Odkrywanie mocy generatywnej sztucznej inteligencji: Podróż w głąb dużych modeli językowych

Streszczenie

Przestrzeń sztucznej inteligencji (AI) została ostatnio zrewolucjonizowana przez pojawienie się generatywnych modeli AI, które pozwalają, aby treści generowane maszynowo wyglądały wizualnie identycznie jak treści generowane przez prawdziwych ludzi. Ta nowo powstająca dziedzina wykorzystuje różnorodne techniki i architektury do generowania różnego rodzaju wyników, od tekstu i obrazów po muzykę i w pełni syntetyczne środowiska. Jednym z najpopularniejszych paradygmatów tej dziedziny jest rodzina modeli generatywnych, a ostatnio także podrodzina dużych modeli językowych (LLM). Zatem generatywna sztuczna inteligencja, w tym LLM, opiera się na koncepcji rozkładu prawdopodobieństwa. Dzieje się tak, gdy technologia zasila wiele zbiorów danych i uczy się wzorców i praw, które się w nich kryją, umożliwiając sztucznej inteligencji efektywne pisanie. Modele LLM były wykorzystywane do planowania i naturalnego tworzenia tekstów w różnych dziedzinach, od trenowania modeli transformatorowych, przez prototypowanie kodu, pisanie, po narrację w dzienniku. Aby sprostać związanym z tym wyzwaniom, opracowano zintegrowaną naturę modelowania z technikami szkoleniowymi, która ostatecznie spełnia wszystkie zasady, regulacje i wytyczne, które pomagają w pomyślnej implementacji modeli generatywnych i LLM.

Słowa kluczowe: Sztuczna inteligencja, prywatność danych, generatywna sztuczna inteligencja, duże modele językowe, przetwarzanie języka naturalnego, rozkład prawdopodobieństwa,

Przegląd generatywnej sztucznej inteligencji i dużych modeli językowych

W dziedzinie algorytmów uczenia maszynowego generatywna sztuczna inteligencja (GAI) to paradygmat, który pomaga maszynom w generowaniu unikalnych materiałów, a także naśladuje wartości danych generowanych przez człowieka. Na tej podstawie GAI pomaga również w rozpoznawaniu i odtwarzaniu podstawowych trendów i struktur, które podążają za zestawem reguł lub informacji, obejmujących tekst, obrazy, dźwięk i inne typy danych. Standardowe techniki sztucznej inteligencji (AI) opierają się w całości na klasyfikacji i regresji, nazywanych również zadaniami stronniczymi . Modele generatywne koncentrują się na uchwyceniu ukrytego zakresu i wartości generowanych przez człowieka. Przetwarzanie języka naturalnego (NLP) wykazuje jedną z takich istotnych ulepszeń, zwanych dużymi modelami językowymi (LLM), które wyróżniają się na podstawie zdolności rozumienia i tworzenia skal pisma przypominających ludzkie. Wszystkie takie modele działają poprzez uczenie się sparametryzowanych zmiennych współzależnych i architektur ze zbioru danych, a następnie generowanie nowych punktów danych, które podążają za tymi trendami. Sieci GAN to systemy antagonistyczne składające się z dwóch zestawów sieci neuronowych (generatora sieci i dyskryminatora), które konkurują ze sobą o generowanie realistycznych próbek, podczas gdy dyskryminatory przeszukują rzeczywiste próbki i zestawy pozorne. Metryki oceny mierzą adaptowalność dyskryminatora do rzeczywistych danych z generatora, umożliwiając sieciom GAN publikowanie w miarę realistycznych obrazów, muzyki, a nawet języka po trenowaniu antagonistycznym. Autoenkodery wariacyjne (VAE) trenują ukrytą naturę danych wejściowych, a następnie publikują nowe próbki z tego wyuczonego utajonego powtórzenia, umożliwiając im generowanie szeregu wyników z zachowaniem części oryginalnych danych. W przeciwieństwie do tego, algorytmy głębokiego uczenia (VAE) trenują utajoną wersję danych wejściowych, a następnie pobierają nową instancję z tej wyuczonej przestrzeni utajonej, aby wygenerować różnorodne dane wyjściowe na podstawie przykładów danych. Jednak rozwój algorytmów LLM stwarza poważne dylematy etyczne i kulturowe, szczególnie w odniesieniu do kwestii stronniczości, dezinformacji i prywatności. Przetwarzając zbiorcze dane całej sieci WWW, algorytmy te ryzykują utrwaleniem i wzmocnieniem błędów w swoich danych edukacyjnych. Pojawiająca się możliwość generowania niezwykle

przekonujących fałszywych wyników budzi obawy, że technologia ta może zostać wykorzystana do tworzenia dezinformacji lub podszywania się pod innych. Głębokie uczenie (GAE) lub sieć neuronowa ma rdzeń zwany LLM, który jest w stanie obsłużyć duże wartości tekstu wejściowego. Modele te są trenowane w oparciu o duże zbiory danych, obejmujące miliardy fraz, co pozwala im na uzyskanie złożonych modeli językowych oraz powiązań poznawczych. Agregacja inteligencji (GAI) wykorzystuje ważny parametr strategiczny, wykorzystując sieci neuronowe zwane generatywnymi sieciami adwersarnymi, a także algorytmy głębokiego uczenia (VAE). Składają się one z dwóch kategorii sieci neuronowych. Zarówno producent, jak i dyskryminator pomagają w tworzeniu prawdziwych próbek, natomiast detektor pomaga w rozróżnianiu danych rzeczywistych i fałszywych. Do tej pory ta metoda LLM wydaje się osiągać doskonałe rezultaty we wszystkich implementacjach w całym sektorze NLP, stosując wczesne metody prognozowania prawdopodobieństwa sekwencji. Rewolucyjny projekt, zwany siecią transformatorową, działający w polach LLM, osiąga stan samouważności, który pozwala symulatorowi na skuteczną interpretację odległej relacji z wartościami wejściowymi opartymi na tekście . Naukowcy poczynili znaczne postępy w tych językach modelowania, tworzeniu i tłumaczeniu wartości tekstowych oraz syntezie i odpowiadaniu na zapytania. Osiąga się to za pomocą opartych na transformatorach modeli LLM, takich jak OpenAI GPT (generatywny, wstępnie wytrenowany transformator). Sieci GAN są również w stanie generować realistyczne wizualizacje, dźwięki i tekst, które są trenowane w sposób antagonistyczny. VAE pomaga w trenowaniu ukrytych modeli wejściowych z wykorzystaniem danych wejściowych oraz w generowaniu próbek poprzez selekcję z ukrytej przestrzeni, co pomaga w różnych zakresach wyjściowych, zachowując jednocześnie niektóre cechy zebranych informacji. Te formy algorytmów generatywnych są wykorzystywane w różnych dyscyplinach, takich jak tworzenie sztuki, wzbogacanie informacji, analiza dzieł literackich, a także rozwój wartości medycznych, co skutecznie demonstruje zdolność i umiejętności promowania standardów innowacji w całym przemyśle. Studia LLM pomagają wykazać się umiejętnością rozumienia i tworzenia kontekstu oraz podejść do treści, które obejmują szeroki zakres dziedzin i tematów. Są one wykorzystywane w różnych praktycznych podejściach, takich jak chatboty, tworzenie treści i analiza sentymentów, które w rzeczywistości opierają się na systemach opinii klientów. Rysunek przedstawia przegląd GAI i LLM w oparciu o model bazowy AI.

