

Przeprowadzanie analizy danych dla AI

Gromadzenie danych nie jest nowoczesnym zjawiskiem; ludzie gromadzili dane od stuleci. Bez względu na to, czy informacje pojawiają się w formie tekstowej, czy liczbowej, ludzie zawsze doceniali sposób, w jaki dane opisują otaczający świat, i używają ich do przemieszczania cywilizacji do przodu. Dane mają wartość samą w sobie. Korzystając z jego treści, ludzkość może się uczyć, przekazywać krytyczne informacje potomkom (nie trzeba wymyślać koła na nowo) i skutecznie działać w świecie. Ludzie ostatnio dowiedzieli się, że dane zawierają więcej niż informacje powierzchniowe. Jeśli dane mają odpowiednią formę numeryczną, możesz zastosować specjalne techniki opracowane przez matematyków i statystów, zwane technikami analizy danych, i wyciągnąć z nich jeszcze więcej wiedzy. Ponadto, poczynając od prostej analizy danych, można wyodrębnić istotne informacje i dane tematyczne do bardziej zaawansowanych analiz za pomocą algorytmów uczenia maszynowego zdolnych do przewidywania przyszłości, klasyfikowania informacji i skutecznego podejmowania decyzji. Analiza danych i uczenie maszynowe umożliwiają przekraczanie wcześniejszych limitów wykorzystania danych w celu opracowania inteligentniejszej sztucznej inteligencji. W tym rozdziale przedstawiono analizę danych. Pokazuje, jak wykorzystywać dane jako narzędzie edukacyjne do rozwiązywania trudnych problemów związanych z AI, takich jak sugerowanie klientowi odpowiedniego produktu, rozumienie języka mówionego, tłumaczenie angielskiego na niemiecki, automatyzacja jazdy samochodem i wiele innych.

Definiowanie analizy danych

Obecna era nazywana jest erą informacji, nie tylko dlatego, że jesteśmy tak bogaci w dane, ale także dlatego, że społeczeństwo osiągnęło pewną dojrzałość w analizowaniu i wydobywaniu z niej informacji. Firmy takie jak Alphabet (Google), Amazon, Apple, Facebook i Microsoft, które oparły swoją działalność na danych, są uważane za pięć najbardziej wartościowych firm na świecie. Takie firmy nie tylko gromadzą i przechowują przechowywane dane dostarczane przez ich cyfrowe procesy; wiedzą też, jak uczynić ją tak cenną jak ropa naftowa, stosując precyzyjną i rozbudowaną analizę danych. Google na przykład rejestruje dane z Internetu w ogóle, a także z własnej wyszukiwarki. Być może spotkałeś się z mantrą „dane to nowa ropa” w wiadomościach, czasopiśmie lub na konferencjach. Z oświadczenia wynika, że dane mogą uczynić firmę bogatą, a do tego potrzeba umiejętności i ciężkiej pracy. Chociaż wielu zastosowało tę koncepcję i sprawiło, że okazała się ona niesamowicie skuteczna, to Clive Humby, brytyjski matematyk, po raz pierwszy zrównał dane z ropą naftową, biorąc pod uwagę jego doświadczenie z danymi konsumentów w sektorze detalicznym. Humby jest znany z tego, że należy do założycieli brytyjskiej firmy marketingowej Dunhumby, a także do programu kart lojalnościowych Tesco. W 2006 r. Humby podkreślił również, że dane to nie tylko pieniądze, które spadają z nieba; wymaga wysiłku, aby były użyteczne. Tak jak nie możesz natychmiast użyć nierafinowanego oleju, ponieważ musi on zostać zmieniony w coś innego w wyniku procesów chemicznych, które zamieniają go w gaz, tworzywa sztuczne lub inne chemikalia, tak więc dane muszą ulec znacznym przekształceniom, aby uzyskać wartość. Najbardziej podstawowe transformacje danych nazywane są analizą danych i można je uznać za podstawowe transformacje chemiczne, które olej przechodzi w rafinerii, zanim stanie się cennym paliwem lub produktami z tworzyw sztucznych. Za pomocą samej analizy danych możesz położyć podwaliny pod bardziej zaawansowane procesy analizy danych, które możesz zastosować do danych. Analiza danych, w zależności od kontekstu, odnosi się do dużej liczby możliwych operacji na danych, czasami specyficznych dla niektórych branż lub zadań. Możesz podzielić wszystkie te transformacje na cztery duże i ogólne rodziny, które dają wyobrażenie o tym, co dzieje się podczas analizy danych:

* Przekształcanie: Zmienia wygląd danych. Termin transformacja odnosi się do różnych procesów, chociaż najczęstszym jest umieszczanie danych w uporządkowanych wierszach i kolumnach w formie

macierzowym (zwanym także transformacją pliku płaskiego). Na przykład nie można skutecznie przetwarzać danych towarów zakupionych w supermarkecie przed umieszczeniem każdego klienta w jednym wierszu i dodaniem produktów zakupionych do pojedynczych kolumn w tym wierszu jako wpisy liczbowe zawierające ilości lub wartość pieniężną. Przekształcanie może również obejmować wyspecjalizowane przekształcenia numeryczne, takie jak przeskalowanie, za pomocą którego zmienia się średnią lub wartości minimalne i maksymalne szeregu liczbowego, aby dostosować go do algorytmu.

