Przyszłe kierunki i otwarte problemy w generatywnej sztucznej inteligencji (AI)

Streszczenie

Technologia sztucznej inteligencji (AI), generatywna AI (GAI), dokonała rewolucji i na skalę międzysektorową, zmieniając nasze działania. Rozwój technologiczny i jej wdrażanie stanowią wyzwania etyczne, społeczne i regulacyjne. Tu zajmujemy się trudnościami związanymi z regulacjami dotyczącymi AI i wskazujemy decydentom sposób radzenia sobie z nimi. Kluczowymi kwestiami są prywatność danych, stronniczość algorytmiczna danych, przejrzystość danych i rozliczalność danych; to właśnie stanowi różnicę między innowacyjnością danych a kwestiami etycznymi. Sekcja omawia interesariuszy z różnych obszarów i kształtowanie multidyscyplinarnych podejść do zarządzania AI. Niniejszy część omawia ramy regulacyjne, które umożliwiają rozwój i rozwój technologii AI. Decydenci mogą stworzyć środowisko sprzyjające współpracy poprzez wdrażanie AI w celu zmniejszenia potencjalnych zagrożeń i wyzwań społecznych. Niniejszy przewodnik pomaga decydentom, początkującym badaczom i praktykom zrozumieć AI, a także współpracować i pracować nad technologiami umożliwiającymi jej wykorzystanie.

Słowa kluczowe: Odpowiedzialność, stronniczość algorytmiczna, współpraca, rozważania etyczne, prywatność danych, sztuczna inteligencja generatywna, podejścia interdyscyplinarne, ramy regulacyjne, odpowiedzialny rozwój, zalecenia polityczne, przejrzystość.

Wprowadzenie

Dzięki postępowi technologicznemu, generatywna sztuczna inteligencja (GenAI) przekształca potencjał kreatywności danych, transformując branże danych i rozwiązując problemy społeczne. Niniejszy rozdział wyjaśnia różnorodne wyzwania i przyszłe kierunki rozwoju GenAI, analizując różne kierunki rozwoju danych, nierozwiązane problemy z danymi oraz przyszłe luki w rozwoju rozwijającej się dziedziny . Czym jest GenAI? Badanie dotyczy tworzenia obrazów o wysokiej jakości, oryginalności obrazów, tekstu, dźwięku i innych formatów . Rozwój technologiczny i zaangażowanie w uczenie głębokie, z wykorzystaniem dużych modeli językowych, ma znaczenie dla GenAI dla tworzenia realistycznych i spójnych danych. Wyzwania etyczne i społeczne, które należy pokonać, aby poprawić jakość i różnorodność próbek. Aby określić przyszły kierunek rozwoju GenAI, ważne jest, aby patrzeć w przyszłość, rozwijać się i nadal rozwijać innowacje, pokonywać przeszkody i otwierać obszary danych . Innowacyjne trendy, projekty i interdyscyplinarne metodologie danych, badacze danych i profesjonaliści są zaangażowani w rozwój systemów GenAI ze względu na skalowalność i kwestie etyczne . Aby rozwiązać otwarte problemy i zidentyfikować obszary rozwoju oraz zrozumieć obecny stan GenAI, wyzwania w GenAI obejmują różnorodność danych, kwestie etyczne i różne problemy skalowalności dla kreatywnego myślenia i współpracy multidyscyplinarnej . Aby poradzić sobie z nierozwiązanym problemem, możemy rozwijać etyczny i odpowiedzialny rozwój technologii GenAI. W tym rozdziale omawiamy ważne tematy, obejmujące implikacje społeczne i etyczne, w celu ulepszenia modeli generatywnych, budowania luki semantycznej, rozwijania różnorodności i jakości danych, kontrolowania interpretowalności, badania nowych technik i architektur, ulepszania kierunków badań, zmiany perspektyw przemysłu oraz różne studia przypadków . Dzięki tej współpracy opracowywane są przyszłe kierunki. Nasz rozdział omawia możliwości ulepszania danych, wyzwania stojące przed danymi oraz konsekwencje GenAI, rozwijając potencjał technologii transformacyjnej do rozwojowego i odpowiedzialnego wykorzystania. Omawiając skomplikowane wyzwania i problemy z perspektywy studentów, omawiamy przyszłość GenAI i jej wpływ.