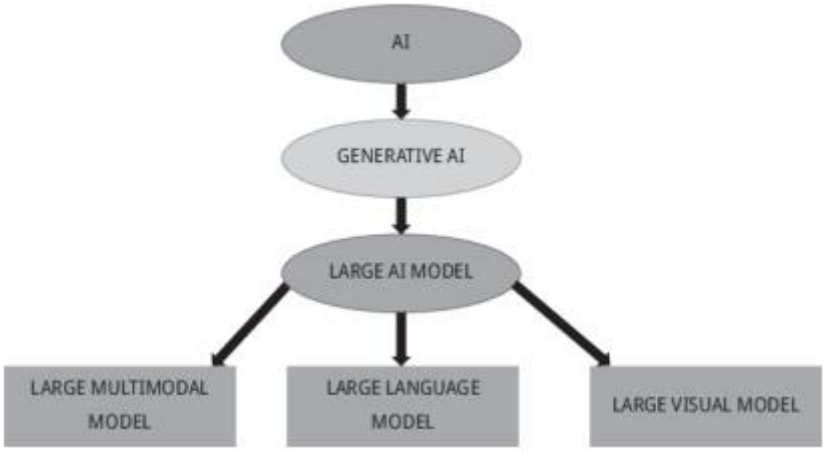

Studia magisterskie z prawa (LLM) zajmują się etyką i stronniczością informacyjną w celu zwiększenia prawdziwie pozytywnych wartości . Wraz ze wzrostem wartości LLM w różnych sektorach społecznych, kluczowe staje się rozwiązywanie tych problemów poprzez rozwój etyczny i ocenę opartą na kryteriach wpływających na wartości humanistyczne.

Podstawowe koncepcje

Główną ideą dotyczącą GAI w LLM jest wykorzystanie różnych wartości głównych wraz z podejściami, które pomagają komputerom dostarczać dane istotne w kontekście. Są one przedstawione w formie treści humanizowanych. Zawiera krótkie wyjaśnienie podstawowych zasad z wartościami statystycznymi i sieciami neuronowymi opartymi na modelach generujących dane dla wybranych modeli. Niniejszy rozdział przedstawia podstawowe ramy dotyczące algorytmów, które pomagają w uczeniu się i rozpoznawaniu struktur i wzorców istniejących w zbiorze danych oraz informacji dotyczących generowania nowych danych. Niektóre z podstawowych koncepcji zostały wyjaśnione dalej.

Rozkład prawdopodobieństwa

GAI działa jak serce, które opiera się na rozkładzie prawdopodobieństwa, który jest niezbędny w estymacji prawdopodobieństwa różnych zdarzeń. Pomaga w zrozumieniu rozkładu prawdopodobieństwa zbioru danych z różnymi wynikami poprzez tworzenie nowego zestawu punktów danych. Zatem opanowanie takiego rozkładu prawdopodobieństwa dostarcza zróżnicowanych i autentycznych materiałów.

Sieci neuronowe

Są one podstawową strukturą wśród wszystkich modeli, które mają charakter generatywny. Składają się z połączonych warstw, gdzie każda warstwa wykonuje różne operacje na danych przepływających do sieci. System neuronowy z propagacją wsteczną zapewnia wgląd w różne wartości wejściowe wraz ze zmianą lub zmianą ustawień, co zwiększa efektywność wraz z upływem czasu.

Generatywne sieci przeciwstawne (GAN)

Model obliczeniowy zwany generatywną siecią przeciwstawną (GAN) pomaga w grach zręcznościowych, które składają się z dwóch stanów sztucznych sieci neuronowych (ANN) zwanych dyskryminatorem i węzłem generatora. Dostarcza on realistyczne próbki z narzędziami dyskryminacyjnymi, które kategoryzują prawdziwe i fałszywe dane. Generuje to doskonałe materiały o dużej zmienności, obejmujące dźwięk, obraz i tekst o charakterze przeciwstawnym.

Autoenkodery wariacyjne (VAE)

Drugi zestaw algorytmów generatywnych, stanowiący podstawę VAE, pomaga w przetwarzaniu ukrytej formy treści informacyjnej, która tworzy nowe próbki z przestrzeni danych. Forma VAE jest rozróżniana na podstawie ich zdolności do rejestrowania podstawowego frameworka danych, który zachowuje niektóre kluczowe właściwości wartości danych wejściowych.

Transfer uczenia

Transfer uczenia zapewnia strategiczny rozwój LLM, które stale trenują wstępnie duże wolumeny zbiorów danych przed dostrojeniem ich do kontekstu. LLM wykorzystują te informacje uzyskane z różnorodnych zbiorów danych, które efektywnie przetwarzają dane, realizując specyficzne zadania, takie jak pisanie podsumowań i analiza sentymentów.

Architektura transformatorowa

Przetwarzanie języka naturalnego (NLP) zostało poddane transformacji za pomocą LLM. Tworzy to modele, które wydajniej radzą sobie z odległymi relacjami z informacjami tekstowymi. Spójne i trafne środowisko jest tworzone w różnych domenach poprzez zastosowanie odpowiedniego procesu dla każdego słowa w zestawie zdań. Trudno jest zrozumieć i zrealizować najważniejsze idee dotyczące sztucznej inteligencji i maszyn uczących się języków (LLM) w wielu branżach.

Algorytmy stosowane w modelach generatywnych

Modele generatywne wykorzystują różne algorytmy i techniki do generowania nowych danych, które przypominają wejściowe dane treningowe. Oto niektóre z kluczowych algorytmów stosowanych w modelach generatywnych.

Rekurencyjne sieci neuronowe (RNN)

Najskuteczniejszą techniką rozwiązywania problemów z przetwarzaniem języka naturalnego (NLP), szczególnie w przypadku reprezentacji danych w postaci sekwencji, są rekurencyjne sieci neuronowe (RNN). Wyzwania związane z modelowaniem sekwencji są znacznie łatwiejsze dzięki pamięci wewnętrznej RNN, która pozwala im przywoływać zarówno przeszłe, jak i teraźniejsze dane wejściowe.