* **Oczyszczanie:** Naprawia niedoskonałe dane. W zależności od sposobu pozyskiwania danych mogą wystąpić różne problemy, takie jak brak informacji, skrajny zasięg lub po prostu nieprawidłowe wartości. Na przykład dane w supermarkecie mogą powodować błędy, gdy towary mają nieprawidłowe ceny. Niektóre dane są kontradictoryjne, co oznacza, że zostały stworzone, aby zepsuć wszelkie wnioski. Na przykład produkt może zawierać fałszywe recenzje w Internecie, które zmieniają jego pozycję. Oczyszczanie pomaga w usuwaniu przeciwnych przykładów z danych i zapewnia wiarygodność wniosków.

* **Kontrola:** Sprawdza poprawność danych. Analiza danych to praca głównie ludzka, choć oprogramowanie odgrywa dużą rolę. Ludzie mogą łatwo rozpoznać wzorce i dostrzec dziwne elementy danych. Z tego powodu analiza danych generuje wiele statystyk danych i zapewnia przydatną wizualizację, taką jak Health InfoScape firmy MIT Senseable Cities i General Electric, która pomaga uchwycić treści informacyjne na pierwszy rzut oka. Na przykład możesz zobaczyć, jak choroby łączą się ze sobą na podstawie danych przetworzonych z 72 milionów rekordów.

* **Modelowanie:** Chwyta związki między elementami obecnymi w danych. Aby wykonać to zadanie, potrzebujesz narzędzi zaczerpniętych ze statystyk, takich jak korelacje, testy t, regresja liniowa i wiele innych, które mogą ustalić, czy wartość naprawdę różni się od innej, czy tylko jest z nią powiązana. Na przykład, analizując wydatki w supermarkecie, możesz stwierdzić, że osoby kupujące pieluchy również kupują piwo. Analiza statystyczna wykazuje, że te dwa produkty są powiązane wielokrotnie w tych samych koszach.

Analiza danych nie jest magią. Transformacje, czyszczenie, inspekcja i modelowanie wykonuje się za pomocą sumowania i mnożenia masy na podstawie rachunku macierzowego (który jest niczym innym jak długimi sekwencjami sumowania i mnożenia, których wiele osób uczy się w szkole). Arsenal analizy danych zapewnia również narzędzia statystyczne, takie jak średnia i wariancja, które opisują rozkład danych lub zaawansowane narzędzia, takie jak analiza korelacji i regresji liniowej, które ujawniają, czy można powiązać ze sobą zdarzenia lub zjawiska (takie jak kupowanie pieluch i piwa) na podstawie dowodów.

Zrozumienie, dlaczego analiza jest ważna

Analiza danych jest niezbędna dla AI. W rzeczywistości żadna współczesna sztuczna inteligencja nie jest możliwa bez wizualizacji, czyszczenia, przekształcania i modelowania danych, zanim zaawansowane algorytmy nie wejdą do procesu i nie zamieniają ich w informacje o jeszcze większej wartości niż wcześniej. Na początku, kiedy AI składało się wyłącznie z rozwiązań algorytmicznych i systemów eksperckich, naukowcy i eksperci starannie przygotowali dane, aby je zasilić. Dlatego na przykład, jeśli ktoś chciałby, aby algorytm sortował informacje, ekspert danych umieścił dane na listach (uporządkowane sekwencje elementów danych) lub w innych strukturach danych, które mogłyby odpowiednio zawierać informacje i umożliwić ich pożądaną manipulację. W tym czasie eksperci od danych gromadzili i organizowali dane, tak aby ich zawartość i forma były dokładnie zgodne z oczekiwaniami, ponieważ zostały one utworzone w tym konkretnym celu. Manipulowanie znanymi danymi w określonej formie stanowiło poważne ograniczenie, ponieważ tworzenie danych wymagało