Przegląd generatywnej sztucznej inteligencji (GenAI)

GenAI to nowa, innowacyjna, zrewolucjonizowana technologia, będąca częścią sztucznej inteligencji, służącą do tworzenia nowych rzeczy bez przetwarzania i analizowania danych, które były już wcześniej dostępne. Standardowa sztuczna inteligencja zajmuje się klasyfikacją, predykcją i klastrowaniem, podczas gdy GAI zajmuje się tworzeniem nowych rzeczy, takich jak obrazy, muzyka, tekst, oraz tworzeniem innowacyjnego wirtualnego świata. Nowe architektury sieci neuronowych, takie jak transformatory, VAE i GAN, działają lepiej niż poprzednia technologia. Główną ideą GenAI jest to, że jest ona trenowana na poprzednich danych, dzięki czemu generuje bardziej realistyczne dane z wytrenowanych danych. Modele te wykorzystują biliony danych do określania różnych wzorców i struktur, tworząc realistyczny obraz. Pomaga to w tworzeniu fałszywych obrazów do tworzenia opowiadań, komponowania piosenek i niekończącego się tworzenia danych za pomocą GenAI i jest wykorzystywane we wszystkich branżach, takich jak muzyka, rozrywka, dane dotyczące opieki zdrowotnej i dane finansowe . GenAI jest wykorzystywane do rozwiązywania problemów etycznych i łatwiejsze do zrozumienia. Skomplikowana natura GenAI pomaga badaczom w identyfikowaniu problemów i opracowywaniu rozwiązań.

Znaczenie eksploracji GenAI

GenAI rozwija się szybko i ważne jest, aby zwrócić uwagę na to, jaki jest kolejny krok rewolucji w tej technologii, który jest kluczowy. Pojawiające się nowe technologie, trendy i wyzwania związane z technikami, a także dostrzeganie możliwości, początkujących naukowców, praktyków wykorzystujących technologie i decydentów, wykorzystują te technologie i wymieniane jako rozwijające się technologie, a nie jako problem. Po zbadaniu przyszłych kierunków rozwoju GenAI, opracowano lepszy model AI, który staje się bardziej niezawodny i bardziej korzystny w różnych dziedzinach. Pomaga nam to rozwiązywać nowe innowacyjne problemy poprzez współpracę z różnymi dziedzinami i uczynić GenAI bardziej etycznym, a także odpowiedzialnym, a także dostarczać perspektywy techniczne, a także myśleć o kwestiach prawnych. W ostatnim czasie GenAI zintegrowało się z naszą codzienną działalnością, dlatego obowiązkowe jest upewnienie się, że jest tworzone i używane odpowiedzialnie, aby uniknąć problemów i stronniczości. Dzięki współpracy z ludźmi z różnych środowisk i aktywnej współpracy możemy opracować wytyczne regulacyjne i ramy, aby sprawdzić, czy AI jest używane prawidłowo . Aby skutecznie wykorzystać technologię, ważne jest, aby skutecznie zwrócić uwagę na przyszłość badań GenAI. Ucząc się od siebie nawzajem, możemy stworzyć świetlaną przyszłość dla GenAI i dla ludzi, którzy z niej korzystają.

Poprawa jakości i różnorodności próby oraz wyzwania związane z generowaniem próby

Opracowanie wysokiej jakości, zróżnicowanych danych próby w modelach GenAI wiąże się z wyzwaniami. Jednym z głównych czynników jest szum w danych rzeczywistych, co utrudnia generowanie danych o dużej złożoności. Głównym wyzwaniem jest opracowanie modeli generujących zróżnicowane wyniki i reprezentujących rozkład danych. Aby przezwyciężyć te problemy, naukowcy opracowują nowe, innowacyjne techniki. Niektóre z technik, na których należy się skupić, to udoskonalanie modeli, celu procesu uczenia lub kryteriów pomiaru i rozwoju jakości próby. Jednym z głównych podejść jest udoskonalenie modelu architektury i metody uczenia. Poprzez dostrajanie parametrów i eksperymentowanie z różnymi algorytmami i technikami optymalizacji, naukowcy opracowują modele do tworzenia bardziej realistycznych i spójnych próbek. Funkcje utraty percepcji oparte są na percepcji danych, aby uczynić je bardziej realistycznymi. Aby poprawić jakość, przedstawiono techniki uczenia się z samonadzorem. W celu wykorzystania zadań pomocniczych i realizacji celu uczenia się bez nadzoru, modele mogą generować bardziej solidną reprezentację danych, a także rozwijać jakość i różnorodność próbek. Rozszerzanie i adaptacja danych są niezbędne do rozwiązania konkretnych problemów i poprawy jakości próbek, na przykład poprzez trenowanie i

rozszerzanie danych o powiązane przykłady lub algorytmy w celu opracowywania lepszych danych i generowania próbek o wyższej jakości .