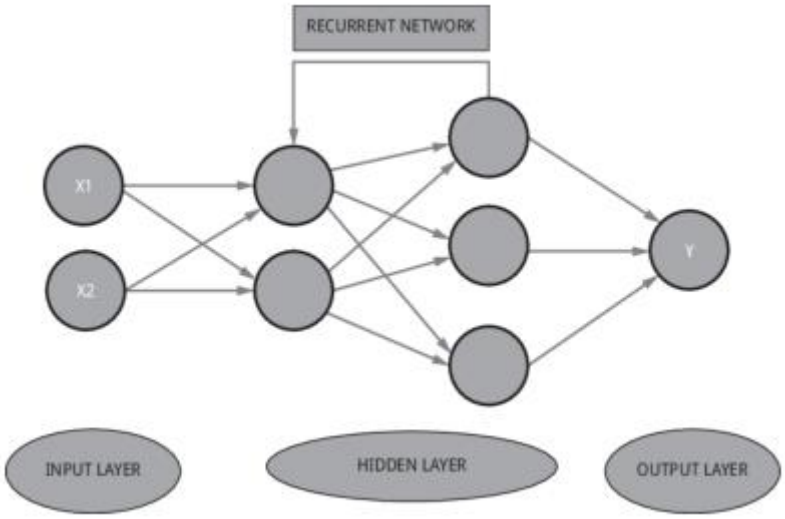

Ponieważ wynik w każdym kroku limitu czasowego zależy nie tylko od odbieranych danych, ale także od wyniku utworzonego we wcześniejszych fazach czasowych, jest on bardzo skuteczny w rozwiązywaniu problemów takich jak ocena sentymentu, tłumaczenie języków i tworzenie lingwistyczne . Rysunek 2 przedstawia podstawową strukturę sieci neuronowej (RNN). Wszystkie wartości w sieci neuronowej (SSN) są od siebie różne; jednak zmienne w sieci RNN są od siebie zależne. Ze względu na wysoką liczbę wielowymiarowych stanów ukrytych i czynników nieliniowych, sieci RNN są w stanie reprezentować zadania w sekwencji.

Pamięć długoterminowa (LSTM) i bramkowana jednostka rekurencyjna (GRU)

Bez stanu ukrytego pamięć długoterminowa (LSTM) ma taką samą konstrukcję jak zwykłe sieci RNN. Komórki, jednostki pamięci w bankach LSTM, otrzymują jako dane wejściowe mieszankę stanu poprzedniego i danych wejściowych. To, co faktycznie jest przechowywane w pamięci, a inne informacje są usuwane, jest określane przez te struktury komórkowe. Uczy się tylko w celu zachowania danych niezbędnych do tworzenia prognoz – wszystkie inne dane są zapominane. Wejście, stan poprzedni i pamięć bieżąca to trzy różne stany pamięci, których LSTM używają w połączeniu, aby rozwiązać problemy takie jak zanikające/eksplodujące gradienty. Jest to mniej skomplikowane niż LSTM, gdzie metoda dodatkowo wykorzystuje aktualizację wartości dla bramek.

Dwukierunkowe sieci neuronowe (BRNN)

Przy tworzeniu dowolnego modelu głębokiego uczenia się, wybór podejścia jest kluczowy. Zaproponowano wiele zaawansowanych modeli generatywnych z sekwencjami wyników

generowanymi przez dwukierunkowe sieci neuronowe (BRNN). Podstawową zasadą działania sieci BRNN jest to, że wynik w kroku czasowym może być oparty zarówno na przyszłych, jak i poprzednich składowych sekwencji. Mówiąc wprost, składają się one z dwóch oddzielnych sieci RNN. Aby to zbadać, należy zmieszać wyniki dwóch sieci RNN, z których jedna wykonuje procedurę w przód, a druga w tył. Rysunek 3 przedstawia strukturę sieci BRNN.

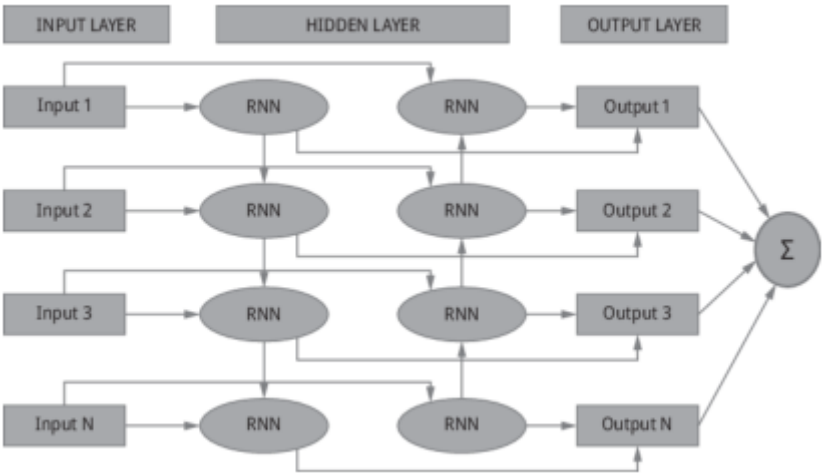

Neuronowe maszyny Turinga to kolejna modyfikacja sieci RNN, która zwiększyła pojemność sieci poprzez włączenie oddzielnego zasobu pamięci, którym można manipulować za pomocą procesu fokusowania. W przeciwieństwie do sieci LSTM, która przechowuje informacje w stanie ukrytym, sieć nietargetowana udostępnia dane na zewnątrz.

Moc splotowych sieci neuronowych (CNN)

Sieci splotowe to popularna technika analizy wizualnej. W zależności od kategoryzacji problemu, zadania NLP wykorzystują frazy, zdania, a czasami symbole zamiast pikseli obrazu, w przeciwieństwie do komputerowych problemów z widzeniem, gdzie piksele z obrazów są używane jako dane wejściowe. W ten sposób każde słowo jest reprezentowane jako graf w każdym wierszu . Odwrócenie macierzy fraz służy do tworzenia map cech o zmiennej długości. Każda mapa jest następnie poddawana maksymalnemu łączeniu, co daje największą liczbę cech z każdej mapy cech. Sześć powyższych map służy do tworzenia unitarnych wektorów cech, które są następnie łączone w celu utworzenia pojedynczego wektora wektorów cech dla warstwy końcowej. Ostatecznie ten wektor cech jest przesyłany do warstwy softmax, która klasyfikuje słowa zgodnie z założeniem kategoryzacji binarnej, dając dwa alternatywne wyniki.