dużo czasu i energii; w związku z tym algorytmy otrzymały mniej informacji niż jest obecnie dostępnych. Dzisiaj uwaga została przeniesiona z tworzenia danych na przygotowanie danych przy użyciu analizy danych. Chodzi o to, że różne źródła już wytwarzają dane w tak dużych ilościach, że można znaleźć to, czego potrzebujesz, bez konieczności tworzenia specjalnych danych dla zadania. Na przykład wyobraź sobie, że chcesz, aby AI kontrolowała drzwi Twojego zwierzaka, aby wpuszczać koty i psy, ale nie pozwalać innym zwierzętom. Współczesne algorytmy AI uczą się na podstawie danych specyficznych dla zadania, co oznacza przetwarzanie dużej liczby zdjęć pokazujących przykłady psów, kotów i innych zwierząt. Najprawdopodobniej przyjedzie taki ogromny zestaw zdjęć z Internetu, może z serwisów społecznościowych lub wyszukiwań obrazów. Wcześniej wykonanie podobnego zadania oznaczało, że algorytmy wykorzystywałyby tylko kilka konkretnych danych wejściowych dotyczących na przykład kształtów, rozmiarów i charakterystycznych cech zwierząt. Niedobór danych oznaczał, że mogliby wykonać tylko kilka ograniczonych zadań. W rzeczywistości nie istnieją przykłady sztucznej inteligencji, która może zasilać drzwi dla zwierząt domowych przy użyciu klasycznych algorytmów lub systemów eksperckich. Analiza danych przychodzi na ratunek nowoczesnym algorytmom poprzez dostarczanie informacji o obrazach pobranych z Internetu. Dzięki analizie danych AI może odkryć rozmiary, różnorodność, liczbę kolorów, słowa użyte w tytułach obrazów i tak dalej. Jest to część kontroli danych i, w tym przypadku, jest to konieczne do ich wyczyszczenia i przekształcenia. Na przykład analiza danych może pomóc w wykryciu zdjęcia zwierzęcia błędnie oznaczonego kota (nie chcesz mylić AI) i pomóc przekształcić obrazy w taki sam format kolorów (na przykład odcienie szarości) i ten sam rozmiar.

Ponowne rozważenie wartości danych

Wraz z eksplozją dostępności danych na urządzeniach cyfrowych, dane nabierają nowych niuansów wartości i użyteczności wykraczających poza początkowy zakres nauczania (nauczania) i przekazywania wiedzy (przekazywanie danych). Obfitość danych, gdy są one przekazywane do analizy danych, zyskuje nowe funkcje, które odróżniają je od informacyjnych:

* Dane lepiej opisują świat, prezentując szeroki wachlarz faktów, a bardziej szczegółowo, podając niuanse dla każdego faktu. Stało się tak obfite, że obejmuje każdy aspekt rzeczywistości. Możesz użyć go do ujawnienia, jak nawet pozornie niezwiązane ze sobą rzeczy i fakty faktycznie się ze sobą wiążą.

* Dane pokazują, w jaki sposób fakty kojarzą się ze zdarzeniami. Możesz wyprowadzić ogólne zasady i dowiedzieć się, jak świat się zmieni lub przekształci, biorąc pod uwagę pewne przesłanki. Gdy ludzie działają w określony sposób, dane zapewniają również pewną zdolność przewidywania.

Pod pewnymi względami dane zapewniają nam nowe supermoce. Chris Anderson, poprzedni redaktor naczelny Wired, omawia, w jaki sposób duże ilości danych mogą pomóc w odkryciach naukowych poza metodą naukową. Autor opiera się na przykładzie osiągnięć Google w branży reklamowej i tłumaczeniowej, w których Google osiągnął znaczącą pozycję nie poprzez stosowanie określonych modeli lub teorii, ale raczej przez zastosowanie algorytmów do uczenia się na podstawie danych. Podobnie jak w reklamie, dane naukowe (takie jak z fizyki czy biologii) mogą wspierać innowacje, które pozwalają naukowcom podchodzić do problemów bez hipotez, zamiast uwzględniać różnice występujące w dużych ilościach danych i wykorzystywać algorytmy odkrywania. Galileo Galilei polegał na metodzie naukowej, aby stworzyć podstawy współczesnej fizyki i astronomii. Większość wczesnych postępów opiera się na obserwacjach i kontrolowanych eksperymentach, które określają przyczyny tego, jak i dlaczego coś się dzieje. Zdolność do innowacji przy użyciu samych danych stanowi przełom w sposobie, w jaki rozumiemy świat. W przeszłości naukowcy przeprowadzili niezliczone obserwacje i dokonali wielu dedukcji, aby opisać fizykę wszechświata. Ten ręczny proces pozwolił ludziom znaleźć podstawowe prawa świata, w którym żyjemy. Analiza danych, łącząc obserwacje wyrażone jako dane

wejściowe i wyjściowe, pozwala nam określić, jak rzeczy działają i zdefiniować, dzięki uczeniu maszynowemu, przybliżonym regułom lub prawom, naszego świata bez konieczności uciekania się do ręcznych obserwacji i wniosków. Proces jest teraz szybszy i bardziej automatyczny.