Poprawa jakości próbek

Istnieje możliwość przyszłej poprawy jakości i generowania próbek. Jednym z głównych czynników jest uwzględnienie uczenia się pod nadzorem i trenowanie nowej techniki z wykorzystaniem różnych zadań pomocniczych i celów, takich jak wykorzystanie modeli uczenia półnadzorowanego do reprezentacji danych i poprawy ich jakości a także poprzez eksplorację wykorzystania funkcji strat percepcyjnych i funkcji badawczych oraz kierowanie procesem generowania. Oceniając postrzegane podobieństwo między wygenerowanymi próbkami a danymi rzeczywistymi, te funkcje strat zachęcają modele do uchwycenia kluczowych cech i subtelności, które przyczyniają się do realizmu. Modele koncentrują się na generowaniu próbek i rozkładzie danych oraz na szerokim zakresie danych .

Strategie różnorodności

Różnorodność próbek danych ma na celu stworzenie kluczowych modeli GenAI i prezentacji wyników. Jednym z głównych podejść jest uwzględnienie celów zwiększających różnorodność w procesie uczenia. Tworząc miary różnorodności lub terminy do regularyzacji, badacze aktywnie angażują się w różnorodność stylów i wariantów, w celu zróżnicowania generowanych próbek. Techniki takie jak nauka programu nauczania i adaptacyjne próbkowanie pomagają rozwiązać te problemy, gdy modele koncentrują się na generowaniu próbek o różnorodnych trybach rozkładu danych poprzez stopniowe ulepszanie modelu do zróżnicowanych próbek i dynamiczne dostosowywanie próbek w celu generowania zróżnicowanych danych oraz łączenie podejść zespołowych w celu generowania różnorodności i ulepszania próbki danych. Różnorodność danych jest wykorzystywana do łączenia różnorodnych danych. Wielopłaszczyznowe podejście jest wykorzystywane do udoskonalenia modelu, aby wykorzystać postęp w projektowaniu architektury, metodach szkolenia i metodach ewaluacji. Badając nowe techniki, naukowcy mogą opracować nową GenAI do zastosowań w różnych danych.

Poprawa kontroli i interpretowalności w generatywnej sztucznej inteligencji (GenAI)

Istotnym wyzwaniem w GenAI jest zapewnienie użytkownikom skutecznej kontroli nad tym, co interpretowalne. Dostępność i ograniczenia kontroli, a także aspekty skomplikowanej natury modeli generatywnych, utrudniają zrozumienie wyników. Ten brak kontroli i interpretowalności może ograniczać zastosowanie GenAI w rzeczywistych scenariuszach. Badanych jest kilka metod poprawy kontroli i interpretowalności w GenAI. Aby wpływać na dane i kontrolować ich interpretowalność, zwiększa się ich wpływ. Użytkownik zyskuje większą kontrolę nad danymi i ich cechami. Inną metodą i metodą jest interaktywność generowania danych, która generuje interfejsy zapewniające interaktywność i modelowanie w czasie rzeczywistym oraz iteracyjne kontynuowanie metody w celu generowania wyników, aż do osiągnięcia celu. Preferencje i sprzężenie zwrotne pętli między modelem a użytkownikiem pozwalają na zaprojektowanie uczenia się i adaptację . Rozróżniono reprezentację uczenia się i manipulowanie atrybutami oraz techniki obiecywane dla przestrzeni ukrytej i sterowania. Podstawowa zmienność danych i pozycja zmiennej, oświetlenie danych i styl zmienności dla czynników oraz zapewnienie użytkownikowi kontroli nad generowaniem próby . Aby poprawić interpretowalność i badania w GenAI, stosuje się wyjaśnialną sztuczną inteligencję (XAI). W przypadku generowania wyników, celem jest dostarczenie użytkownikom informacji o tym, gdzie i jak dane się znajdują. W przypadku wewnętrznej reprezentacji danych, aspektów danych i kluczowego elementu wpływającego na wynik modelu, techniki XAI zwiększają zaufanie i przejrzystość w systemach GenAI. Postępy w projektowaniu algorytmów, interfejsie rozwoju użytkownika i współpracy interdyscyplinarnej na rzecz interoperacyjności i kontroli GenAI są wykorzystywane w różnych dziedzinach i domenach.