Funkcje aktywacji stosowane w modelach generatywnych

Dobór funkcji aktywacji ma istotny wpływ na skuteczność działania tych modeli. Bez ich pomocy system zachowywałby się jak funkcja liniowa, próbując uczyć się nieregularnych cech. Funkcja aktywacji jest implementowana, aby umożliwić systemowi uczenie się skomplikowanych zagadnień. Dlatego też jej różniczkowalność również wpływa na wybór funkcji aktywacji. W głębokich modelach generatywnych często stosuje się następujące funkcje aktywacji.

Sigmoidalna

Do kategoryzacji wyników w modelach generatywnych stosuje się sigmoidalną funkcję aktywacji. Wartości tej funkcji wynoszą 0 i 1. Wynik jest wyśrodkowany wokół zera i wykazuje opóźnione

całkowanie – dwie wady, które sprawiły, że funkcja ta straciła na popularności ze względu na łatwość zrozumienia i użycia.

Relu

Różne głęboko generowane struktury lepiej nadają się do różnych funkcji aktywacji. Leaky i Relu to dwie z wielu popularnych funkcji aktywacji. Jest ona wykorzystywana w prawie wszystkich głębokich modelach generatywnych i pomaga złagodzić problem zanikającego gradientu. Aktywacja Relu redukuje wartości ujemne do zera. Obecne ograniczenia Relu obejmują fakt, że jest on ograniczony do zastosowania w warstwach ukrytych wewnątrz sieci neuronowych oraz że niektóre gradienty słabną, a nawet zanikają podczas treningu, co zwiększa ryzyko obumarcia neuronów w wyniku działania Relu, co pokazano na Rysunku 4.

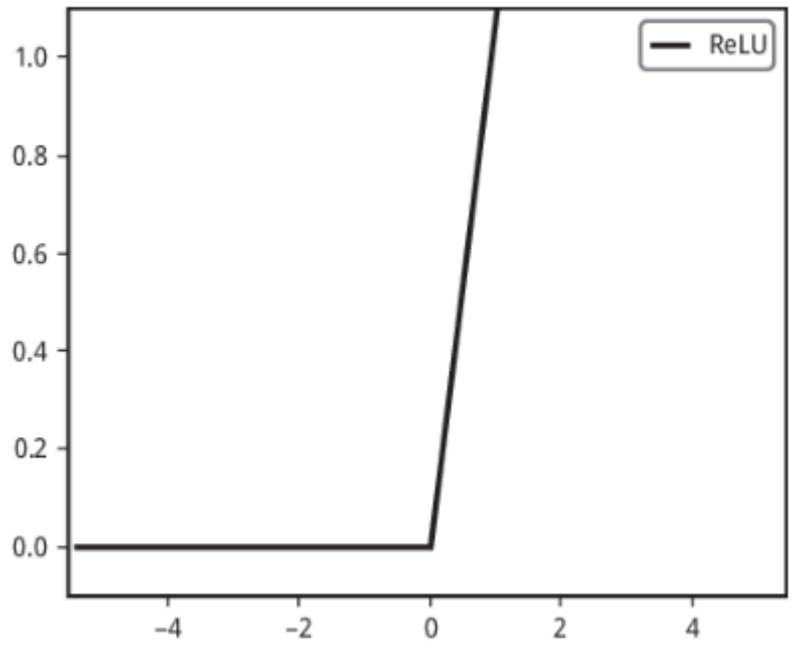

Aby utrzymać aktualizacje, zaimplementowano nieszczelną odmianę Relu, która wykorzystuje niewielkie nachylenia. W takich okolicznościach gradienty są całkowicie zamknięte na propagację wsteczną. Ponieważ generator sieci neuronowej musi zachować tylko jeden sposób uczenia się, pobierając nachylenia z dyskryminatora, jest to bardzo korzystne dla algorytmów GAN.

Techniki optymalizacji modelowania generatywnego

Modele głębokiego uczenia mają na celu znalezienie minimum, które dobrze sprawdza się pod względem generalizacji. Mogą one określić najniższą wartość funkcji z celami (funkcja błędu) za pomocą strategii optymalizacji . Uruchamianie algorytmów uczenia się z różnymi zmiennymi i wybieranie optymalnych, aby zmaksymalizować zdolność algorytmu do generalizacji, byłoby rozsądnym podejściem. Zatem tempo uczenia się musi być wysokie w niektórych obszarach, a niskie w innych. Ustawienie odrębnych tempa uczenia dla każdego wymiaru stanowi oczywiste rozwiązanie tego problemu, ale wiele modeli głębokiego uczenia się obejmuje dużą liczbę pomiarów, co czyni to niepraktycznym. Inną techniką obliczającą tempo adaptacyjnego uczenia się dla każdego parametru jest Adam, czyli adaptacyjne oszacowanie momentu. Coraz więcej osób wykorzystuje technikę optymalizacji Adam, będącą wariantem losowego spadku gradientu, do zastosowań uczenia maszynowego, takich jak analiza wizualna i NLP. W praktyce Adam działa skutecznie i przewyższa inne adaptacyjne metody uczenia się, ponieważ szybko się scala, model szybko się uczy i rozwiązuje

wszystkie problemy napotykane przez inne metody optymalizacji, w tym zanikające tempo odkrywania, powolną integrację i duże odchylenia w modyfikacji parametrów, które powodują fluktuację utraty funkcji.

Generowanie tekstu

Jednym z głównych zadań przetwarzania języka naturalnego (NLP) jest generowanie tekstu, czyli automatyczne tworzenie tekstu sensownego i odpowiedniego kontekstowo. Zazwyczaj w oparciu o dane wejściowe lub wskazówkę, procedura ta obejmuje tworzenie słów lub sekwencji znaków zgodnych z określonym wzorcem lub stylem. Tworzenie tekstu odbywa się za pomocą różnych metod, od podstawowych ram statystycznych po złożone struktury uczenia maszynowego. Najbardziej imponującą metodą jest wykorzystanie języków modelowania, które działają poprzez tworzenie nowej formy tekstu na podstawie rozproszonych prawdopodobieństw w danym języku. Sieci neuronowe (RNN) i projekty oparte na transformatorach okazują się zaawansowanymi modelami, które pomagają w przechwytywaniu danych, a ich relacja jest uwzględniana jako tekst wejściowy. Taka forma tworzenia tekstu jest wykorzystywana w wielu dziedzinach, takich jak tłumaczenie robotyczne, tworzenie materiałów dla chatbotów, konwersacje systemowe i asystenci AI.

