


Przedstawiamy głębokie uczenie się

Prawdopodobnie wiele słyszałeś o głębokim uczeniu się. Termin pojawia się wszędzie i wydaje się mieć zastosowanie do wszystkiego. W rzeczywistości uczenie głębokie jest podzbiorem uczenia maszynowego, które z kolei jest podzbiorem sztucznej inteligencji (AI). Pierwszym celem jest pomoc w zrozumieniu, na czym naprawdę polega głębokie uczenie się i jak ma ono zastosowanie w dzisiejszym świecie. Możesz być zaskoczony, gdy dowiesz się, że głębokie uczenie się nie jest jedyną grą w mieście; istnieją inne metody analizy danych. W rzeczywistości głębokie uczenie się spełnia określony zestaw potrzeb, jeśli chodzi o analizę danych, więc możesz używać innych metod i nawet o tym nie wiedzieć. Uczenie głębokie to tylko podzbiór sztucznej inteligencji, ale jest to ważny podzbiór. Widzisz techniki głębokiego uczenia się używane do wielu zadań, ale niezbyt zadań. W rzeczywistości niektórzy ludzie kojarzą głębokie uczenie się z zadaniami, których nie są w stanie wykonać. Następnym krokiem w odkrywaniu uczenia głębokiego jest zrozumienie, co może, a czego nie może dla Ciebie zrobić. W ramach pracy z głębokim uczeniem napiszesz aplikacje, które wykorzystują głębokie uczenie do przetwarzania danych, a następnie generują pożądane wyniki. Oczywiście musisz trochę wiedzieć o środowisku programistycznym, zanim będziesz mógł wiele zrobić. Tak, uczenie głębokie może wykonywać niesamowite zadania, gdy jest odpowiednio używane, ale może również powodować poważne problemy w przypadku problemów, których nie obsługuje dobrze. Czasami trzeba spojrzeć na inne technologie, aby wykonać dane zadanie, lub dowiedzieć się, których technologii użyć z głębokim uczeniem, aby zapewnić bardziej wydajne i eleganckie rozwiązanie określonych problemów.

Zdefiniowanie, co oznacza głębokie uczenie się

Zrozumienie głębokiego uczenia się zaczyna się od precyzyjnej definicji terminów. W przeciwnym razie trudno będzie oddzielić szum medialny od realiów tego, co faktycznie może zapewnić głębokie uczenie się. Uczenie głębokie jest częścią zarówno sztucznej inteligencji, jak i uczenia maszynowego, jak pokazano na rysunku .



Aby zrozumieć głębokie uczenie się, musisz zacząć od zewnątrz - to znaczy zacząć od sztucznej inteligencji, a następnie przejść przez uczenie maszynowe, a na końcu zdefiniować głębokie uczenie się. Poniższe sekcje pomogą Ci przejść przez ten proces.

Począwszy od sztucznej inteligencji

Stwierdzenie, że sztuczna inteligencja jest sztuczną inteligencją, tak naprawdę nie mówi nic znaczącego, dlatego tak wiele dyskusji i nieporozumień pojawia się w związku z tym terminem. Tak, możesz argumentować, że to, co się dzieje, jest sztuczne i nie pochodzi z naturalnego źródła. Jednak część dotycząca inteligencji jest w najlepszym przypadku niejednoznaczna. Ludzie definiują inteligencję na wiele różnych sposobów. Możesz jednak powiedzieć, że inteligencja obejmuje pewne ćwiczenia umysłowe składające się z następujących czynności:

Uczenie się: posiadanie umiejętności pozyskiwania i przetwarzania nowych informacji.

Rozumowanie: umiejętność manipulowania informacjami na różne sposoby.

Zrozumienie: rozważenie wyniku manipulacji informacją.

Chwytnie prawdy: ustalanie ważności zmanipulowanych informacji.

Dostrzeganie relacji: rozróżnianie interakcji zweryfikowanych danych z innymi danymi.

Rozważanie znaczeń: Stosowanie prawdy do określonych sytuacji w sposób zgodny z ich relacją.

Oddzielenie faktów od przekonań: ustalenie, czy dane są odpowiednio poparte udowodnionymi źródłami, w przypadku których można wykazać, że są konsekwentnie prawdziwe.

Lista mogłaby być dość długa, ale nawet ta lista jest stosunkowo podatna na interpretację przez każdego, kto zaakceptuje ją jako wykonalną. Jak widać z listy, inteligencja często jednak podąża za procesem, który system komputerowy może naśladować w ramach symulacji:

1. Wyznacz cel w oparciu o potrzeby lub pragnienia.
2. Oceń wartość wszelkich obecnie znanych informacji wspierających cel.
3. Zbierz dodatkowe informacje, które mogą wesprzeć cel.
4. Manipuluj danymi tak, aby uzyskały formę zgodną z istniejącymi informacjami.
5. Zdefiniuj relacje i wartości prawdy między istniejącymi a nowymi informacjami.
6. Określ, czy cel został osiągnięty.
7. Zmodyfikuj cel w świetle nowych danych i jego wpływu na prawdopodobieństwo sukcesu.
8. W razie potrzeby powtarzaj kroki od 2 do 7, aż cel zostanie osiągnięty (uznany za prawdziwy) lub wyczerpią się możliwości jego osiągnięcia (uznany za fałszywy).

