku. Według Pew Research Center w ciągu ostatnich 40 lat nie było praktycznie żadnego wzrostu płac. W tym okresie Stany Zjednoczone również doświadczyły pogłębiającej się przepaści majątkowej. Ekonomista z Berkeley Gabriel Zucman szacuje, że 0,1% populacji kontroluje prawie 20% bogactwa. Są jednak działania, które można podjąć. Przede wszystkim rządy mogą starać się zapewnić pomoc w zakresie edukacji i transformacji. Wraz z tempem zmian w dzisiejszym świecie, większość ludzi będzie musiała stale odnawiać umiejętności. Dyrektor generalny IBM, Ginni Rometty, zauważył, że sztuczna inteligencja zmieni wszystkie miejsca pracy w ciągu najbliższych 5-10 lat. Nawiasem mówiąc, jej firma odnotowała 30% redukcję zatrudnienia w dziale HR z powodu automatyzacji. Następnie są ludzie, którzy opowiadają się za dochodem podstawowym, który zapewnia każdemu minimalną kwotę rekompensaty. To z pewnością złagodziłoby niektóre nierówności, ale ma też wady. Ludzie na pewno czerpią dumę i satysfakcję ze swojej kariery. Więc jakie może być morale osoby, która nie może znaleźć pracy? To może mieć ogromny wpływ. Wreszcie, mówi się nawet o jakimś rodzaju podatku od sztucznej inteligencji. To zasadniczo odzyskałoby duże zyski firm, które czerpią korzyści z tej technologii. Chociaż, biorąc pod uwagę ich moc, prawdopodobnie trudno byłoby uchwalić tego typu akty prawne.

**Uzbrojenie AI**

Laboratorium Badawcze Sił Powietrznych pracuje nad prototypami czegoś, co nazywa się Skyborg. To prosto z Gwiezdnych Wojen. Pomyśl o Skyborgu jako R2-D2, który służy jako skrzydłowy AI dla myśliwca, pomagając identyfikować cele i zagrożenia. Robot AI może również przejąć kontrolę, jeśli pilot jest ubezwłasnowolniony lub rozproszony. Siły Powietrzne rozważają nawet wykorzystanie tej technologii do obsługi dronów. Fajne hę? Z pewnością. Ale jest poważny problem: czy wykorzystując sztuczną inteligencję ludzie mogą ostatecznie zostać wyrzuceni z pętli podczas podejmowania decyzji

dotyczących życia i śmierci na polu bitwy? Czy może to ostatecznie doprowadzić do większego rozlewu krwi? Być może maszyny podejmą błędne decyzje – przysparzają jeszcze więcej problemów? Wielu badaczy i przedsiębiorców zajmujących się sztuczną inteligencją jest zaniepokojonych. W tym celu ponad 2400 podpisało oświadczenie wzywające do zakazu tak zwanych robotów-zabójców. Nawet ONZ bada jakiś rodzaj zakazu. Ale Stany Zjednoczone wraz z Australią, Izraelem, Wielką Brytanią i Rosją oparły się temu ruchowi. W rezultacie może pojawić się prawdziwy wyścig zbrojeń AI. Według artykułu RAND Corporation, istnieje nawet możliwość, że ta technologia może doprowadzić do wojny nuklearnej, powiedzmy do roku 2040. Jak? Autorzy zauważają, że sztuczna inteligencja może ułatwić celowanie w okręty podwodne i mobilne systemy rakietowe. Według raportu:

Naukowcy twierdzą, że narody mogą ulec pokusie dążenia do możliwości pierwszego uderzenia jako sposobu na uzyskanie przewagi przetargowej nad rywalami, nawet jeśli nie mają zamiaru przeprowadzić ataku. Podważa to stabilność strategiczną, bo nawet jeśli państwo posiadające te zdolności nie ma zamiaru z nich korzystać, to przeciwnik nie może być tego pewien.

Jednak w niedalekiej perspektywie sztuczna inteligencja prawdopodobnie będzie miała największy wpływ na wojnę informacyjną, która nadal może być wysoce destrukcyjna. Przekonaliśmy się o tym, gdy rosyjski rząd ingerował w wybory prezydenckie w 2016 roku. Podejście to było dość mało zaawansowane technologicznie, ponieważ wykorzystywało farmy trolli w mediach społecznościowych do rozpowszechniania fałszywych wiadomości – ale konsekwencje były znaczące. Ale w miarę jak sztuczna inteligencja staje się potężniejsza i bardziej przystępna cenowo, prawdopodobnie zobaczymy, jak doładowuje tego rodzaju kampanie. Na przykład systemy deepfake mogą z łatwością tworzyć realistyczne zdjęcia i filmy ludzi, które można wykorzystać do szybkiego rozpowszechniania wiadomości.