Wstępne trenowanie i dostrajanie modeli LLM

Metody wstępnego trenowania i dostosowywania parametrów stanowią kluczowe etapy w użytkowaniu i tworzeniu modeli LLM. Jest to szczególnie istotne w przypadku modeli GAI. Faza wstępnego trenowania jest połączona z trenowaniem dużych zbiorów danych, które pomagają modelom LLM zapoznać się z podstawowymi ramami językowymi, a także trendami obserwowanymi w językach naturalnych. Ogólnie rzecz biorąc, do trenowania stosuje się podejście uczenia maszynowego, zwane podejściem bez nadzoru, w którym symulator jest trenowany w celu przechodzenia przez kolejną sekwencję fraz w oparciu o kontekst podany w słowach. Aby uzyskać rozległą wiedzę na temat słów, dokumentów, takich jak czasopisma, książki i treści online, trenuje się modele LLM, takie jak seria OpenAI GPT. Po takiej wstępnie wytrenowanej sieci modele LLM są dostrajane pod kątem dostosowania modelu do dalszych obszarów i operacji. Udoskonalanie jest określane jako proces ponownego trenowania modelu wraz z wcześniej wytrenowanymi treściami, które są mniejsze i również specyficzne dla oznaczonych instancji treningu nadzorowanego. Dostrajanie algorytmu odbywa się poprzez modyfikację parametrów, które ściśle odpowiadają wymaganiom stawianym zadaniom, aby osiągnąć doskonałość w takich czynnościach, jak generowanie podsumowań, odpowiadanie na zapytania i analiza sentymentu. Istnieje również głęboka potrzeba poprawy zdolności LLM-ów w konkretnych projektach, aby tworzyć bardziej precyzyjne i odpowiednie formy aplikacji tekstowych.

Rysunek 5 przedstawia etapy wstępnego treningu i dostrajania LLM.

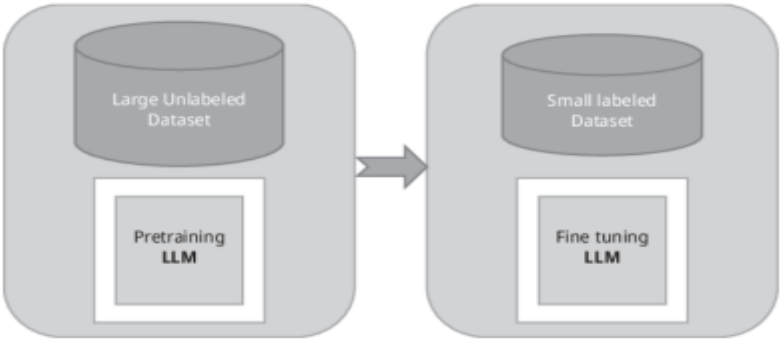

Te fazy precyzyjnego treningu i wstępnego treningu są kluczowe, ponieważ pomagają w tworzeniu sieci GAN i LLM, które z kolei umożliwiają tworzenie ogromnych zbiorów danych, a także w dostosowywaniu określonych zadań i domen, co pozwala na pełne wykorzystanie możliwości sztucznej inteligencji (AI) i przetwarzania języka naturalnego (NLP). W kontekście GAI, nieoznakowane duże zbiory danych odnoszą się do zbioru bez określonej etykiety lub adnotacji, dostarczanej przez ludzi w celu wskazania jego klasy/kategorii. Źródłami są bardzo często dane o wysokiej częstotliwości z różnych źródeł, z których głównymi są dane tekstowe (dokumenty, obrazy, nagrania audio lub dane z czujników), a w większości przypadków nie ma adnotacji dostarczonych przez człowieka. Nieoznakowane, ogromne zbiory danych są bardzo powszechne w zadaniach uczenia się bez nadzoru, gdzie maszyna musi znaleźć ukryte wzorce, struktury lub reprezentacje w danych bez etykietowania. Przeciwieństwem małych, oznaczonych zbiorów danych w GenAI jest to, że składają się one z próbek danych, z których każda jest oznaczona etykietą lub adnotacją prezentującą kategorię, klasę lub zmienną docelową. Takie małe zbiory danych są zazwyczaj przeznaczone do zadań uczenia nadzorowanego, których celem jest trenowanie modeli uczenia maszynowego w celu przewidywania lub klasyfikowania nowych próbek na podstawie przykładów dostarczonych wraz z oznaczonymi zbiorami danych. Grupa przykładów w małych, oznaczonych zbiorach danych w GenAI to rodzaj danych podzielonych na miniaturowe podzbiory, w których każdy egzemplarz ma tę samą etykietę lub adnotację. W rzeczywistości kontrast jest tu przedstawiony w tym, że zbiory danych treningowych są znacznie mniejsze niż duże, nieoznaczone zbiory danych. Tego rodzaju zbiory danych są wykorzystywane w uczeniu nadzorowanym, gdzie celem jest trenowanie modeli uczenia maszynowego w celu przewidywania lub etykietowania nowych próbek danych przy użyciu oznaczonych przykładów dostarczonych w zbiorze danych. Sieci GAN zawierają dwa ważne komponenty, zwane trenowaniem wstępnym i dostrajaniem, które nieznacznie różnią się od modeli LLM. Sieć generacyjna pomaga sieci dyskryminatorów w sieciach GAN odróżnić próbki rzeczywiste od fałszywych. Pomaga to w generowaniu dokładniejszych próbek, nawet jeśli rozkład jest nieznany. Bezpośrednio po początkowym treningu stosowana jest procedura uczenia się antagonistycznego, która udoskonala zarówno generator, jak i dyskryminator. Pomaga to w poprawie jakości próbek uzyskanych z różnych źródeł. Ten stan dopasowania pomaga w iteracyjnym ustawianiu wartości w celu osiągnięcia równowagi Nasha, tak aby generator generował dane w oparciu o opinię dyskryminatora, która jest bardziej prawdopodobna w odniesieniu do rzeczywistych informacji.

Wpływ na generatywną sztuczną inteligencję i LLM

Na generatywne AI i GAI wpływają wstępne etapy szkolenia i dostrajania, które pomagają w kształtowaniu modeli o wysokiej skuteczności, a także zdolności do szerszego zastosowania i zakresów środowiskowych. Wstępna faza szkolenia umożliwia LLM tworzenie ogromnych zbiorów danych w celu wygenerowania kompleksowego zrozumienia mowy, a także struktur werbalnych . LLM skutecznie tworzą spójne i istotne teksty kontekstowe w różnych dyscyplinach, takich jak złożone wzorce uczenia się, zastosowania oparte na regułach gramatycznych oraz instrukcje oparte na większej ilości danych tekstowych. Ze względu na niewielki zakres danych specyficznych dla danego zadania, szkolenie odbywa się za pomocą LLM, które są udoskonalane pod kątem dalszego przetwarzania domeny i zadań, z szerszym wstępnym szkoleniem, co sprzyja uczeniu się poprzez transfer. Pomaga to w tworzeniu ram z proceduralnymi zbiorami danych, a także zmniejsza wymagania dotyczące dużych zbiorów danych dzięki etykietom, które zwiększają adaptowalność i dostępność LLM w rzeczywistości. Tabela przedstawia główne różnice między tradycyjnymi formami AI a strukturami GAI.