Mimo że można tworzyć algorytmy i zapewniać dostęp do danych wspierających ten proces w komputerze, zdolność komputera do uzyskiwania inteligencji jest poważnie ograniczona. Na przykład komputer nie jest w stanie niczego zrozumieć, ponieważ opiera się na procesach maszynowych do manipulowania danymi przy użyciu czystej matematyki w sposób ściśle mechaniczny. Podobnie komputery nie mogą łatwo oddzielić prawdy od nieprawdy. W rzeczywistości żaden komputer nie jest w stanie w pełni zrealizować żadnej z czynności umysłowych opisanych na liście opisującej inteligencję. Myśląc o sztucznej inteligencji, musisz wziąć pod uwagę cele ludzi, którzy ją rozwijają. Celem jest naśladowanie ludzkiej inteligencji, a nie jej powielanie. Komputer tak naprawdę nie myśli, ale sprawia wrażenie, jakby myślał. Jednak komputer faktycznie zapewnia ten wygląd tylko w logicznej / matematycznej formie inteligencji. Komputer z umiarkowanym powodzeniem naśladuje wzrokowo-przestrzenną inteligencję i kinestetyczną inteligencję ciała. Komputer ma niską, zadowalającą zdolność

inteligencji interpersonalnej i językowej. Jednak w przeciwieństwie do ludzi komputer nie ma możliwości naśladowania inteligencji intrapersonalnej lub twórczej.

Biorąc pod uwagę rolę AI

Jak opisano w poprzedniej sekcji, pierwszą koncepcją, którą należy zrozumieć, jest to, że sztuczna inteligencja nie ma nic wspólnego z ludzką inteligencją. Tak, część sztucznej inteligencji jest modelowana tak, aby symulować ludzką inteligencję, ale tym właśnie jest: symulacja. Myśląc o sztucznej inteligencji, zwróć uwagę, że istnieje zależność między poszukiwaniem celu, przetwarzaniem danych wykorzystywanym do osiągnięcia tego celu oraz pozyskiwaniem danych wykorzystywanym do lepszego zrozumienia celu. Sztuczna inteligencja polega na algorytmach, aby osiągnąć wynik, który może, ale nie musi mieć nic wspólnego z ludzkimi celami lub metodami ich osiągania. Mając to na uwadze, możesz sklasyfikować sztuczną inteligencję na cztery sposoby:

* **Ludzkie działanie:** gdy komputer zachowuje się jak człowiek, najlepiej odzwierciedla to test Turinga, w którym komputer odnosi sukces, gdy nie jest możliwe rozróżnienie między komputerem a człowiekiem. Ta kategoria odzwierciedla również to, co media sugerują, że myślisz o sztucznej inteligencji. Widzisz, że jest stosowany w technologiach, takich jak przetwarzanie języka naturalnego, reprezentacja wiedzy, automatyczne rozumowanie i uczenie maszynowe (z których wszystkie cztery muszą być obecne, aby zdać test). Oryginalny test Turinga nie obejmował żadnego kontaktu fizycznego. Nowszy, Total Turing Test obejmuje kontakt fizyczny w postaci przesłuchania zdolności percepcyjnych, co oznacza, że komputer musi również wykorzystywać widzenie komputerowe i robotykę, aby odnieść sukces. Nowoczesne techniki obejmują ideę osiągnięcia celu, a nie całkowite naśladowanie ludzi. Na przykład bracia Wright nie udało się stworzyć samolotu poprzez dokładne odwzorowanie lotów ptaków; raczej ptaki dostarczyły pomysłów, które doprowadziły do aerodynamiki, która z kolei ostatecznie doprowadziła do walki ludzi. Celem jest latanie. Zarówno ptaki, jak i ludzie osiągają ten cel, ale stosują różne podejścia.

* **Myślenie po ludzku:** Kiedy komputer myśli jak człowiek, wykonuje zadania, które wymagają od człowieka inteligencji (w przeciwieństwie do rutynowych procedur), aby odnieść sukces, na przykład prowadzenie samochodu. Aby określić, czy program myśli jak człowiek, musisz mieć jakąś metodę określania sposobu myślenia ludzi, którą definiuje podejście do modelowania poznawczego. Ten model opiera się na trzech technikach:

Introspekcja: wykrywanie i dokumentowanie technik używanych do osiągnięcia celów poprzez monitorowanie własnych procesów myślowych.

Testy psychologiczne: obserwowanie zachowania osoby i dodawanie go do bazy danych podobnych zachowań innych osób ze względu na podobny zestaw okoliczności, celów, zasobów i warunków środowiskowych (między innymi).