Definiowanie uczenia maszynowego

Szczytem analizy danych jest uczenie maszynowe. Możesz z powodzeniem zastosować uczenie maszynowe tylko wtedy, gdy analiza danych zapewni prawidłowe wprowadzanie danych. Jednak tylko uczenie maszynowe może powiązać szereg wyników i danych wejściowych, a także skutecznie określić zasady działania za nimi. Analiza danych koncentruje się na zrozumieniu danych i manipulowaniu nimi, tak aby stały się one bardziej użyteczne i zapewniały wgląd w świat, podczas gdy uczenie maszynowe ściśle koncentruje się na pobieraniu danych z danych i opracowywaniu działającej, wewnętrznej reprezentacji świata, którą można wykorzystać do celów praktycznych. Uczenie maszynowe umożliwia ludziom wykonywanie takich zadań, jak przewidywanie przyszłości, znaczące klasyfikowanie rzeczy i podejmowanie najlepszej racjonalnej decyzji w danym kontekście. Główną ideą uczenia maszynowego jest to, że można przedstawić rzeczywistość za pomocą funkcji matematycznej, której algorytm nie zna z góry, ale którą może odgadnąć po obejrzeniu niektórych danych. Możesz wyrazić rzeczywistość i całą jej trudną złożoność w kategoriach nieznanych funkcji matematycznych, które algorytmy uczenia maszynowego znajdują i udostępniają. Ta koncepcja jest podstawową ideą wszystkich rodzajów algorytmów uczenia maszynowego. Uczenie się w uczeniu maszynowym jest czysto matematyczne i kończy się na powiązaniu pewnych danych wejściowych z niektórymi wynikami. Nie ma to nic wspólnego ze zrozumieniem tego, czego nauczył się algorytm (analiza danych buduje zrozumienie do pewnego stopnia), dlatego proces uczenia się jest często opisywany jako szkolenie, ponieważ algorytm jest szkolony, aby dopasować poprawną odpowiedź (wynik) do każdego oferowanego pytania (wejście). Pomimo braku celowego zrozumienia i bycia po prostu procesem matematycznym, uczenie maszynowe może okazać się przydatne w wielu zadaniach. Zapewnia aplikacji AI moc robienia najbardziej racjonalnych rzeczy w określonym kontekście, gdy uczenie się odbywa się przy użyciu właściwych danych. Poniższe sekcje opisują bardziej szczegółowo, w jaki sposób uczenie maszynowe działa, jakie korzyści można uzyskać i jakie są ograniczenia korzystania z uczenia maszynowego w aplikacji.

Zrozumienie działania uczenia maszynowego

Wiele osób jest przyzwyczajonych do tego, że aplikacje zaczynają się od funkcji, akceptują dane jako dane wejściowe, a następnie zapewniają wynik. Na przykład programista może utworzyć funkcję o nazwie `Add()`, która przyjmuje dwie wartości jako dane wejściowe, takie jak 1 i 2. Wynik `Add()` wynosi 3. Wyjściem tego procesu jest wartość. W przeszłości napisanie programu oznaczało zrozumienie funkcji służącej do manipulowania danymi w celu uzyskania określonego wyniku przy użyciu określonych danych wejściowych. Uczenie maszynowe zmienia ten proces. W tym przypadku wiesz, że masz dane wejściowe, takie jak 1 i 2. Wiesz również, że pożądanym wynikiem jest 3. Jednak nie wiesz, jaką funkcję zastosować, aby utworzyć pożądanym wynikiem. Szkolenie zapewnia algorytm uczącego się z wszelkiego rodzaju przykładami poświadczonych danych wejściowych i oczekiwanych wyników z tych danych. Następnie uczący się używa tych danych wejściowych do utworzenia funkcji. Innymi słowy, szkolenie to proces, w którym algorytm uczący się odwzorowuje elastyczną funkcję na dane. Dane wyjściowe to zazwyczaj prawdopodobieństwo pewnej klasy lub wartości liczbowej. Aby dać wyobrażenie o tym, co dzieje się w procesie szkolenia, wyobraź sobie, że dziecko uczy się odróżniać drzewa od innych obiektów. Zanim dziecko może to zrobić w sposób niezależny, nauczyciel przedstawia dziecku pewną liczbę obrazów drzewa, wraz ze wszystkimi faktami, które odróżniają drzewo od innych obiektów świata. Takimi faktami mogą być takie cechy, jak materiał drzewa (drewno), jego części (pień, gałęzie, liście lub igły, korzenie) oraz lokalizacja (zasadzone w glebie). Dziecko tworzy wyobrażenie o