Mierniki wydajności: Tradycyjna sztuczna inteligencja: Generatywna sztuczna inteligencja

Zasada: Działania oparte na predykcji w celu podejmowania decyzji opartych na danych: Uczenie maszynowe oparte na tekście w celu generowania nowej treści

Architektura: Ustrukturyzowany lub nieustrukturyzowany zbiór danych: Internet lub złożony zbiór danych

Interwencja człowieka: Stały nadzór człowieka: Samouczenie się lub

bez nadzoru

Rezultat: Ograniczony nadzór kierownictwa wyższego szczebla nad decyzjami biznesowymi: Nadzór nie jest wymagany

Istnieją różne strategie dostrajania, które koncentrują się głównie na określonej domenie lub czynnościach, które dostosowują ustawienia, aby były bardziej precyzyjne i odpowiadały zamierzonemu zadaniu . W przypadku takich zastosowań, jak synteza, ocena sentymentów lub produkcja konwersacji, LLM-y generują bardziej szczegółowe i trafne wyniki dzięki próbkom opartym na zadaniach, które są zazwyczaj bardziej precyzyjne i trafne. Aby sprostać wymaganiom zwiększenia produktywności, a także skuteczności badaczy i firm, LLM-y są dostosowywane poprzez proces dostrajania NLP. Pomaga to w tworzeniu złożonych struktur modeli generujących ludzkie teksty w różnych dziedzinach. Jest to również wykorzystywane w różnych aplikacjach, takich jak tworzenie treści, chatboty, w przetłumaczonych i podsumowanych formach z innowacyjnymi mechanizmami pisania. Zachęca to do kreatywności, a także do postępu w dziedzinie przetwarzania komputerowego i NLP.

Zastosowanie LLM

GAI i LLM zmieniły nasze podejście do danych języka naturalnego i ich wykorzystanie, oferując szeroki wybór zastosowań w wielu obszarach . Poniżej przedstawiono niektóre istotne zastosowania.

Rozumienie języka naturalnego (NLU)

Rozumienie języka naturalnego (NLU) pomaga w kategoryzacji tekstu, zwanej oceną sentymentalną, oraz w identyfikacji encji zależnych od LLM . Systemy takie jak chatboty wykorzystują takie ramy, aby skutecznie komunikować się za pośrednictwem asystentów AI z systemami wsparcia i udzielać skutecznych odpowiedzi na zapytania użytkowników, wyodrębniając istotne informacje z niestrukturyzowanego tekstu wejściowego. Techniki analizy semantycznej wykorzystują metody rozpoznawania znaczenia i intencji z danych tekstowych. Wśród szeregu prezentowanych zadań znajdują się rozpoznawanie encji nazwanych, analiza sentymentalna, łączenie encji i etykietowanie ról semantycznych.

Generowanie tekstu i kreatywne pisanie

Ze względu na różne style pisania różnych przedmiotów, LLM pomagają w tworzeniu materiału, który ma być bardziej logiczny i adekwatny do treści. Pomagają one również w pracy z zadaniami wymagającymi wyobraźni, takimi jak tworzenie poezji, raportów, a także opowiadań [24]. LLM-y pomagają w tworzeniu narzędzi do generowania treści dla dostosowanych działań sugestyjnych, a także postów online. Zdolność LLM-ów do wykorzystywania rozumienia kontekstowego polega na uchwyceniu szerszego kontekstu i znaczenia danych tekstowych. Takie podejście obejmowałoby długoterminową zależność, rozpoznawanie niejednoznacznej retoryki i rozwiązywanie odniesień zaimkowych oraz korzyści.

Tłumaczenie językowe

Dzięki LLM-om dziedzina automatycznego tłumaczenia poczyniła w ostatnich czasach ogromne postępy, co oznacza, że obecnie można łatwo i precyzyjnie konwertować między wieloma językami z

ludzkim akcentem. Modele te uczą się różnych języków, rozumiejąc ich złożoność i różnice, stając się w ten sposób w stanie dostarczać dokładne tłumaczenia do różnych celów, takich jak wielojęzyczne chatboty lub sklepy internetowe dla globalnych narzędzi komunikacyjnych. Dzięki technikom NLU, LLM-y są teraz w stanie odczytywać i rozumieć zapytania użytkowników, generować odpowiednie kontekstowe odpowiedzi i dialogi oraz płynnie współpracować z ludźmi i maszynami. Umożliwia ona różnorodne zastosowania dotyczące chatbotów, asystentów wirtualnych, systemów rekomendacji i platform generowania treści, w których współczesne modele językowe pełnią funkcję inteligentnych agentów zdolnych do rozumienia języka ludzkiego i reagowania na niego w sposób dość naturalny i znaczący.

Podsumowanie tekstu

Metody LLM są wykorzystywane w zadaniach podsumowujących, w których duże ilości informacji muszą zostać skondensowane w zwięzłe, ale bogate w informacje podsumowania. W dziedzinach takich jak raportowanie, śledztwa i dokumentacja prawna, algorytmy mogą szybko znaleźć istotne dane, wyodrębnić kluczowe punkty z długich dokumentów, artykułów, nagłówków itd., podejmując w ten sposób szybkie decyzje w oparciu o te informacje. W przypadku podsumowania ekstrakcyjnego, frazy lub zdania z tekstu wejściowego są po prostu redukowane i wyodrębniane w celu utworzenia podsumowania. Metoda ta obejmuje przeglądanie zdań na podstawie ich atrybutów, w tym ważności zdania, związku z głównym tematem i istotności prezentowanych informacji. TextRank, LexRank i algorytmy oparte na grafach należą do technik najczęściej stosowanych do ekstrakcji podsumowań dla różnych dokumentów.

Systemy dialogowe

Agenty systemów konwersacyjnych i dialogowych, które są zdolne do prowadzenia istotnych i organicznych rozmów z ludźmi, są tworzone za pomocą systemów LLM. Takie systemy są wykorzystywane w systemach edukacyjnych, przez asystentów wykorzystujących sztuczną inteligencję oraz boty usługowe, aby oferować klientom zindywidualizowaną pomoc, odpowiadać na zapytania i pomagać im w różnych aktywnościach i obszarach.