Obrazowanie mózgu: monitorowanie aktywności mózgu bezpośrednio za pomocą różnych środków mechanicznych, takich jak komputerowa tomografia osiowa (CAT), pozytonowa tomografia emisyjna (PET), obrazowanie metodą rezonansu magnetycznego (MRI) i magnetoencefalografia (MEG).

Po utworzeniu modelu możesz napisać program symulujący model. Biorąc pod uwagę różnorodność procesów myślowych ludzi i trudność w dokładnym przedstawieniu tych procesów myślowych jako części programu, wyniki są w najlepszym przypadku eksperymentalne. Ta kategoria ludzkiego myślenia jest często używana w psychologii i innych dziedzinach, w których niezbędne jest modelowanie procesu myślenia człowieka w celu stworzenia realistycznych symulacji.

* Myślenie racjonalne: badanie sposobu myślenia ludzi przy użyciu pewnych standardów umożliwia stworzenie wytycznych opisujących typowe ludzkie zachowania. Osoba jest uważana za racjonalną, gdy postępuje zgodnie z tymi zachowaniami w ramach pewnych poziomów odchylenia. Komputer, który myśli racjonalnie, opiera się na zarejestrowanych zachowaniach, aby stworzyć przewodnik dotyczący interakcji ze środowiskiem w oparciu o dostępne dane. Celem tego podejścia jest logiczne rozwiązywanie problemów, gdy jest to możliwe. W wielu przypadkach takie podejście umożliwiłoby stworzenie podstawowej techniki rozwiązania problemu, która byłaby następnie modyfikowana w celu rzeczywistego rozwiązania problemu. Innymi słowy, rozwiązanie problemu w zasadzie często różni się od rozwiązania go w praktyce, ale nadal potrzebujesz punktu wyjścia.

* Racjonalne działanie: badanie, jak ludzie zachowują się w określonych sytuacjach, przy określonych ograniczeniach, pozwala określić, które techniki są zarówno wydajne, jak i skuteczne. Komputer, który działa racjonalnie, polega na zarejestrowanych działaniach w celu interakcji ze środowiskiem w oparciu o warunki, czynniki środowiskowe i istniejące dane. Podobnie jak w przypadku racjonalnego myślenia, czyny racjonalne zależą od rozwiązania w zasadzie, które w praktyce może nie okazać się przydatne. Jednak racjonalne działania stanowią podstawę, na której komputer może rozpocząć negocjacje dotyczące pomyślnego zakończenia celu.

CZŁOWIEK A PROCES RACJONALNY

Procesy ludzkie różnią się wynikami od procesów racjonalnych. Proces jest racjonalny, jeśli zawsze działa właściwie na podstawie aktualnych informacji, mając idealną miarę wydajności. Krótko mówiąc, racjonalne procesy przebiegają według książki i zakładają, że „książka” jest rzeczywiście poprawna. Ludzkie procesy obejmują instynkt, intuicję i inne zmienne, które niekoniecznie odzwierciedlają książkę i mogą nawet nie uwzględniać istniejących danych. Na przykład racjonalnym sposobem prowadzenia samochodu jest zawsze przestrzeganie prawa. Jednak ruch nie jest racjonalny. Jeśli ściśle przestrzegasz przepisów, utkniesz gdzieś, ponieważ inni kierowcy nie przestrzegają ich dokładnie. Aby odnieść sukces, samochód jeżdżący samodzielnie musi więc działać bardziej po ludzku niż racjonalnie. Obecnie sztuczna inteligencja jest używana w wielu aplikacjach. Jedynym problemem jest to, że technologia działa tak dobrze, że nawet nie wiesz, że istnieje. W rzeczywistości możesz być zaskoczony, że wiele urządzeń w Twoim domu już korzysta z tej technologii. Zastosowania sztucznej inteligencji liczą się w milionach - wszystkie są bezpiecznie poza zasięgiem wzroku, nawet jeśli mają dość dramatyczny charakter. Oto tylko kilka sposobów, w jakie możesz zobaczyć użycie sztucznej inteligencji:

* Wykrywanie oszustw: Otrzymujesz telefon od wystawcy karty kredytowej z pytaniem, czy dokonałeś konkretnego zakupu. Firma obsługująca karty kredytowe nie jest wścibska; po prostu ostrzega Cię o tym, że ktoś inny może dokonywać zakupu przy użyciu Twojej karty. Sztuczna inteligencja osadzona w kodzie wystawcy karty kredytowej wykryła nieznaną wzorzec wydatków i zaalarmowała o tym kogoś.

* Planowanie zasobów: wiele organizacji musi efektywnie planować wykorzystanie zasobów. Na przykład szpital może być zmuszony do określenia, gdzie umieścić pacjenta, na podstawie potrzeb pacjenta, dostępności wykwalifikowanych ekspertów oraz czasu, przez jaki lekarz spodziewa się, że pacjent będzie 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 szybkim postawieniu diagnozy, aby uratować życie pacjenta.