**Odkrycie leków**

Postępy w odkrywaniu leków były niemal cudowne, ponieważ obecnie mamy lekarstwa na takie nieuleczalne choroby, jak wirusowe zapalenie wątroby typu C, i nadal robimy postępy w niezliczonej liczbie nowotworów. Ale oczywiście z pewnością jest wiele do zrobienia. Faktem jest, że firmy farmaceutyczne mają więcej problemów z opracowywaniem terapii. Oto tylko jeden przykład: w marcu 2019 r. firma Biogen ogłosiła, że jeden z jej leków na chorobę Alzheimera, który był w fazie III badań, nie przyniósł znaczących wyników. W wiadomościach akcje firmy spadły o 29%, niszcząc 18 miliardów dolarów wartości rynkowej. Weź pod uwagę, że opracowywanie tradycyjnych leków często wiąże się z wieloma próbami i błędami, co może być czasochłonne. Czy może być lepszy sposób? Coraz częściej naukowcy szukają pomocy w AI. Widzimy, jak powstają różne startupy, które koncentrują się na możliwościach. Jednym z nich jest Insitro. Firma, która rozpoczęła działalność w 2019 roku, nie miała problemów z zebraniem oszałamiających 100 milionów dolarów w rundzie serii A. Niektórzy z inwestorów to Alexandria Venture Investments, Bezos Expeditions (która jest firmą inwestycyjną Jeffa Bezosa z Amazon.com), Mubadala Investment Company, Two Sigma Ventures i Verily. Mimo że zespół jest stosunkowo niewielki – zatrudnia około 30 pracowników – wszyscy są świetnymi badaczami, którzy zajmują się takimi obszarami, jak nauka o danych, głębokie uczenie, inżynieria oprogramowania, bioinżynieria i chemia. Dyrektor generalna i założycielka, Daphne Koller, ma rzadkie połączenie doświadczenia w zaawansowanej informatyce i naukach o zdrowiu, ponieważ kierowała działalnością firmy Google zajmującą się opieką zdrowotną, Calico. Jako świadectwo sprawności Insitro, firma nawiązała już współpracę z mega operatorem farmaceutycznym Gilead. Wiąże się to z potencjalnymi wypłatami ponad 1 miliarda dolarów na badania nad niealkoholowym stłuszczeniowym zapaleniem wątroby (NASH), które jest poważną chorobą wątroby. Kluczem jest to, że Gilead był w stanie zgromadzić dużą ilość danych, które mogą szkolić modele. Odbywa się to przy użyciu komórek znajdujących się poza ciałem człowieka – to znaczy za pomocą systemu in vitro. Gilead ma pilną

potrzebę przyjrzenia się alternatywnym podejściom, ponieważ jedna z jej terapii NASH, selonsertyb, nie powiodła się w badaniach klinicznych (dotyczyło to osób, które miały chorobę w późniejszych stadiach). Sztuczna inteligencja obiecuje, że przyspieszy odkrywanie leków, ponieważ głębokie uczenie powinno być w stanie zidentyfikować złożone wzorce. Ale technologia może również okazać się pomocna w opracowywaniu spersonalizowanych terapii – na przykład dostosowanych do budowy genetycznej danej osoby – co może mieć kluczowe znaczenie dla leczenia niektórych chorób. Niezależnie od tego, prawdopodobnie najlepiej złagodzić oczekiwania. Pojawią się poważne przeszkody do pokonania, ponieważ branża opieki zdrowotnej będzie musiała przejść zmiany, ponieważ będzie zwiększona edukacja w zakresie sztucznej inteligencji. Zajmie to trochę czasu i prawdopodobnie pojawi się opór. Następnie głębokie uczenie jest ogólnie „czarną skrzynką", jeśli chodzi o zrozumienie, jak naprawdę działają algorytmy. Może to okazać się trudne w uzyskaniu zgody organów regulacyjnych na nowe leki, ponieważ FDA koncentruje się na związkach przyczynowych. Wreszcie ludzkie ciało jest wysoce wyrafinowane i wciąż uczymy się, jak to działa. Poza tym, jak widzieliśmy w przypadku innowacji, takich jak dekodowanie ludzkiego genomu, zrozumienie nowych podejść zwykle zajmuje dużo czasu. Jako oznakę złożoności rozważ sytuację IBM Watson. Mimo że firma ma jednych z najbardziej utalentowanych badaczy sztucznej inteligencji i wydała miliardy na tę technologię, niedawno ogłosiła, że nie będzie już sprzedawać Watsona do celów odkrywania leków.