tym, jak wygląda drzewo, porównując wyświetlanie cech drzewa z obrazami innych, różnych przedmiotów, takich jak meble wykonane z drewna, ale które nie mają wspólnych cech z drzewem. Klasyfikator uczenia maszynowego działa tak samo. Buduje swoje zdolności poznawcze, tworząc matematyczne sformułowanie, które obejmuje wszystkie podane cechy w sposób, który tworzy funkcję, która może odróżnić jedną klasę od drugiej. Udawaj, że istnieje sformułowanie matematyczne, zwane także funkcją celu, wyrażającą cechy drzewa. W takim przypadku klasyfikator uczący się może szukać swojej reprezentacji jako repliki lub aproksymacji (inna funkcja, która działa podobnie). Zdolność do wyrażenia takiego matematycznego sformułowania jest zdolnością do reprezentacji klasyfikatora. Z matematycznego punktu widzenia można wyrazić proces reprezentacji w uczeniu maszynowym za pomocą równoważnego odwzorowania terminów. Mapowanie ma miejsce, gdy odkryjesz budowę funkcji, obserwując jej wyniki. Skuteczne mapowanie w uczeniu maszynowym jest podobne do dziecka internalizującego ideę obiektu. Dziecko w skuteczny sposób rozumie abstrakcyjne reguły wywodzące się z faktów o świecie, tak że na przykład gdy dziecko zobaczy drzewo, natychmiast je rozpoznaje. Taka reprezentacja (abstrakcyjne reguły wyprowadzone z faktów ze świata rzeczywistego) jest możliwa, ponieważ algorytm uczenia ma wiele wewnętrznych parametrów (składających się z wektorów i macierzy wartości), które są równe pamięci algorytmu dla pomysłów, które są odpowiednie dla jego działania mapowania, które łączy cechy klas odpowiedzi. Wymiary i rodzaj parametrów wewnętrznych ograniczają rodzaj funkcji docelowych, których algorytm może się nauczyć. Mechanizm optymalizacji w algorytmie zmienia parametry od nich na początkowe wartości podczas nauki reprezentowania ukrytej funkcji celu. Podczas optymalizacji algorytm wyszukuje możliwe warianty kombinacji parametrów, aby znaleźć taki, który pozwala na prawidłowe mapowanie między funkcjami i klasami podczas treningu. Ten proces ocenia wiele potencjalnych funkcji docelowych spośród tych, które algorytm uczenia może odgadnąć. Zbiór wszystkich potencjalnych funkcji, które algorytm uczenia może odkryć, to przestrzeń hipotez. Możesz nazwać wynikowy klasyfikator z jego ustawionymi parametrami hipotezą, w uczeniu maszynowym można powiedzieć, że algorytm ustawił parametry do replikacji funkcji docelowej i jest teraz gotowy do zdefiniowania poprawnych klasyfikacji (fakt wykazany później). Przestrzeń hipotez musi zawierać wszystkie warianty parametrów wszystkich algorytmów uczenia maszynowego, które chcesz spróbować odwzorować na nieznaną funkcję podczas rozwiązywania problemu z klasyfikacją. Różne algorytmy mogą mieć różne przestrzenie hipotez. Najważniejsze jest to, że przestrzeń hipotez zawiera funkcję celu (lub jej przybliżenie, która jest inną, ale podobną funkcją, ponieważ w końcu wszystko, czego potrzebujesz, to coś, co działa).

Możesz sobie wyobrazić tę fazę jako czas, w którym dziecko eksperymentuje z wieloma różnymi kreatywnymi pomysłami, gromadząc wiedzę i doświadczenia (analogię do podanych cech) w celu stworzenia wizualizacji drzewa. Oczywiście rodzice są zaangażowani w tę fazę i zapewniają odpowiedni wkład środowiskowy. W uczeniu maszynowym ktoś musi podać odpowiednie algorytmy uczenia się, podać niektóre parametry, które nie są możliwe do nauczenia (zwane hiperparametrami), wybrać zestaw przykładów do nauki i wybrać funkcje towarzyszące przykładom. Tak jak dziecko nie zawsze może nauczyć się odróżniać dobro od zła, jeśli jest pozostawione samemu sobie na świecie, tak algorytmy uczenia maszynowego potrzebują ludzi, aby uczyć się z powodzeniem.

Zrozumienie zalet uczenia maszynowego

Obecnie AI i uczenie maszynowe są używane w wielu aplikacjach. Jedynym problemem jest to, że technologia działa tak dobrze, że nie wiesz, że ona w ogóle istnieje. W rzeczywistości możesz być zaskoczony, gdy wiele urządzeń w domu korzysta już z obu technologii. Obie technologie zdecydowanie pojawiają się w twoim samochodzie i miejscu pracy. W rzeczywistości zastosowania zarówno sztucznej inteligencji, jak i uczenia maszynowego w milionach - wszystko to bezpiecznie poza zasięgiem wzroku,

nawet jeśli mają dość dramatyczny charakter. Oto tylko kilka sposobów wykorzystania sztucznej inteligencji:

* Wykrywanie oszustw: Otrzymujesz telefon od wystawcy karty kredytowej z pytaniem, czy dokonałeś określonego zakupu. Firma wydająca karty kredytowe nie jest wścibska; po prostu ostrzega Cię o fakcie, że ktoś może dokonać zakupu przy użyciu Twojej karty. Sztuczna inteligencja osadzona w kodzie wystawcy karty kredytowej wykryła nieznaną wzorcową wydatków i powiadomiła o tym kogoś.

* Planowanie zasobów: Wiele organizacji musi efektywnie planować wykorzystanie zasobów. Na przykład szpital może być zmuszony ustalić, gdzie umieścić pacjenta na podstawie jego potrzeb, dostępności wykwalifikowanych ekspertów i czasu, jaki lekarz spodziewa się w szpitalu.

* Złożona analiza: ludzie często potrzebują pomocy przy złożonej analizie, ponieważ istnieje dosłownie zbyt wiele czynników do rozważenia. Na przykład ten sam zestaw objawów może wskazywać na więcej niż jeden problem. Lekarz lub inny ekspert może potrzebować pomocy w postawieniu diagnozy w odpowiednim czasie, aby uratować życie pacjenta.