* Automatyzacja: każda forma automatyzacji może skorzystać na dodaniu sztucznej inteligencji do obsługi nieoczekiwanych zmian lub zdarzeń. Problem z niektórymi typami automatyzacji polega

obecnie na tym, że nieoczekiwane zdarzenie, takie jak obiekt w niewłaściwym miejscu, może w rzeczywistości spowodować zatrzymanie automatyzacji. Dodanie sztucznej inteligencji do automatyzacji może pozwolić automatyzacji na obsługę nieoczekiwanych zdarzeń i kontynuowanie, jakby nic się nie wydarzyło.

* Obsługa klienta: linia obsługi klienta, do której dzwonisz dzisiaj, może nawet nie mieć za sobą człowieka. Automatyzacja jest wystarczająco dobra, aby śledzić skrypty i korzystać z różnych zasobów, aby odpowiedzieć na większość pytań. Przy dobrej infekcji głosowej (również zapewnianej przez sztuczną inteligencję) możesz nawet nie być w stanie stwierdzić, że rozmawiasz z komputerem.

* Systemy bezpieczeństwa: Wiele systemów bezpieczeństwa występujących obecnie w różnego rodzaju maszynach opiera się na sztucznej inteligencji, która przejmuje kontrolę nad pojazdem w czasie kryzysu. Na przykład wiele automatycznych układów hamulcowych polega na sztucznej inteligencji, która zatrzymuje samochód na podstawie wszystkich sygnałów wejściowych, które może dostarczyć pojazd, takich jak kierunek poślizgu.

* Wydajność maszyn: AI może pomóc w sterowaniu maszyną w taki sposób, aby uzyskać maksymalną wydajność. Sztuczna inteligencja kontroluje wykorzystanie zasobów, aby system nie przekraczał szybkości ani innych celów. Każda uncja energii jest wykorzystywana dokładnie tak, jak potrzeba, aby zapewnić pożądane usługi.

Koncentrując się na uczeniu maszynowym

Uczenie maszynowe to jeden z wielu podzbiorów sztucznej inteligencji i jedyny jaki omówimy. W uczeniu maszynowym celem jest stworzenie symulacji ludzkiego uczenia się, aby aplikacja mogła dostosować się do niepewnych lub nieoczekiwanych warunków. Aby wykonać to zadanie, uczenie maszynowe opiera się na algorytmach analizujących ogromne zbiory danych. Obecnie uczenie maszynowe nie zapewnia takiego rodzaju sztucznej inteligencji, jaki prezentują filmy (maszyna nie może się intuicyjnie uczyć, tak jak człowiek); może symulować tylko określone rodzaje uczenia się i to tylko w wąskim zakresie. Nawet najlepsze algorytmy nie potrafią myśleć, czuć, prezentować żadnej formy samoświadomości ani wykonywać wolnej woli. Cechy, które są podstawowe dla ludzi, są frustrująco trudne do uchwycenia przez maszyny z powodu tych ograniczeń percepcji. Maszyny nie są samoświadome. Uczenie maszynowe może wykonywać analizy predykcyjne znacznie szybciej niż jakkolwiek człowiek. W rezultacie uczenie maszynowe może pomóc ludziom pracować wydajniej. Obecny stan sztucznej inteligencji polega zatem na przeprowadzaniu analiz, ale ludzie nadal muszą brać pod uwagę konsekwencje tej analizy: podejmować wymagane decyzje moralne i etyczne. Istota sprawy polega na tym, że uczenie maszynowe zapewnia tylko uczącą się część sztucznej inteligencji, a ta część nie jest jeszcze w przybliżeniu gotowa do stworzenia sztucznej inteligencji, jaką można zobaczyć w filmach.

Głównym punktem pomyłki między uczeniem się a inteligencją jest to, że ludzie zakładają, że tylko dlatego, że maszyna staje się lepsza w swojej pracy (może się uczyć), jest również świadoma (ma inteligencję). Nic nie potwierdza tego poglądu na uczenie maszynowe. To samo zjawisko występuje, gdy ludzie zakładają, że komputer celowo powoduje u nich problemy. Komputer nie może przypisywać emocji i dlatego działa tylko na podstawie dostarczonych danych wejściowych i instrukcji zawartych w aplikacji, aby przetworzyć te dane. Prawdziwa sztuczna inteligencja w końcu pojawi się, gdy komputery będą mogły wreszcie naśladować sprytną kombinację używaną przez naturę:

* Genetyka: powolna nauka z pokolenia na pokolenie

* Nauczanie: Szybka nauka ze zorganizowanych źródeł

* Eksploracja: spontaniczne uczenie się poprzez media i interakcje z innymi

Aby koncepcje uczenia maszynowego były zgodne z możliwościami maszyny, należy rozważyć konkretne zastosowania systemów uczących się. Warto przyrzeć się zastosowaniom uczenia maszynowego poza normalną sferą tego, co wielu uważa za domenę sztucznej inteligencji. Oto kilka zastosowań uczenia maszynowego, których możesz nie kojarzyć z AI:

* Kontrola dostępu: W wielu przypadkach kontrola dostępu jest propozycją tak lub nie. Karta inteligentna pracownika zapewnia dostęp do zasobu w taki sam sposób, jak ludzie używali kluczy od wieków. Niektóre blokady oferują możliwość ustawiania czasu i dat, w których dostęp jest dozwolony, ale taka zgrubna kontrola nie spełnia wszystkich potrzeb. Korzystając z uczenia maszynowego, możesz określić, czy pracownik powinien uzyskać dostęp do zasobu na podstawie roli i potrzeb. Na przykład pracownik może uzyskać dostęp do sali szkoleniowej, gdy szkolenie odzwierciedla rolę pracownika.

* Ochrona zwierząt: ocean może wydawać się wystarczająco duży, aby umożliwić zwierzętom i statkom wspólne życie bez problemu. Niestety co roku wiele zwierząt zostaje potraconych przez statki. Algorytm uczenia maszynowego mógłby pozwolić statkom na unikanie zwierząt dzięki poznaniu dźwięków i cech zarówno zwierzęcia, jak i statku. (Statek polegałby na podwodnym sprzęcie nasłuchowym, który śledziłby zwierzęta za pomocą ich dźwięków, które można usłyszeć z dużej odległości od statku).

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

Przejście od uczenia maszynowego do uczenia głębokiego

Jak wspomniano wcześniej, uczenie głębokie to podzbiór uczenia maszynowego. W obu przypadkach wydaje się, że algorytmy uczą się, analizując ogromne ilości danych (jednak w niektórych przypadkach uczenie się może nastąpić nawet przy niewielkich zbiorach danych). Jednak głębokie uczenie się różni się głębokością analizy i rodzajem automatyzacji, które zapewnia. Możesz podsumować różnice między nimi w następujący sposób:

* Zupełnie inny paradygmat: uczenie maszynowe to zbiór wielu różnych technik, które umożliwiają komputerowi uczenie się na podstawie danych i wykorzystywanie tego, czego się uczy, do udzielania odpowiedzi, często w formie przewidywań. Uczenie maszynowe opiera się na różnych paradygmatach, takich jak analiza statystyczna, znajdowanie analogii w danych, używanie logiki i praca z symbolami. Porównaj niezliczone techniki stosowane w uczeniu maszynowym z jedną techniką stosowaną w uczeniu głębokim, która naśladuje funkcje ludzkiego mózgu. Przetwarza dane za pomocą jednostek obliczeniowych, zwanych neuronami, ułożonych w uporządkowane sekcje, zwane warstwami. Technika leżąca u podstaw głębokiego uczenia się jest sieć neuronowa.

* Elastyczne architektury: rozwiązania uczenia maszynowego oferują wiele gałek (korekty) zwane hiperparametrami, które dostosowujesz w celu optymalizacji uczenia algorytmu na podstawie danych. Rozwiązania do uczenia głębokiego również używają hiperparametrów, ale używają też wielu warstw konfigurowanych przez użytkownika (użytkownik określa liczbę i typ). W rzeczywistości, w zależności od powstałej sieci neuronowej, liczba warstw może być dość duża i tworzyć unikalne sieci neuronowe zdolne do wyspecjalizowanego uczenia się: niektóre mogą nauczyć się rozpoznawać obrazy, podczas gdy inne mogą wykrywać i analizować polecenia głosowe. Chodzi o to, że termin „głęboki” jest

właściwy; odnosi się do dużej liczby warstw potencjalnie używanych do analizy. Architektura składa się z zespołu różnych neuronów i ich ułożenia w warstwach w rozwiązaniu do głębokiego uczenia się.

* Definicja funkcji autonomicznych: rozwiązania uczenia maszynowego wymagają interwencji człowieka, aby odnieść sukces. Aby poprawnie przetwarzać dane, analitycy i naukowcy wykorzystują dużą część własnej wiedzy do opracowywania działających algorytmów. Na przykład w rozwiązaniu uczenia maszynowego, które określa wartość domu, opierając się na danych zawierających wymiary ścian różnych pomieszczeń, algorytm uczenia maszynowego nie będzie w stanie obliczyć powierzchni domu, chyba że analityk określi sposób obliczania to wcześniej. Tworzenie odpowiednich informacji dla algorytmu uczenia maszynowego nazywa się tworzeniem funkcji, co jest czynnością czasochłonną. Uczenie głębokie nie wymaga od ludzi wykonywania żadnych czynności związanych z tworzeniem funkcji, ponieważ dzięki wielu warstwom definiuje własne najlepsze funkcje. Dlatego też uczenie głębokie przewyższa uczenie maszynowe w bardzo trudnych zadaniach, takich jak rozpoznawanie głosu i obrazów, rozumienie tekstu lub pokonanie ludzkiego mistrza w grze Go (cyfrowa forma gry planszowej, w której zdobywasz terytorium przeciwnika).