**Rząd**

Artykuł z Bloomberg.com z kwietnia 2019 r. wywołał duże poruszenie. Opisuje zakulisowe spojrzenie na to, jak Amazon.com zarządza swoim systemem AI głośników Alexa. Chociaż wiele z nich opiera się na algorytmach, tysiące ludzi analizuje klipy głosowe, aby poprawić wyniki. Często skupiamy się na radzeniu sobie z niuansami slangu i dialektów regionalnych, które były trudne dla algorytmów głębokiego uczenia. Ale oczywiście ludzie zastanawiają się: czy mój inteligentny głośnik naprawdę mnie słucha? Czy moje rozmowy są prywatne? Amazon.com szybko zauważył, że ma surowe zasady i wymagania. Ale nawet to wzbudziło jeszcze większe obawy! Według Bloomberga. com post, recenzenci AI czasami słyszeli klipy, które wiązały się z potencjalnie przestępczą działalnością, taką jak napaść na tle seksualnym. Ale Amazon najwyraźniej ma politykę, aby nie ingerować. W miarę jak sztuczna inteligencja staje się coraz bardziej wszechobecna, będziemy mieć więcej tego rodzaju historii; iw większości nie będzie jednoznacznych odpowiedzi. Niektóre osoby mogą ostatecznie zdecydować się nie kupować produktów AI. Jednak prawdopodobnie będzie to niewielka grupa. Hej, nawet przy niezliczonych problemach z prywatnością na Facebooku, nie nastąpił spadek liczby użytkowników. Bardziej prawdopodobne jest, że rządy zaczną wdzierać się w kwestie sztucznej inteligencji. Grupa kongresmenów zasponsorowała projekt ustawy o nazwie Algorithmic Accountability Act, który ma na celu nakazanie firmom przeprowadzania audytów ich systemów AI (byłby to dotyczyć większych firm, z przychodami powyżej 50 mln USD i ponad 1 mln użytkowników). Prawo, jeśli zostanie uchwalone, będzie egzekwowane przez Federalną Komisję Handlu. Istnieją również posunięcia legislacyjne ze stanów i miast. W 2019 r. Nowy Jork uchwalił własne prawo, które wymaga większej przejrzystości w zakresie sztucznej inteligencji. Podejmowane są również wysiłki w stanie Waszyngton, Illinois i Massachusetts. Przy całej tej działalności niektóre firmy stają się proaktywne, na przykład poprzez przyjmowanie własnych rad etycznych. Wystarczy spojrzeć na Microsoft. Rada ds. etyki firmy, zwana Aether (AI and Ethics in Engineering and Research), postanowiła nie zezwolić na używanie jej systemu rozpoznawania twarzy do zatrzymania ruchu w Kalifornii. protestować przed użyciem niektórych aplikacji. Ponownie, celem tego jest Amazon.com ze swoim oprogramowaniem Rekognition, które wykorzystuje rozpoznawanie twarzy, aby pomóc organom ścigania zidentyfikować podejrzanych. ACLU zgłosiła obawy co do dokładności systemu, zwłaszcza w odniesieniu do kobiet i mniejszości. W jednym ze swoich eksperymentów stwierdził, że Rekognition zidentyfikowało 28 członków Kongresu jako posiadających wcześniejsze rejestry karne!34 Jeśli chodzi

o Amazon.com, zakwestionował on te roszczenia. Uznanie jest tylko jednym z wielu zastosowań sztucznej inteligencji w organach ścigania, które prowadzą do kontrowersji. Być może najbardziej godnym uwagi przykładem jest COMPAS (ang. Correctional Offender Management Profiling for Alternative Sanctions), który wykorzystuje analitykę do oceny prawdopodobieństwa popełnienia przestępstwa. System jest często używany do wydawania wyroków. Ale poważnym problemem jest: czy może to naruszyć konstytucyjne prawo osoby do rzetelnego procesu, ponieważ istnieje realne ryzyko, że sztuczna inteligencja będzie niewłaściwa lub dyskryminująca? Właściwie na razie jest kilka dobrych odpowiedzi. Ale biorąc pod uwagę znaczenie, jakie algorytmy sztucznej inteligencji będą odgrywać w naszym systemie wymiaru sprawiedliwości, wydaje się, że warto założyć, że Sąd Najwyższy będzie tworzył nowe prawo.