* Automatyzacja: każda forma automatyzacji może skorzystać z dodania sztucznej inteligencji do obsługi nieoczekiwanych zmian lub zdarzeń. Problem z niektórymi rodzajami automatyzacji dzisiaj polega na tym, że nieoczekiwane zdarzenie, takie jak obiekt w niewłaściwym miejscu, może faktycznie spowodować zatrzymanie automatyzacji. Dodanie sztucznej inteligencji do automatyzacji może pozwolić automatyzacji na obsługę nieoczekiwanych zdarzeń i kontynuowanie działania tak, jakby nic się nie stało.

* Obsługa klienta: Linia obsługi klienta, do której dzwonisz dzisiaj, może nie mieć ludzi. Automatyzacja jest wystarczająco dobra, aby śledzić skrypty i korzystać z różnych zasobów, aby obsłużyć większość pytań. Przy dobrym odbiciu głosu (zapewnionym również przez sztuczną inteligencję) możesz nawet nie być w stanie powiedzieć, że rozmawiasz z komputerem.

* Systemy bezpieczeństwa: Wiele systemów bezpieczeństwa stosowanych obecnie w różnego rodzaju maszynach opiera się na sztucznej inteligencji, która przejmuje kontrolę nad pojazdem w czasach kryzysu. Na przykład wiele automatycznych układów hamowania opiera się na sztucznej inteligencji, aby zatrzymać samochód na podstawie wszystkich danych wejściowych, które może zapewnić pojazd, takich jak kierunek poślizgu.

* Wydajność maszyny: AI może pomóc kontrolować maszynę w taki sposób, aby uzyskać maksymalną wydajność. AI kontroluje wykorzystanie zasobów, aby system nie przekroczył prędkości ani innych celów. Każda uncja mocy jest wykorzystywana dokładnie w razie potrzeby, aby zapewnić pożądane usługi.

Ta lista nawet nie zaczyna drapać powierzchni. AI można znaleźć na wiele innych sposobów. Jednak przydatne jest również przeglądanie zastosowań uczenia maszynowego poza normalnym królestwem, które wielu uważa za dziedzinę sztucznej inteligencji. Oto kilka zastosowań uczenia maszynowego, których możesz nie kojarzyć z AI:

* Kontrola dostępu: W wielu przypadkach kontrola dostępu to propozycja tak lub nie. Karta inteligentna pracownika zapewnia dostęp do zasobu w taki sam sposób, w jaki ludzie używali kluczy od stuleci. Niektóre zamki umożliwiają ustawianie godzin i dat, dla których dostęp jest dozwolony, ale gruboziarnista kontrola nie odpowiada na wszystkie potrzeby. Korzystając z uczenia maszynowego, możesz ustalić, czy pracownik powinien uzyskać dostęp do zasobu na podstawie roli i potrzeb. Na przykład pracownik może uzyskać dostęp do pokoju szkoleniowego, gdy szkolenie odzwierciedla rolę pracownika.

* Ochrona zwierząt: ocean może wydawać się wystarczająco duży, aby pozwolić zwierzętom i statkom na wspólne zamieszkanie bez problemu. Niestety co roku wiele zwierząt ginie podstatkami. Algorytm uczenia maszynowego może pozwolić statkom unikać zwierząt, ucząc się dźwięków i cech zarówno zwierzęcia, jak i statku.

* Przewidywanie czasów oczekiwania: większość ludzi nie lubi czekać, gdy nie ma pojęcia, jak długo to potrwa. Uczenie maszynowe pozwala aplikacji na określenie czasu oczekiwania na podstawie poziomów zatrudnienia, obciążenia personelu, złożoności problemów, które personel próbuje rozwiązać, dostępności zasobów i tak dalej.

Bycie przydatnym: przyziemność

Mimo że filmy sugerują, że sztuczna inteligencja z pewnością zrobi ogromny plusk, a czasami zdarza się, że w prawdziwym życiu widać niesamowite zastosowania AI, większość zastosowań AI jest przyziemna, a nawet nudna. Na przykład w ostatnim artykule opisano, w jaki sposób Verizon używa języka R do uczenia maszynowego do analizy danych o naruszeniach bezpieczeństwa i automatyzacji corocznych raportów bezpieczeństwa. Czynność wykonania tej analizy jest nudna w porównaniu z innymi rodzajami aktywności AI, ale Verizon oszczędza pieniądze, wykonując analizę przy użyciu R, a wyniki są również lepsze.