Musisz zrozumieć wiele problemów związanych z rozwiązaniami uczenia głębokiego, z których najważniejszym jest to, że komputer nadal niczego nie rozumie i nie jest świadomy rozwiązania, które zapewnił. Po prostu zapewnia formę pętli sprzężenia zwrotnego i automatyzacji połączonych w celu wytworzenia pożądanego wyniku w krótszym czasie, niż człowiek mógłby ręcznie uzyskać dokładnie ten sam wynik, manipulując rozwiązaniem uczącym się.

Druga kwestia polega na tym, że niektórzy ludzie w ciemności nalegali, aby warstwy głębokiego uczenia się były ukryte i niedostępne do analizy. Tak nie jest. Wszystko, co może zbudować komputer, jest ostatecznie śledzone przez człowieka. W rzeczywistości ogólne rozporządzenie o ochronie danych (RODO) wymaga, aby ludzie przeprowadzali taką analizę. Wymóg przeprowadzenia tej analizy jest kontrowersyjny, ale obowiązujące prawo mówi, że ktoś musi to zrobić. Trzecią kwestią jest to, że samoregulacja idzie tylko do tej pory. Uczenie głębokie nie zawsze zapewnia rzetelny lub poprawny wynik. W rzeczywistości rozwiązania do głębokiego uczenia mogą pójść strasznie źle. Nawet jeśli kod aplikacji nie idzie źle, urządzenia używane do obsługi głębokiego uczenia mogą. Mimo to, mając na uwadze te problemy, możesz zobaczyć głębokie uczenie używane w wielu niezwykle popularnych aplikacjach.

Korzystanie z Deep Learning w prawdziwym świecie

Nie popełnij błędu: ludzie używają uczenia głębokiego w prawdziwym świecie do wykonywania szerokiego zakresu zadań. Na przykład wiele samochodów używa obecnie interfejsu głosowego. Interfejs głosowy może wykonywać podstawowe zadania, nawet od samego początku. Jednak im więcej z nim rozmawiasz, tym lepiej działa interfejs głosowy. Interfejs uczy się, gdy z nim rozmawiasz - nie tylko sposobu, w jaki mówisz, ale także osobistych preferencji. Poniższe sekcje zawierają trochę informacji o tym, jak głębokie uczenie działa w prawdziwym świecie.

Zrozumienie pojęcia uczenia się

Kiedy ludzie się uczą, polegają na czymś więcej niż tylko danych. Ludzie mają intuicję oraz niesamowitą wiedzę o tym, co zadziała, a co nie. Częścią tej wrodzonej wiedzy jest instynkt, który jest przekazywany z pokolenia na pokolenie poprzez DNA. Sposób, w jaki ludzie wchodzą w interakcje z danymi wejściowymi, również różni się od tego, co robi komputer. W przypadku komputera uczenie się polega na zbudowaniu bazy danych składającej się z sieci neuronowej, która ma wbudowane wagi i odchylenia, aby zapewnić prawidłowe przetwarzanie danych. Sieć neuronowa przetwarza następnie dane, ale nie w sposób, który jest nawet zdalnie taki sam, jak będzie to robił człowiek.

Wykonywanie zadań uczenia głębokiego

Ludzie i komputery są najlepsi w różnych zadaniach. Ludzie są najlepsi w rozumowaniu, myśleniu o etycznych rozwiązaniach i emocjonalności. Komputer ma przetwarzać dane - dużo danych - naprawdę szybko. Często używasz uczenia głębokiego do rozwiązywania problemów, które wymagają wyszukiwania wzorców w ogromnych ilościach danych - problemów, których rozwiązanie jest nieintuicyjne i niezauważalne od razu. Niemal w każdym przypadku można podsumować problem i jego rozwiązanie jako szybkie przetwarzanie ogromnych ilości danych, szukanie wzorców, a następnie poleganie na tych wzorcach, aby odkryć coś nowego lub stworzyć konkretny rodzaj wyjścia.

Wykorzystanie uczenia głębokiego w aplikacjach

Uczenie głębokie może być samodzielnym rozwiązaniem, ale często jest używane jako część znacznie większego rozwiązania i jest mieszane z innymi technologiami. Na przykład łączenie uczenia głębokiego z systemami eksperckimi nie jest rzadkością, jednak rzeczywiste aplikacje to coś więcej niż tylko liczby generowane z jakiegoś mglistego źródła. Pracując w świecie rzeczywistym, należy również wziąć pod uwagę różne rodzaje źródeł danych i zrozumieć, jak one działają. Kamera może wymagać innego rodzaju rozwiązania do głębokiego uczenia, aby uzyskać z niej informacje, podczas gdy termometr lub detektor zbliżeniowy może generować proste liczby (lub dane analogowe, które wymagają pewnego rodzaju przetwarzania). Rzeczywiste rozwiązania są niechlujne, więc musisz być przygotowany na więcej niż jedno rozwiązanie problemów w swoim zestawie narzędzi.