**AGI (sztuczna ogólna inteligencja)**

W Części 1 dowiedzieliśmy się o różnicy między silną i słabą sztuczną inteligencją. I w większości jesteśmy w słabej fazie AI, w której technologia jest wykorzystywana do wąskich kategorii. Jeśli chodzi o silną sztuczną inteligencję, chodzi o ostateczność: zdolność maszyny do rywalizacji z człowiekiem. Jest to również znane jako sztuczna inteligencja ogólna lub AGI. Osiągnięcie tego jest prawdopodobnie za wiele lat, być może coś, czego możemy nie zobaczyć aż do następnego stulecia lub kiedykolwiek. Ale oczywiście jest kilku błyskotliwych badaczy, którzy wierzą, że AGI wkrótce nadejdzie. Jednym z nich jest Ray Kurzweil, wynalazca, futurolog, autor bestsellerów i dyrektor ds. inżynierii w Google. Jeśli chodzi o sztuczną inteligencję, odcisnął swoje piętno na branży, na przykład dzięki innowacjom w obszarach takich jak systemy zamiany tekstu na mowę. Kurzweil uważa, że AGI – w którym test Turinga zostanie złamany – nastąpi w 2019 r., a następnie do 2045 r. pojawi się Osobliwość. W tym miejscu będziemy mieli świat hybrydowych ludzi: po części człowiek, po części maszyna. Trochę szalony? Być może tak. Ale Kurzweil ma wielu głośnych zwolenników. Ale trzeba zrobić wiele ciężkich rzeczy, aby dostać się do AGI. Nawet pomimo wielkich postępów w zakresie głębokiego uczenia się, nadal wymaga dużych ilości danych i znacznej mocy obliczeniowej. Zamiast tego AGI będzie potrzebować nowych podejść, takich jak możliwość korzystania z uczenia się nienadzorowanego. Uczenie się transferu prawdopodobnie również będzie miało kluczowe znaczenie. Na przykład, jak omówiliśmy wcześniej w książce, sztuczna inteligencja była w stanie zrealizować nadludzkie możliwości podczas grania w gry takie jak Go. Ale uczenie transferowe oznaczałoby, że ten system byłby w stanie wykorzystać tę wiedzę do grania w inne gry lub uczenia się innych dziedzin. Ponadto AGI będzie musiała mieć zdolność do zdrowego rozsądku, abstrakcji, ciekawości i znajdowania związków przyczynowych, a nie tylko korelacji. Takie zdolności okazały się niezwykle trudne w przypadku komputerów. Jeśli już, to będą musiały nastąpić przełomy w technologiach sprzętowych i chipowych. Taka jest opinia Yanna LeCuna, jednego z czołowych badaczy sztucznej inteligencji na świecie i głównego naukowca zajmującego się sztuczną inteligencją na Facebooku. Uważa również, że w przypadku baterii i innych źródeł energii potrzebny jest znacznie większy postęp. Coś jeszcze, co będzie kluczowe: większa różnorodność w dziedzinie sztucznej inteligencji. Według raportu AI Now Institute około 80% profesorów AI to mężczyźni; a wśród pracowników badawczych AI na Facebooku i Google kobiety stanowiły odpowiednio 15% i 10%. Ta koślawość oznacza, że badania mogą być bardziej podatne na stronniczość. Ponadto nastąpi utrata korzyści płynących z szerszych poglądów i spostrzeżeń.

**Dobro społeczne**

Firma konsultingowa McKinsey & Co., zajmująca się doradztwem w zakresie zarządzania, napisała obszerne badanie zatytułowane „Zastosowanie sztucznej inteligencji dla dobra społecznego". Pokazuje, w jaki sposób sztuczna inteligencja jest wykorzystywana do radzenia sobie z takimi problemami, jak ubóstwo, klęski żywiołowe i poprawa edukacji. Badanie obejmuje około 160 przypadków użycia. Oto kilka przykładów:

• Analiza platform mediów społecznościowych może pomóc w śledzeniu wybuchu choroby.

• Organizacja non-profit o nazwie Rainforest Connection wykorzystuje TensorFlow do tworzenia modeli sztucznej inteligencji - na podstawie danych dźwiękowych – w celu zlokalizowania nielegalnego pozyskiwania drewna.

• Badacze zbudowali sieć neuronową, która jest szkolona na podstawie nagrań wideo przedstawiających kłusowników w Afryce. Dzięki temu dron przelatuje nad obszarami, aby wykryć osoby naruszające przepisy, na przykład za pomocą obrazów termowizyjnych w podczerwieni.