Wyzwania etyczne w generatywnej sztucznej inteligencji (GenAI)

Różnorodne obawy i wyzwania stanowią problem postępu w GenAI. Kwestie etyczne, z którymi boryka się GenAI, to wiarygodność danych, obawy dotyczące prywatności, stronniczość danych oraz ich rzetelność. Praktycy i badacze stoją przed wyzwaniami i odpowiedzialnością za dane, wykorzystując najnowsze innowacyjne technologie. Głównym czynnikiem wpływającym na wiarygodność danych jest dogłębne wykrywanie fałszerstw oraz manipulacja medialna w celu wyrządzenia szkód i dezinformacji. Aby wskazać te wyzwania, opracowuje się działania i techniki zapewniające transparentność i wykrywanie danych. Pomaga to we współpracy społeczności, badaczy i osób z różnych branż, a także w podnoszeniu świadomości opinii publicznej na temat metod wykrywania głębokich fałszerstw. Prywatność jest jednym z aspektów etycznych w kontekście GenAI. W GenAI wykorzystywane są duże zbiory danych. Istnieje ryzyko informacyjne, a osoby mogą nie wyrazić zgody na udostępnianie danych. Gromadzenie danych i ich transparentność są kontrolowane, a prawa do prywatności danych są kontrolowane. Uczciwość i stronniczość danych są ściśle powiązane z kwestiami etycznymi. Uprzedzenia w modelu i architekturach szkolenia danych prowadzą do dyskryminacyjnych wyników. Aby przezwyciężyć te uprzedzenia, badacze mogą skoncentrować się na szkoleniu danych, na świadomości danych i rozwoju metryk . Odpowiedzialność za dane i ich przejrzystość są odpowiedzialnością GenAI. Przejrzystość jasno wyjaśnia, w jaki sposób dane są wykorzystywane i przekazywane. Odpowiedzialność zapewnia mechanizm pociągania twórców danych, danych użytkowników i danych interesariuszy do odpowiedzialności za kwestie społeczne i etyczne. Techniki interoperacyjności i model otwartego dostępu przyczyniają się do zwiększenia przejrzystości danych i danych podlegających rozliczeniu. Decydenci, praktycy i badacze muszą stawić czoła wyzwaniom etycznym w technologiach AI. Zapewnienie wiarygodności, prywatności danych, stronniczości lub utraty, uczciwości danych, przejrzystości danych i rozliczalności, zapewnia odpowiedzialną AI .

Rozszerzanie frameworków generatywnych

Trudności w rozwijaniu modeli generatywnych

Istnieje duży problem ze zwiększaniem rozmiaru i jakości modeli generatywnych. Jednym z największych problemów jest koszt i czas potrzebny na trenowanie tych modeli, ponieważ wymaga to dużej mocy obliczeniowej. Ponadto istnieją inne wyzwania, które należy rozwiązać, aby zapewnić efektywne trenowanie modeli, co pozwoli im rosnąć i stawać się bardziej złożonymi, w zależności od potrzeb . W rzeczywistości modele generatywne powinny obsługiwać duże zbiory danych i złożone cele. W rzeczywistości trenowanie ogromnych modeli generatywnych może być trudne, gdy jest wykonywane jednocześnie na różnych komputerach lub urządzeniach. Jednak przetwarzanie rozproszone wiąże się z pewnymi trudnościami, takimi jak zapewnienie płynnej współpracy wszystkich elementów modelu przy jednoczesnym prawidłowym udostępnianiu informacji. Mimo to, nawet po tym wszystkim, istnieją problemy związane z kontrolowaniem i obsługą danych, a także z samym oprogramowaniem. Powinny istnieć systemy śledzenia wielu wersji w odniesieniu do organizacji i konserwacji danych.

Metody uczenia rozległych modeli

Aby rozwiązać te problemy i umożliwić trenowanie bardzo dużych modeli generatywnych, istnieje wiele różnych metod testowania. Jedną z nich jest paralelizm modeli, w którym różne sekcje modelu są dzielone na różne komputery lub węzły. W ten sposób możliwe jest trenowanie modeli większych niż te, które może pomieścić pamięć pojedynczego urządzenia. Inną metodą jest paralelizm danych, który polega na dzieleniu danych treningowych pomiędzy różne komputery lub węzły, a następnie każdy z nich oblicza niezależnie własne gradienty, a następnie łączy je w celu aktualizacji parametrów modelu. Pozwala to na wykorzystanie wielu komputerów i danych do szybszego uruchomienia modelu.

Poza tym istnieją inne podejścia, takie jak algorytmy optymalizacji rozproszonej, punkt kontrolny gradientu i trening o mieszanej precyzji, które mogą ułatwić trenowanie naprawdę dużych modeli generatywnych. Pomagają one w rozwiązywaniu problemów z pamięcią i zwiększają wydajność procesów treningowych .