Określanie limitów uczenia maszynowego

Uczenie maszynowe polega na algorytmach do analizy ogromnych zestawów danych. Obecnie uczenie maszynowe nie jest w stanie zapewnić sztucznej inteligencji, jaką prezentują filmy. Nawet najlepsze algorytmy nie potrafią myśleć, czuć, wykazywać żadnej formy samoświadomości ani ćwiczyć wolnej woli. Uczenie maszynowe pozwala wykonywać analizy predykcyjne znacznie szybciej niż jakikolwiek inny człowiek. W rezultacie uczenie maszynowe może pomóc ludziom pracować wydajniej. Zatem obecny stan sztucznej inteligencji polega na przeprowadzaniu analiz, ale ludzie muszą nadal brać pod uwagę implikacje tej analizy i podejmować wymagane decyzje moralne i etyczne. Zasadniczo uczenie maszynowe stanowi tylko część uczenia się sztucznej inteligencji, a ta część nie jest prawie gotowa do stworzenia sztucznej inteligencji takiej, jaką widzisz w filmach. Głównym punktem pomieszenia uczenia się z inteligencją jest założenie, że po prostu dlatego, że maszyna staje się lepsza w swojej pracy (uczenie się), jest również świadoma (inteligencja). Nic nie obsługuje tego poglądu uczenia maszynowego. To samo zjawisko występuje, gdy ludzie zakładają, że komputer celowo powoduje dla nich problemy. Komputer nie może przypisywać emocji i dlatego działa tylko na podstawie dostarczonych danych wejściowych i instrukcji zawartych w aplikacji, aby je przetworzyć. Prawdziwa sztuczna inteligencja pojawi się w końcu, gdy komputery będą w stanie naśladować sprytną kombinację używaną przez naturę:

* Genetyka: powolne uczenie się z pokolenia na pokolenie

* Nauczanie: szybkie uczenie się ze zorganizowanych źródeł

* Eksploracja: spontaniczne uczenie się za pośrednictwem mediów i interakcji z innymi

Oprócz tego, że uczenie maszynowe składa się z matematyki, funkcje zoptymalizowane do określonego celu, inne słabości ujawniają ograniczenia uczenia maszynowego. Musisz wziąć pod uwagę trzy ważne ograniczenia:

* Reprezentacja: Reprezentowanie niektórych problemów za pomocą funkcji matematycznych nie jest łatwe, szczególnie w przypadku złożonych problemów, takich jak naśladowanie ludzkiego mózgu. W

tej chwili uczenie maszynowe może rozwiązać pojedyncze, specyficzne problemy, które odpowiadają na proste pytania, takie jak „Co to jest to?” i „ile to kosztuje?” i „Co dalej?”

* Przeuczenie: algorytmy uczenia maszynowego mogą się dowiedzieć, co Cię interesuje, ale tak naprawdę nie. Dlatego ich wewnętrzne funkcje w większości zapamiętują dane bez uczenia się na ich podstawie. Przeuczenie występuje, gdy algorytm uczy się zbyt wiele na podstawie danych, aż do utworzenia funkcji i reguł, które w rzeczywistości nie istnieją.

* Brak skutecznego uogólnienia z powodu ograniczonych danych: Algorytm uczy się tego, czego go uczysz. Jeśli podasz algorytm ze złymi lub dziwnymi danymi, zachowuje się w nieoczekiwany sposób.

Jeśli chodzi o reprezentację, jeden algorytm uczący się może nauczyć się wielu różnych rzeczy, ale nie każdy algorytm nadaje się do określonych zadań. Niektóre algorytmy są na tyle ogólne, że mogą grać w szachy, rozpoznawać twarze na Facebooku i diagnozować raka u pacjentów. Algorytm redukuje dane wejściowe i oczekiwane wyniki tych danych wejściowych do funkcji w każdym przypadku, ale funkcja ta jest specyficzna dla rodzaju zadania, które ma wykonywać algorytm. Sekret uczenia maszynowego jest uogólnienie. Jednak wraz z uogólnieniem pojawiają się problemy z nadmiernym dopasowaniem i stronniczością danych. Celem jest uogólnienie funkcji wyjściowej, aby działała na danych wykraczających poza przykłady szkoleniowe. Weźmy na przykład filtr antyspamowy. Powiedz, że twój słownik zawiera 100 000 słów (mały słownik). Ograniczony zestaw danych szkoleniowych obejmujący 4000 lub 5000 kombinacji słów musi tworzyć uogólnioną funkcję, która może następnie znaleźć spam w $2^{100\,000}$ kombinacji, które funkcja zobaczy podczas pracy z rzeczywistymi danymi. W takich warunkach algorytm wydaje się uczyć zasad języka, ale w rzeczywistości nie radzi sobie dobrze.

Algorytm może poprawnie reagować na sytuacje podobne do tych, które są wykorzystywane do jego szkolenia, ale w zupełnie nowych sytuacjach nie będzie miał pojęcia. Lub może wykazywać uprzedzenia w nieoczekiwany sposób ze względu na rodzaj danych wykorzystywanych do szkolenia. Na przykład Microsoft wyszkolił AI, Tay, aby rozmawiać z ludźmi na Twitterze i uczyć się na ich odpowiedziach. Niestety, interakcje stały się szalone, ponieważ użytkownicy narażali Tay na mowę nienawiści, budząc obawy o dobroć dowolnej sztucznej inteligencji napędzanej technologią uczenia maszynowego. Problem polegał na tym, że algorytm uczenia maszynowego był zasilany złymi, niefiltrowanymi danymi (Microsoft nie użył odpowiedniej analizy danych do czyszczenia i odpowiednio zrównoważyć dane wejściowe), co przewyższyło wynik. Overfitting wybrał niewłaściwy zestaw funkcji do reprezentowania świata w sposób ogólny, zgodnie z potrzebami, aby uniknąć dostarczania wyników niezgodnych, takich jak mowa nienawiści. Inne sztucznej inteligencji przeszkolone do rozmowy z ludźmi, takie jak nagradzane Mitsuku, nie są narażone takie same ryzyko jak Tay, ponieważ ich nauka jest ściśle kontrolowana i nadzorowana przez analizę danych i ocenę człowieka.