• Sztuczna inteligencja jest wykorzystywana do analizy danych z 55 893 działek w mieście Flint w celu znalezienia dowodów na zatrucie ołowiem. System opiera się głównie na modelu bayesowskim, który pozwala na bardziej wyrafinowane przewidywania toksyczności. Oznacza to, że pracownicy służby zdrowia mogą szybciej podjąć działania, jeśli pojawią się jakiekolwiek problemy w mieście, potencjalnie ratując życie.

**Wniosek**

Myślę, że ten temat jest dobrym miejscem na zakończenie tej książki. Niezależnie od wszystkich potencjalnych szkód i negatywnych konsekwencji, sztuczna inteligencja naprawdę ma nadzieję, że zmieni świat. Dobrą wiadomością jest to, że jest wielu ludzi, którzy koncentrują się na urzeczywistnieniu tego. Nie chodzi o zarabianie ogromnych pieniędzy czy zdobycie sławy. Celem jest zmiana świata.

**Kluczowe dania na wynos**

• Samochody autonomiczne nie są nowe. Ale punkt zwrotny dla rozwoju tej technologii nadszedł w 2004 roku, wraz z konkursem sponsorowanym przez DARPA.

• Niektóre z kluczowych elementów autonomicznego samochodu obejmują kamery wideo, Lidar (lasery, które pomagają przetwarzać środowisko) i czujniki (takie jak do wykrywania innych pojazdów i przeszkód, takich jak krawężniki).

• Jeśli chodzi o definiowanie tego, co jest „autonomiczne”, istnieje pięć poziomów. Piąty to sytuacja, w której pojazd jest w pełni autonomiczny.

• Niektóre z wyzwań dla samochodów autonomicznych to infrastruktura (istniejące autostrady nie są idealne), regulacje, koszty i przyjęcie przez konsumentów.

• Stany Zjednoczone są uważane za światowego lidera w dziedzinie sztucznej inteligencji. Ale to może się wkrótce zmienić. Chiny dużo inwestują w sztuczną inteligencję i mają duże zalety, takie jak ogromne ilości danych i duża liczba wykwalifikowanych inżynierów.

• Jedną z obaw związanych ze sztuczną inteligencją jest to, że doprowadzi ona do masowego bezrobocia, zarówno w przypadku pracy fizycznej, jak i tymczasowej. To prawda, że technologia już wpłynęła na branże, takie jak produkcja, ale rynki okazały się zdolne do adaptacji. Ale jeśli sztuczna inteligencja ma charakter transformacyjny, może to doprowadzić do wielu zakłóceń. Dlatego prawdopodobnie będzie potrzebne szkolenie i przekwalifikowanie do nowych zawodów.

• Drony mają duży wpływ na działania wojenne. Ale dzięki sztucznej inteligencji możliwe staje się umożliwienie tej technologii podejmowania decyzji na polu bitwy. Teraz jest wielu ludzi, którzy postrzegają to jako duży problem. Jednak Stany Zjednoczone, Rosja i inne kraje wydają się być skoncentrowane na pogoni za bronią autonomiczną.

• Ale jeśli chodzi o działania wojenne – przynajmniej w najbliższym czasie – sztuczna inteligencja może mieć bardziej natychmiastowy efekt w postaci rozpowszechniania fałszywych informacji. Widzieliśmy to podczas ingerencji Rosjan w wybory prezydenckie w 2016 roku.

• Oczekuje się, że sztuczna inteligencja znacznie pomoże w procesie odkrywania leków. Już teraz operatorzy megafarmaceutów, tacy jak Gilead, badają tę technologię. Sztuczna inteligencja może nie tylko przetwarzać ogromne ilości danych, ale także wykrywać wzorce, które mogą nie być dostrzegalne dla ludzi.

• W miarę jak sztuczna inteligencja staje się coraz bardziej wszechobecna, rosną obawy o prywatność i przejrzystość. Z tego powodu w Kongresie, w tym w miastach i stanach, pojawiły się ruchy, aby wprowadzić regulacje. Nie jest jasne, co może się wydarzyć, ale wydaje się prawdopodobne, że zobaczymy więcej ograniczeń. W międzyczasie niektóre firmy starają się działać proaktywnie, na przykład tworząc rady etyki.

• Sztuczna ogólna inteligencja lub AGI to miejsce, w którym system ma ludzką inteligencję. Jesteśmy jednak prawdopodobnie daleko od tego. Powodem jest to, że będą potrzebne nowe innowacje w sztucznej inteligencji, takie jak nienadzorowane uczenie się i tworzenie nowego sprzętu.