Możliwe postępy w skalowalności w przyszłości

Przyszłość może przynieść jeszcze większe postępy w skalowalności modeli GenAI. To jeden z obszarów, w którym możemy skupić się na opracowaniu nowych algorytmów szkoleniowych, które będą bardziej wydajne pod względem optymalizacji, takich jak wykorzystanie adaptacyjnych współczynników uczenia, metauczenia i metod optymalizacji drugiego rzędu. Takie nowatorskie algorytmy mogą umożliwić naszym modelom szybsze trenowanie, mniejsze zużycie pamięci i mniejszą wrażliwość na różne wybory hiperparametrów. Sprzęt to kolejny obszar, który może ulec poprawie. Wraz z wynalezieniem nowszych i lepszych komputerów i procesorów, mogą one umożliwić znacznie szybsze i efektywniejsze trenowanie i uruchamianie modeli generatywnych. Przykładami są obliczenia kwantowe, inżynieria neuromorficzna lub dedykowane akceleratory do celów głębokiego uczenia. Ponadto istnieje możliwość ułatwienia współpracy ludzi nad trenowaniem modeli generatywnych na różnych maszynach i w różnych środowiskach. Obejmuje to integrację uczenia federacyjnego, zdecentralizowanego trenowania i przetwarzania brzegowego z procesem tworzenia modeli GenAI. Podejścia te mogą umożliwić szkolenie modeli na dużą skalę przy jednoczesnym zachowaniu prywatności i bezpieczeństwa danych, a wielu badaczy bada, w jaki sposób można zwiększyć skalowalność tych systemów na potrzeby badań.

Luka semantyczna

Luka semantyczna jest jednym z najpoważniejszych problemów w GenAI. Oznacza ona różnicę między ludzką wiedzą o wielowarstwowych strukturach semantycznych a unikalnymi zdolnościami na poziomie ludzkim w odniesieniu do współczesnych, ograniczonych modeli generatywnych. Istota luki semantycznej polega na tym, że tradycyjne modele generatywne nie zawsze są w stanie uchwycić semantykę języka ludzkiego, a nawet kontekst, w jakim człowiek coś postrzega. Wyeliminowanie luki semantycznej jest możliwe tylko dzięki interdyscyplinarnej pracy informatyków, językoznawców, kognitywistów, psychologów i ekspertów z różnych dziedzin. Kompilacja wiedzy z różnych dyscyplin pomoże badaczom w generowaniu bardziej solidnych rozwiązań semantycznych. Ogólnie rzecz biorąc, głębsze zrozumienie tego słowa może przyczynić się do rozwoju bardziej inspirujących modeli GenAI, które są bardziej kompleksowe z perspektywy percepcji i rozumienia. Szczególnie ważne jest, aby społeczność zajmująca się sztuczną inteligencją zdała sobie sprawę, że symptomem luki semantycznej jest podstawowy problem związany z brakiem algorytmów i modeli ugruntowanych semantycznie. Obecne kadencje mogą być uczone statystycznego rozpoznawania wzorców i elementów powierzchownych, ale nie są w stanie odróżnić semantyki od znaczenia tych elementów. W związku z tym nie są w stanie tworzyć zdań, które są kontekstowo poprawne, nawet jeśli nauczono ich gramatycznie poprawnych sekwencji symboli . Luka semantyczna różni się w zależności od dziedziny i modalności, dostosowując podejścia i techniki. Na przykład luka semantyczna w generowaniu języka naturalnego obejmuje rozumienie struktur językowych, składnię danych, pragmatykę i semantykę poprzez budowanie połączenia między semantyką wizualną danych, relacjami obiektowymi i kontekstem sceny danych. Podejścia interdyscyplinarne są ważne dla budowania luki semantycznej w celu budowania metodologii i wiedzy w różnych dziedzinach w celu rozwoju modeli GenAI. Dodanie terminów lingwistycznych i kognitywnych do rozwoju algorytmów i architektury GenAI pozwala uchwycić znaczenie i strukturę danych. Naukowcy i interdyscyplinarna współpraca wykorzystują różne techniki i metodologie z różnych dziedzin, takich jak przetwarzanie języka naturalnego, neuronauka poznawcza i widzenie komputerowe, do generowania możliwości i zrozumienia modeli GenAI.