Biorąc pod uwagę środowisko programowania Deep Learning

Możesz automatycznie założyć, że musisz przeskoczyć przez okropny zestaw kótek i nauczyć się ezoterycznych umiejętności programowania, aby zagłębić się w głębokie uczenie się. To prawda, że zyskujesz elastyczność, pisząc aplikacje przy użyciu jednego z języków programowania, które dobrze sprawdzają się w przypadku potrzeb uczenia głębokiego. Jednak Deep Learning Studio i inne podobne produkty umożliwiają ludziom tworzenie rozwiązań do głębokiego uczenia bez programowania. Zasadniczo, takie rozwiązania obejmują opisanie tego, co chcesz jako wynik, poprzez graficzne zdefiniowanie modelu. Tego rodzaju rozwiązania sprawdzają się dobrze w przypadku prostych problemów, które inni musieli już rozwiązać, ale brakuje im elastyczności, aby coś zrobić zupełnie inaczej - zadanie, które wymaga czegoś więcej niż zwykłej analizy. Rozwiązania do uczenia głębokiego w chmurze, takie jak te dostarczane przez Amazon Web Services (AWS), mogą zapewnić dodatkową elastyczność. Te środowiska również zwykle upraszczają środowisko programistyczne, zapewniając tyle lub mało wsparcia, ile chcesz. W rzeczywistości AWS zapewnia obsługę różnego rodzaju bezserwerowego computingu, w którym nie musisz martwić się o żadną infrastrukturę. Jednak te rozwiązania mogą stać się dość drogie. Mimo że zapewniają większą elastyczność niż korzystanie z gotowego rozwiązania, nadal nie są tak elastyczne, jak w przypadku rzeczywistego środowiska programistycznego.

Masz też do rozważenia inne rozwiązania nieprogramistyczne. Na przykład, jeśli potrzebujesz mocy i elastyczności, ale nie chcesz programować, aby to uzyskać, możesz polegać na produkcie takim jak MATLAB, który zapewnia zestaw narzędzi do głębokiego uczenia się. MATLAB i niektóre inne środowiska koncentrują się bardziej na algorytmach, których chcesz używać, ale aby uzyskać z nich pełną funkcjonalność, musisz pisać skrypty jako minimum, co oznacza, że zanurzasz się w programowaniu niektórych stopni. Problem z tymi środowiskami polega na tym, że może im brakować również w dziale zasilania, więc niektóre rozwiązania mogą zająć więcej czasu, niż się spodziewasz. W pewnym momencie, bez względu na to, ile innych rozwiązań spróbujesz, poważne problemy z głębokim uczeniem będą wymagały programowania. Przeglądając wybory online, często widzisz sztuczną inteligencję, uczenie maszynowe i uczenie głębokie, wszystkie razem. Jednak podobnie jak te trzy

technologie działają na różnych poziomach, tak samo działają języki programowania , których potrzebujesz. Dobre rozwiązanie do głębokiego uczenia będzie wymagało zastosowania przetwarzania wieloprotocowego, najlepiej z wykorzystaniem jednostki przetwarzania grafiki (GPU) z wieloma rdzeniami. Twój wybrany język musi również obsługiwać GPU za pośrednictwem kompatybilnej biblioteki lub pakietu. Zatem sam wybór języka zwykle nie wystarczy; musisz dokładniej zbadać, czy język rzeczywiście spełnia Twoje potrzeby. Mając to na uwadze, oto najpopularniejsze języki (w kolejności popularności w chwili pisania tego tekstu) do zastosowania w uczeniu głębokim:

*Python

* R

* MATLAB (język skryptowy, a nie produkt)

*Oktave

Jedynym problemem z tą listą jest to, że inni programiści mają inne opinie. Python i R zwykle pojawiają się na górze wszystkich list, ale potem możesz znaleźć różnego rodzaju opinie. Wybierając język, zazwyczaj musisz wziąć pod uwagę następujące kwestie:

* Krzywa uczenia się: Twoje doświadczenia mają wiele do powiedzenia na temat tego, czego możesz się najłatwiej nauczyć. Python jest prawdopodobnie najlepszym wyborem dla kogoś, kto programuje od wielu lat, ale R może być lepszym wyborem dla kogoś, kto ma już doświadczenie w programowaniu funkcjonalnym. MATLAB lub Octave mogą działać najlepiej dla matematyka.

* Szybkość: każde rozwiązanie do głębokiego uczenia będzie wymagało dużej mocy obliczeniowej. Wiele osób twierdzi, że ponieważ R jest językiem statystycznym, oferuje więcej wsparcia statystycznego i zwykle zapewnia szybsze wyniki. W rzeczywistości obsługa Pythona dla doskonałego programowania równoległego prawdopodobnie niweluje tę przewagę, gdy masz wymagany sprzęt.