Zastanawianie się, jak uczyć się na danych

Wszystko w uczeniu maszynowym obraca się wokół algorytmów. Algorytm to procedura lub formuła używana do rozwiązania problemu. Domena problemowa wpływa na rodzaj potrzebnego algorytmu, ale podstawowa zasada jest zawsze taka sama: rozwiązać jakiś problem, np. Prowadzić samochód lub grać w Domino. W pierwszym przypadku problemy są złożone i liczne, ale ostatecznym problemem jest doprowadzenie pasażera z jednego miejsca do drugiego bez awarii samochodu. Podobnie, celem gry w Domino jest zwycięstwo. Nauka odbywa się na wiele różnych sposobów, w zależności od algorytmu i jego celów. Możesz podzielić algorytmy uczenia maszynowego na trzy główne grupy, w zależności od ich celu:

*Nadzorowana nauka

* Uczenie się bez nadzoru

* Nauka przez wzmocnienie

W poniższych sekcjach omówiono różne rodzaje algorytmów bardziej szczegółowo wykorzystywane przez uczenie maszynowe.

Nadzorowana nauka

Uczenie nadzorowane ma miejsce, gdy algorytm uczy się na podstawie danych przykładowych i powiązanych odpowiedzi docelowych, które mogą składać się z wartości liczbowych lub etykiet ciągów, takich jak klasy lub znaczniki, w celu późniejszego przewidzenia poprawnej odpowiedzi po podaniu nowych przykładów. Podejście nadzorowane jest podobne do uczenia się przez człowieka pod nadzorem nauczyciela. Nauczyciel podaje dobre przykłady do zapamiętania przez ucznia, a następnie uczeń czerpie ogólne zasady z tych konkretnych przykładów. Musisz rozróżnić problemy regresji, których celem jest wartość liczbową, i problemy z klasyfikacją, których celem jest zmienna jakościowa, taka jak klasa lub znacznik. Zadanie regresji może określać średnie ceny domów w rejonie Bostonu, a przykładem zadania klasyfikacji jest rozróżnianie rodzajów kwiatów tęczówki na podstawie ich miarki płatków i płatków.

Uczenie się bez nadzoru

Uczenie się bez nadzoru ma miejsce, gdy algorytm uczy się na podstawie prostych przykładów bez żadnej powiązanej odpowiedzi, pozostawiając algorytm samemu określać wzorce danych. Ten typ algorytmu ma tendencję do przekształcania danych w coś innego, na przykład nowe funkcje, które mogą reprezentować klasę lub nową serię nieskorelowanych wartości. Uzyskane dane są bardzo przydatne w zapewnianiu ludziom wglądu w znaczenie oryginalnych danych i nowych przydatnych danych wejściowych do nadzorowanych algorytmów uczenia maszynowego. Uczenie się bez nadzoru przypomina metody stosowane przez ludzi w celu ustalenia, że niektóre obiekty lub zdarzenia należą do tej samej klasy, takie jak obserwowanie stopnia podobieństwa między obiektami. Niektóre systemy polecające, które można znaleźć w Internecie w postaci automatyzacji marketingu, oparte są na tego rodzaju nauczaniu. Algorytm automatyzacji marketingu czerpie swoje sugestie z tego, co kupiłeś w przeszłości. Zalecenia oparte są na oszacowaniu, do której grupy klientów najbardziej przypominasz, a następnie na podstawie tej grupy możesz wyciągnąć prawdopodobne preferencje.

Uczenie się przez wzmocnienie

Uczenie się przez wzmocnienie następuje, gdy przedstawisz algorytm przykładowi pozbawionemu etykiet, jak w przypadku nauki bez nadzoru. Można jednak dołączyć do przykładu pozytywną lub negatywną informację zwrotną zgodnie z rozwiązaniem zaproponowanym przez algorytm. Uczenie się przez wzmocnienie jest powiązane z aplikacjami, dla których algorytm musi podejmować decyzje (więc produkt ma charakter nakazowy, a nie tylko opisowy, jak w przypadku uczenia bez nadzoru), a decyzje niosą za sobą konsekwencje. W ludzkim świecie przypomina naukę metodą prób i błędów. Błędy pomagają ci się uczyć, ponieważ mają dodaną karę (koszt, stratę czasu, żal, ból itd.), Uczęc cię, że pewne działanie jest mniej prawdopodobne niż inne. Ciekawy przykład uczenia się przez wzmocnienie pojawia się, gdy komputery same uczą się grać w gry wideo. W tym przypadku aplikacja przedstawia algorytm z przykładami konkretnych sytuacji, takich jak utknięcie gracza w labiryncie podczas unikania wroga. Aplikacja informuje algorytm o wynikach podejmowanych działań, a uczenie się odbywa się, starając się unikać tego, co odkrywa jako niebezpieczne i dążyć do przetrwania.