Generowanie treści i personalizacja

Systemy oparte na sterowanej sztucznej inteligencji (LLM) tworzą treści angażujące użytkowników. Odbywa się to za pomocą LLM, które zapewnia, że interesujący materiał jest prezentowany użytkownikom zgodnie z ich potrzebami lub preferencjami. Na przykład, spersonalizowane opisy produktów, promocji, reklam i rekomendacji są tworzone w zależności od tego, co dana osoba lubi, a czego nie, zwiększając w ten sposób poziom zadowolenia klientów i ogólne zaangażowanie w takie systemy. Proces abstrakcyjnego streszczania implikuje generowanie nowych zdań, które odpowiadają głównym ideom i koncepcjom tekstu, ale jednocześnie obejmują całe jego znaczenie w formie skondensowanej. Proces ten wykorzystuje techniki generowania języka naturalnego i modele językowe, a następnie podsumowuje akapity. Coraz więcej badaczy, wykorzystując LLM, jako przykład serii OpenAI GPT, wykorzystuje je do abstrakcyjnego streszczania tekstów, dzięki ich zdolności do rozumienia i generowania tekstu w języku angielskim, który naśladuje ludzkie zachowanie.

Badania medyczne i naukowe

W naukowych badaniach medycznych coraz częściej wykorzystuje się LLM podczas takich działań, jak analiza danych, generowanie hipotez, przeglądy badań i inne. Te modele matematyczne mogą analizować ogromne liczby prac naukowych, notatek pacjentów i artykułów naukowych, co pozwala im następnie identyfikować istotne informacje, wykrywać wzorce, dokonywać odkryć i pomagać w

rozwijaniu wiedzy medycznej. Ogólnie rzecz biorąc, GAI i LLM mają wiele zastosowań w sektorach i dyscyplinach, które stale ewoluują, aby wspierać kreatywność i ulepszać interakcje człowiek-maszyna. Modele GAI mogą pomóc między innymi w generowaniu związków chemicznych o wymaganych właściwościach, a także w przewidywaniu struktur molekularnych i optymalizacji kandydatów na leki pod kątem skuteczności i bezpieczeństwa. Takie modele mogą uzyskiwać dostęp do ogromnych baz danych chemicznych, przeprowadzać symulacje interakcji molekularnych i skracać odkrywanie potencjalnych leków na wiele chorób. Modele te mogą dostarczać algorytmom głębokiego uczenia się wysokiej jakości obrazy medyczne, które następnie mogą być wykorzystywane do szkolenia, rozszerzania danych z ograniczonych zestawów danych i symulowania rzadkich lub trudnych schorzeń. GAI może przyczynić się do rozwoju zindywidualizowanych schematów leczenia, przewidywania ich skuteczności i optymalizacji procesu leczenia. Technologia ta umożliwia skanowanie elektronicznej dokumentacji medycznej, danych z obrazowania medycznego, a nawet informacji genetycznych, dzięki czemu lekarze mogą uzyskać podstawowe zalecenia i wskazówki dotyczące diagnozowania i leczenia pacjenta.

Wyzwania i ograniczenia

Istnieje jednak szereg wyzwań i ograniczeń, które należy uwzględnić w kontekście wykorzystania LLM i GAI.

Błąd i uczciwość

Wyniki LLM trenowane na dużych zbiorach danych, które dziedziczą te błędy, są często obciążone błędami. Takie błędy mogą sprzyjać dyskryminacji określonych grup ludzi, utrwalać nierówności lub stereotypizować różne społeczności. Aby zapewnić uczciwość w LLM, konieczne jest zwalczanie błędów, a także promowanie równości w ich obrębie na odpowiedzialnych etapach rozwoju dowolnej sztucznej inteligencji.

Etyczne wykorzystanie

Ludzie mogą niewłaściwie wykorzystywać LLM wraz z innymi systemami GAI, np. rozpowszechniając za ich pośrednictwem fałszywe wiadomości, a nawet przybierając fałszywe tożsamości, korzystając z tych technologii. Ważne jest egzekwowanie silnych ram prawnych, wspieranych przez regulacje prawne, wraz z mechanizmami raportowania, które będą promować etyczne wykorzystanie LLM, jednocześnie zapobiegając nadużyciom prowadzącym do niezamierzonych negatywnych konsekwencji.

Obawy dotyczące prywatności

Ryzyko naruszenia prywatności może pojawić się podczas generowania tekstu, ponieważ modele LLM trenowane na dużych zbiorach danych mogą nieumyślnie przywołać prywatne lub poufne informacje z danych treningowych [30]. Bezpieczeństwo użytkowników i integralność informacji powinny być chronione podczas opracowywania modeli LLM poprzez stosowanie szyfrowania, poufności danych, prywatności różnicowej itp.

Zasoby obliczeniowe

Szkolenie i optymalizacja programów LLM wymagają znacznych zasobów obliczeniowych, takich jak wydajne procesory GPU, TPU i infrastruktura na dużą skalę. Wysokie koszty obliczeniowe związane z tworzeniem i wdrażaniem programów LLM mogą ograniczać ich powszechną akceptację i adopcję, zwłaszcza wśród mniejszych przedsiębiorstw lub badaczy o ograniczonych budżetach.

Wpływ na środowisko

Ogromne zużycie energii podczas nauczania programów LLM przyczynia się do emisji gazów cieplarnianych i zanieczyszczenia środowiska. Aby zmniejszyć wpływ na środowisko GAI poprzez nauczanie LLM, można zaprojektować algorytmy, które zużywają mniej energii, a jednocześnie promują odpowiedzialne praktyki badawcze w zakresie sztucznej inteligencji w trakcie rozwoju.

Interpretowalność i przejrzystość

Ponieważ nie są one łatwe do zinterpretowania nawet w najlepszych czasach, zrozumienie, dlaczego model podjął daną decyzję lub co jego wynik oznacza w ogólności dla dużych architektur sieci neuronowych, takich jak te wykorzystywane w większości najnowocześniejszych modeli językowych, może być trudne. Cele te wymagają zwiększenia przejrzystości modeli, umożliwiając współpracę między ludźmi a maszynami, a także zapewniając szerszą dostępność poprzez lepsze zrozumienie wspierane przez lepsze studia magisterskie (LLM).

Jakość i różnorodność danych

Aby studia magisterskie (LLM) mogły być skutecznie uogólniane i generować spójne wyniki, kluczowe znaczenie ma jakość i różnorodność danych szkoleniowych. Gromadzenie, wzbogacanie i dywersyfikacja danych w szkoleniach LLM są zatem ważne, ponieważ mogą ograniczać użyteczność lub stosowalność algorytmów opartych na niepoprawnych lub przekłamanych zbiorach danych. Aby pokonać te wyzwania i ograniczenia, potrzebne jest podejście multidyscyplinarne, angażujące środowisko akademickie, decydentów, grupy interesariuszy i całe społeczeństwo. Etyka, sprawiedliwość, prywatność, zrównoważony rozwój i uczciwość powinny być w centrum uwagi podczas tworzenia i wykorzystywania studiów magisterskich (LLM), uwalniając w ten sposób ich transformacyjny potencjał dla GAI.