* Wsparcie społeczności: istnieje wiele form wsparcia społeczności, ale dwa najważniejsze dla głębokiego uczenia się to pomoc w zdefiniowaniu rozwiązania i dostęp do wielu gotowych pomocy programowych. Po czwarte, Octave prawdopodobnie zapewnia najmniej wsparcia społeczności; Python zapewnia najwięcej.

* Koszt: ile kosztuje język, zależy od wybranego rozwiązania i miejsca jego uruchomienia. Na przykład MATLAB to zastrzeżony produkt, który wymaga zakupu, więc masz coś zainwestowanego natychmiast, gdy używasz MATLAB. Jednak mimo że inne języki są na początku bezpłatne, możesz znaleźć ukryte koszty, takie jak uruchomienie kodu w chmurze, aby uzyskać dostęp do obsługi GPU. Obsługa struktur DNN: Framework może znacznie ułatwić pracę z Twoim językiem. Jednak musisz mieć framework która dobrze współgra ze wszystkimi innymi częściami rozwiązania. Dwie najpopularniejsze frameworki to TensorFlow i PyTorch. Co dziwne, Python jest jedynym językiem, który obsługuje oba, więc oferuje największą elastyczność. Używasz Case z MATLAB i TensorFlow z R.

*Gotowy do produkcji: język musi obsługiwać taki rodzaj wyjścia, jaki jest potrzebny w Twoim projekcie. Pod tym względem Python wyróżnia się, ponieważ jest językiem ogólnego przeznaczenia. Możesz z nim stworzyć dowolną aplikację. Jednak bardziej szczegółowe środowiska zapewniane przez inne języki mogą być niezwykle pomocne w przypadku niektórych projektów, dlatego należy wziąć pod uwagę wszystkie z nich.

Pokonywanie szumu związanego z głębokim uczeniem się

W poprzednich częściach omówiono niektóre kwestie związane z postrzeganiem uczenia głębokiego, takie jak przekonanie niektórych ludzi, że pojawia się ono wszędzie i robi wszystko. Problem z głębokim uczeniem się polega na tym, że padł on ofiarą własnej kampanii medialnej. Uczenie głębokie rozwiązuje specyficzne problemy. Poniższe sekcje pomogą Ci uniknąć szumu związanego z głębokim uczeniem się.

Odkrywanie ekosystemu start-upów

Korzystanie z rozwiązania do uczenia głębokiego znacznie różni się od tworzenia własnego rozwiązania do uczenia głębokiego. Samo spełnienie wymagań edukacyjnych może zająć trochę czasu. Jednak po samodzielnym przepracowaniu kilku projektów zaczynasz zdawać sobie sprawę, że szum wokół głębokiego uczenia się rozciąga się aż do początku konfiguracji. Głębokie uczenie nie jest dojrzałą technologią, więc próba jej wykorzystania przypomina budowanie wioski na Księżycu lub głębokie nurkowanie w Rowie Mariańskim. Napotkasz problemy, a technologia będzie się nieustannie zmieniać. Niektóre metody stosowane do tworzenia rozwiązań głębokiego uczenia również wymagają pracy. Koncepcja, że komputer faktycznie uczy się czegokolwiek, jest fałszywa, podobnie jak idea, że komputery mają w ogóle jakąkolwiek formę świadomości. Powodem, dla którego Microsoft, Amazon i inni dostawcy mają problemy z głębokim uczeniem się, jest to, że nawet ich inżynierowie mogą mieć nierealistyczne oczekiwania. Głębokie uczenie się sprowadza się do matematyki i dopasowywania wzorców - z pewnością naprawdę wymyślnej matematyki i dopasowywania wzorców, ale myśl, że to cokolwiek innego, jest po prostu błędna.

Wiedzieć, kiedy nie używać głębokiego uczenia

Głębokie uczenie to tylko jeden sposób przeprowadzania analizy i nie zawsze jest to najlepszy sposób. Na przykład, mimo że systemy eksperckie są uważane za starą technologię, tak naprawdę nie można stworzyć autonomicznego samochodu bez niego. Rozwiązanie do głębokiego uczenia się okazuje się zbyt wolne dla tej konkretnej potrzeby. Twój samochód prawdopodobnie będzie zawierał ogólnie uczącą się sztuczną inteligencję, a uczenie głębokie w szczególności może trafić na nagłówki gazet, gdy technologia nie spełni oczekiwań. Błędem jest myślenie, że głębokie uczenie się może w jakiś sposób podejmować decyzje etyczne lub że wybierze właściwy sposób działania w oparciu o uczucia (których nie ma żadna maszyna). Antropomorfizacja korzystania z głębokiego uczenia się zawsze będzie błędem. Niektóre zadania wymagają po prostu człowieka. Szybkość i zdolność do myślenia jak człowiek to najważniejsze kwestie związane z głębokim uczeniem się, ale jest ich o wiele więcej. Na przykład nie możesz korzystać z uczenia głębokiego, jeśli nie masz wystarczających danych, aby go wytrenować.