Niektóre z technik, takie jak architektury rozszerzonej pamięci, podejścia neuronalno-symboliczne i mechanizmy uwagi, czerpią z koncepcji nauk kognitywnych i ich zasad poprawy interpretowalności danych, kontekstowości danych i generowanych wyników w sposób spójny [→54]. Łączą one wszystkie metody i modele, a także z różnych dziedzin, takich jak tekst, obrazy i dźwięk. Konieczne jest zbudowanie lepszego modelu, który zintegruje się z lepszą percepcją i ludzkim zrozumieniem [→55]. Nauki kognitywne zyskują lepszy wgląd w percepcję człowieka, myślenie poznawcze i więcej w przetwarzanie języka, w celu rozwoju świetnej GenAI i połączenia się z luką semantyczną. Badając zatem, jak ludzki mózg postrzega, rozumie znaczenie i generuje ogromną ilość informacji, naukowcy mogą poszerzyć swoją wiedzę na temat procesów poznawczych, aby zrozumieć znaczenie semantycznie i produktywnie. Jedną z kluczowych i ważnych cech jest kognitywistyka i informacja kontekstowa. Ludzie polegają na wskazówkach kontekstowych, wiedzy kontekstowej i świadomości sytuacyjnej, aby generować i interpretować wiedzę. Rozwijanie tych możliwości poprawia wydajność modelu . Hierarchiczne przetwarzanie danych i przetwarzanie pamięci w rozumieniu semantycznym i generowaniu danych opiera się na zasadach. Aby zwiększyć kontekstowość danych, spójność danych i trafność danych generowanych wyników, stosuje się techniki takie jak mechanizmy uwagi, architektury rozszerzonej pamięci i modelowanie hierarchiczne z modelowania poznawczego . Akwizycja języka i rozwój człowieka w celu projektowania i rozwoju modeli GenAI naśladujących funkcje ludzkiego mózgu. Budowanie nowego języka i wiedzy semantycznej, dla naturalnych, ludzkich zdolności generowania i rozumienia semantycznego . Dzięki zdobywaniu wiedzy z zakresu nauk kognitywnych i integracji wiedzy z różnych dziedzin, powstaje solidniejszy model percepcji człowieka i intencji semantyki.

Innowacyjne Architektury

Aby ulepszyć modele GenAI pod kątem adaptowalności i zdolności przewidywania, badacze poszukują najlepszych, nowatorskich architektur z różnych dziedzin i ich koncepcji, takich jak modelowanie probabilistyczne, teoria grafów i neuronauka. Architektury te służą poszerzeniu perspektywy użytkownika w zakresie efektywności i jej znaczenia.

1. Architektury hierarchiczne: Modele te wykorzystują struktury hierarchiczne i opisują złożone zależności danych z różnych poziomów abstrakcji danych. Zapewnia to elastyczne i zrozumiałe procesy generowania danych. Architektury modułowe są również pomocne w integracji wiedzy specyficznej dla danej domeny danych i priorytetów modelu generatywnego.

2. Modelowanie probabilistyczne: Techniki probabilistycznych, hierarchicznych modeli bayesowskich mogą pomóc w wzbogaceniu danych i ich reprezentacji. Są one wykorzystywane do kontekstu i spójnego generowania danych.

3. Grafowe sieci neuronowe i sieci kapsułowe: Architektury budowane są w oparciu o teorię prawdopodobieństwa i służą do budowania relacji między encjami. Posiadają pełną ekspresję i skuteczność modeli GenAI i wyzwań z nimi związanych.

Rozwój metod treningowych

Aby poprawić skalowalność, stabilność i wydajność danych, istotne jest udoskonalenie technik treningowych, aby uczynić modele GenAI bardziej konwencjonalnymi metodami treningowymi, takimi jak gradient spadkowy. Innym algorytmem, stochastycznym gradientem, jest kluczowy dla rozwoju modeli generatywnych. Za każdym razem, gdy model staje się duży, dochodzi do jego załamania i powstaje problem nadmiernego dopasowania. Niektóre z kluczowych czynników to:

1. Adaptacyjne algorytmy optymalizacji: Algorytmy te działają dynamicznie, dostosowując tempo uczenia, regularyzację parametrów i strategie optymalizacji w oparciu o model danych i jego właściwości. Prowadzi to do zwiększenia szybkości konwergencji, stabilności danych i odporności danych na hiperparametry. Niektóre z typowych przykładów to Adam, RMSprop i AdaGrad.

2. Regularyzacja, augmentacja i uczenie się programu nauczania: Metody te mogą pomóc w rozwiązaniu problemów takich jak załamanie modów i różnorodność próbek. Na przykład techniki regularyzacji, takie jak porzucanie programu nauczania (dropout) czy augmentacja danych, zwiększają ich solidność, podczas gdy uczenie się oparte na programie nauczania zwiększa złożoność danych wejściowych.

3. Uczenie się przez wzmacnianie, uczenie się pod nadzorem i trening adwersaryjny: Te metody i techniki są wprowadzane w celu uczenia się na podstawie informacji zwrotnej lub z aktywnego środowiska, w celu tworzenia modeli generatywnych oraz rozwijania bardziej efektywnych i spójnych umiejętności generowania.