Przyszłe kierunki

Istnieje wiele dziedzin, w których można oczekiwać, że LLM i GAI znajdą interesujące zastosowania w nadchodzących latach. Oto kilka potencjalnych obszarów dalszych badań:

Ciągłe doskonalenie skali i wydajności

Przewiduje się, że przyszłe LLM będą znacznie większe niż obecne wersje; będą również bardziej wydajne, umożliwiając im rozumienie złożonego języka naturalnego [34]. Metody szkolenia ulegną radykalnej zmianie wraz z udoskonaleniami sprzętowymi, umożliwiającymi budowę LLM na niespotykaną dotąd skalę w połączeniu z postępami algorytmicznymi.

Możliwości multimodalne

Oczekuje się, że LLM nowej generacji będą bardziej adaptacyjne w różnych sytuacjach, a także będą zdolne do dostosowywania treści w zależności od preferencji odbiorców, grup socjologicznych i wcześniejszych dialogów.

Adaptacja kontekstowa i personalizacja

Aplikacje takie jak systemy sugestii, usługi przewidujące, narzędzia edukacyjne, wyszukiwarki restauracji i aplikacje pogodowe to tylko kilka przykładów usług, które ostatecznie zmienią sposób, w jaki wchodzimy w interakcje ze sztuczną inteligencją. Robi to poprzez ocenę danych kontekstowych, aby generować spersonalizowane odpowiedzi, artykuły i rekomendacje, które uczynią doświadczenia bardziej konkretnymi.

Etyczny i odpowiedzialny rozwój sztucznej inteligencji (AI)

Jeśli chodzi o technologię studiów magisterskich (LLM) i GAI, oczywiste jest, że tendencja do etycznego i moralnie uzasadnionego rozwoju AI stanie się faktem. Dążąc do osiągnięcia większego zaufania, odpowiedzialności i publicznego zrozumienia praktyk AI, naukowcy, rząd i partnerzy biznesowi będą współpracować, aby wyrównać szanse moralne, działać uczciwie, zapewnić prywatność danych i transparentność w odniesieniu do studiów magisterskich (LLM).

Współpraca między człowiekiem a sztuczną inteligencją (AI)

Jutro studia magisterskie (LLM) będą postrzegane jako platformy, z których można bardzo łatwo korzystać z pomocą ludzi i/lub sztucznej inteligencji (AI), aby szybko rozwiązywać problemy oraz usprawniać procesy kreatywne i decyzyjne [36]. Użytkownicy będą mieli możliwość współpracy w ramach programu, wniesienia własnego wkładu i lepszego wykorzystania sztucznej inteligencji w bardziej realistycznych sposobach realizacji tych paradygmatów, co przyczyni się do poprawy symbiozy i współpracy między człowiekiem a maszyną.

Zastosowania specyficzne dla danej dziedziny i specjalistyczne

Z czasem przyszłe studia magisterskie (LLM) będą łączyć ludzi i sztuczną inteligencję, tworząc idealne dopasowanie, co z kolei przyczyni się do rozwoju ludzkiej kreatywności, efektywności i trafności decyzji. Zadania użytkowników, takie jak wprowadzanie zmian, dodawanie komentarzy i zadawanie pytań systemom sztucznej inteligencji w ramach tych modeli, będą bardziej akceptowane, ponieważ decyzje będą podejmowane bardziej logicznie, a współpraca między człowiekiem a maszyną ulegnie poprawie.

Badania i współpraca interdyscyplinarna

Dyscyplina i współpraca między psychologią społeczną języka, neuronauką i etyką będą w niedalekiej przyszłości głównym stylem studiów magisterskich (LLM) i sztucznej inteligencji. Ta innowacja dyscyplinarna zainspiruje nowe podejścia w dziedzinie sztucznej inteligencji i będzie motorem innowacji w miejscu, gdzie nauki humanistyczne i sztuczna inteligencja spotykają się w dogłębnych badaniach nad poznaniem i mową. Mimo że istnieje jeszcze wiele nieodkrytych obszarów, studia LLM i GAI zmierzają ku świetlanej przyszłości, która przełamie bariery sztucznej inteligencji, otworzy możliwości niesamowitych zastosowań i sprawi, że sztuczna inteligencja stanie się nieodłączną częścią ludzkiego języka.

Podsumowanie

Podsumowując, studia LLM i GAI należą do najważniejszych kamieni milowych w rozwoju sztucznej inteligencji (AI). Ich doświadczenie sprzyja licznym, rewolucyjnym zmianom w sposobie pozyskiwania i wykorzystywania informacji w kontekście języków naturalnych. Wykorzystując niewyobrażalną zdolność do jednoczesnego czytania, analizowania, cytowania i tworzenia tekstu na niespotykaną dotąd skalę, możliwości studiów LLM stworzyły mnóstwo potencjalnych zastosowań we wszystkich dziedzinach i sektorach. Chociaż studia LLM, w zakresie swoich niezwykłych możliwości, są podatne na problemy etyczne i społeczne, w tym autonomię, uprzedzenia i bezpieczeństwo, nie powinno to przesłaniać ich potencjału w zakresie rozwoju społecznego i kreatywności. Podejście mające na celu zapewnienie kompetentnego grafowania studiów LLM i technologii Sail w obszarze etyki, rozwoju prawa i dobrych praktyk wymaga współpracy specjalistów ze środowiska akademickiego, parlamentu, biznesu i społeczności w celu rozwiązania tych problemów. Architektury wielokanałowe, w tym umiejętności praktyczne i potencjał wielozmysłowy w zakresie rozwoju aplikacji branżowych, mogą zostać jeszcze lepiej dopracowane w przyszłości studiów LLM dzięki rosnącej skalowalności i wydajności. Przed projektowaniem aplikacji AI konieczne jest uwzględnienie wszystkich czterech

elementów: moralności, równości, przejrzystości i projektowania zorientowanego na użytkownika. W zależności od nich należy określić ich zastosowanie zarówno w życiu osobistym, jak i społecznym. Dlatego też powinny być one ponumerowane, jednocześnie kontynuując rozwój technologii. Modele lingwistyczne wraz z technologią ogólnej AI pozwalają na ostateczną restrukturyzację używanych języków, tworząc w ten sposób bardzo interesującą epokę w używaniu i odbiorze języka, a jednocześnie wnosząc dużą wartość do komunikacji i analizy w erze cyfrowej. Dzięki wykorzystaniu zarówno studiów LLM, jak i GAI, możliwe jest wykonywanie skomplikowanych zadań, wspieranie twórczej pracy pojedynczej osoby oraz budowanie sprawiedliwego społeczeństwa w taki sposób, aby ludzie byli traktowani równo. W zarządzaniu istnieją zasady moralne, zrównoważone metody i technologie multidyscyplinarne.