Wykorzystanie obliczeń rozproszonych

Wielkoskalowe uczenie oparte na generatywnym modelu i wdrażanie danych w rozproszonych domenach wykorzystuje obliczenia rozproszone. Jest to niezbędne, ponieważ uczenie modeli na dużą skalę wymaga ogromnych ilości pamięci danych i mocy obliczeniowej procesora, które przekraczają możliwości tradycyjnych metod uczenia. Niektóre ze strategii rozwoju obejmują:

1. Rozproszone struktury szkoleniowe: Należą do nich takie struktury, jak rozproszony przepływ tensorowy, rozproszony PyTorch i Horovod, zapewniające optymalizację rozproszoną dla paralelizmu danych i modelu. W celu integracji rozproszonych środowisk obliczeniowych, poprzez wykonywanie obliczeń rozproszonych na wielu węzłach i urządzeniach, te struktury zapewniają wydajność szkolenia i danych dla rozległego modelu dużych zbiorów danych.

2. Infrastruktura przetwarzania w chmurze: Postęp w infrastrukturze chmurowej obejmuje systemy GPU, klastry danych, TPU i rozwiązania bezserwerowe dla platform obliczeniowych, zapewniając skalowalność danych i przystępność cenową metod wdrażania i rozwoju modeli GenAI na dużą skalę. Naukowcy i praktycy mogą efektywnie trenować dane i wdrażać wielkoskalowe modele generatywne bez konieczności inwestowania w infrastrukturę i korzystania z usług chmurowych, co zapewnia im dostęp do danych na żądanie, moc obliczeniową, przechowywanie danych i możliwości przetwarzania danych.

3. Edge computing: Rozwój rozproszonych struktur obliczeniowych i implementacja modeli w modelach GenAI z wykorzystaniem ustawień edge computing, gdzie dane są przetwarzane i tworzone ze źródła. Zapewnia to niskie opóźnienia reakcji, wnioskowanie w czasie rzeczywistym i zachowanie prywatności podczas wykonywania modeli na urządzeniach brzegowych, takich jak smartfony, urządzenia IoT i serwery brzegowe danych. Pomaga to w generowaniu i wdrażaniu aplikacji AI w zastosowaniach praktycznych.

Obszary badawcze w generatywnej sztucznej inteligencji (GenAI)

Badanie obszarów badawczych w GenAI pomaga w rozwoju i tworzeniu zaawansowanych algorytmów. Niektóre z obszarów badawczych obejmują:

1. Adaptacyjne modele generatywne: Koncentracja na różnych modelach i ich efektywnym dostosowywaniu do nowych zadań i sytuacji. Obejmuje to wykorzystanie metod metauczenia się i generatywne wykorzystanie modeli.

2. Modele generatywne oparte na uczeniu się z niewielką liczbą prób: Badanie modeli pod kątem efektywnego generowania i modelowania danych z wykorzystaniem niewielkiej metawiedzy. Pomaga to w radzeniu sobie z niedoborem danych i generowaniem danych.

3. Interpretowalne i kontrolowane modele generatywne: Przyjazne dla użytkownika tworzenie przestrzeni ukrytej pozwala na wydajne generowanie wyników. Jest to przydatne do interaktywnego tworzenia treści i personalizacji generowania treści.

4. Rozszerzanie i synteza danych: Różnorodne badanie rozszerzania i syntezy danych, w kontekście niedoboru danych, w celu generowania realistycznych i różnorodnych próbek danych oraz w celu trenowania modelu z wykorzystaniem różnych zestawów danych.

Perspektywy branżowe i studia przypadków

Branża GenAI charakteryzuje się innowacyjnością i dynamicznym rozwojem, a jej wykorzystanie jest wykorzystywane w różnych dziedzinach, takich jak rozrywka, rozrywka i gry. Technologie tworzenia i ulepszania danych będą usprawniać i współdziałać z danymi, takimi jak media, podejmowanie decyzji i zarządzanie danymi. Niektóre z zastosowań obejmują gry wideo, analitykę predykcyjną danych w medycynie oraz generowanie treści w handlu elektronicznym. Istnieją ograniczenia i wyzwania związane z wykorzystaniem i personalizacją danych. Zapewnienie jakości i różnorodności danych podczas ich trenowania oraz wyzwań i możliwości interpretacji w przewidywaniu wyników. W przyszłości wiele z GenAI poprawi adaptowalność i interaktywność. Ulepszenie danych do tworzenia środowiska i informacji zwrotnej. Konieczna jest współpraca między badaczami danych a specjalistami z branży, aby etycznie i odpowiedzialnie podchodzić do tych zasad i praktyk w zakresie AI .

Zastosowania w świecie rzeczywistym

* Jednym z godnych uwagi zastosowań GenAI jest tworzenie gier wideo, gdzie obrazy generowane przez AI mogą być wykorzystywane do tworzenia realistycznych i immersyjnych środowisk gry. Może to nie tylko poprawić estetykę gry, ale także skrócić czas i koszty jej tworzenia. Postacie i animacje generowane przez AI mogą sprawić, że gry będą bardziej angażujące i interaktywne.

* Kolejnym obszarem, w którym GenAI wywiera znaczący wpływ, jest obrazowanie medyczne. Analizując obrazy medyczne, takie jak zdjęcia rentgenowskie i tomografia komputerowa, modele GenAI mogą przewidywać przebieg chorób, wspomagać diagnostykę, a nawet opracowywać nowe metody leczenia. Ma to potencjał zrewolucjonizowania opieki zdrowotnej poprzez poprawę wyników leczenia pacjentów i redukcję kosztów.

* Jednym z sukcesów w dziedzinie GenAI jest opracowanie modeli tłumaczenia języków, takich jak GPT-3. Modele te osiągnęły imponujące wyniki w takich zadaniach, jak tłumaczenie, streszczanie tekstu i odpowiadanie na pytania, co doprowadziło do ich powszechnego zastosowania w różnych branżach. Nadal jednak istnieją wyzwania do pokonania, takie jak zapewnienie różnorodności i jakości danych szkoleniowych, rozwiązanie problemów etycznych oraz uczynienie modeli bardziej interpretowalnymi i wyjaśnialnymi.

Historie sukcesu i wyzwania

Jednym z takich obszarów jest integracja GenAI z innymi nowymi technologiami, takimi jak rzeczywistość rozszerzona, rzeczywistość wirtualna i robotyka. Może to doprowadzić do stworzenia bardziej immersyjnych i interaktywnych doświadczeń w różnych branżach. Kolejnym ważnym obszarem zainteresowania jest rozwiązywanie problemów etycznych i rozwijanie odpowiedzialnych praktyk w zakresie sztucznej inteligencji (AI). Obejmuje to zapewnienie uczciwości, ograniczanie

stronniczości i promowanie przejrzystości w systemach AI. Wspierając współpracę między badaczami, specjalistami z branży i decydentami, możliwe jest opracowanie wytycznych i przepisów promujących odpowiedzialny rozwój i użytkowanie AI.

Spostrzeżenia dotyczące przyszłych kierunków rozwoju

W miarę rozwoju GenAI, pojawia się kilka obiecujących kierunków przyszłych badań i rozwoju. Jednym z takich obszarów jest integracja GenAI z innymi nowymi technologiami, takimi jak rzeczywistość rozszerzona, rzeczywistość wirtualna i robotyka. Może to doprowadzić do stworzenia bardziej immersyjnych i interaktywnych doświadczeń w różnych branżach. Kolejnym ważnym obszarem zainteresowania jest rozwiązywanie problemów etycznych i rozwijanie odpowiedzialnych praktyk w zakresie AI. Obejmuje to zapewnienie uczciwości, ograniczanie stronniczości i promowanie przejrzystości w systemach AI. Wspierając współpracę między badaczami, specjalistami z branży i decydentami, możliwe jest opracowanie wytycznych i przepisów promujących odpowiedzialny rozwój i użytkowanie AI.

1. Modele generatywne specyficzne dla danej dziedziny: Integracja modeli generatywnych z wiedzą i ograniczeniami specyficznymi dla danej dziedziny w celu poprawy wydajności i generalizacji modeli w wyspecjalizowanych dziedzinach.

2. Współpraca człowiek-maszyna: Badanie modeli generatywnych pod kątem współtworzenia i współpracy twórczej, potencjalnie prowadzących do nowych form współpracy człowiek-maszyna w dziedzinach takich jak muzyka, design i sztuka.

3. Potrzebne są standaryzowane procedury ewaluacji i zestawy danych, aby zapewnić powtarzalność i uczciwe porównania między różnymi modelami i zadaniami.

4. Należy dokładnie rozważyć etyczne i społeczne implikacje wykorzystania modeli GenAI w praktycznych zastosowaniach, w tym kwestie zgody, prywatności i stronniczości.

5. Wymagania obliczeniowe i zasobowe związane z trenowaniem i wdrażaniem modeli generatywnych na dużą skalę mogą stanowić wyzwanie dla skalowalności i zrównoważonego rozwoju, które należy rozwiązać poprzez postęp w sprzęcie i technikach trenowania.

Przyszłe wyzwania i możliwości

W miarę rozwoju GenAI stoi przed szeregiem wyzwań i możliwości, które ukształtują jego przyszłość. Aby stale się rozwijać i być innowacyjnym, musimy zrozumieć te wyzwania i znaleźć sposoby na ich pokonanie, jednocześnie wykorzystując związane z nimi możliwości.

Wyzwania

1. Jakość i różnorodność próbek: Innowacyjna sztuczna inteligencja jest innowacyjna, a GenAI zapewnia wysoką jakość i różnorodność próbek. Tworzenie bardziej realistycznych, kontekstualizowanych i zróżnicowanych wyników w różnych materiałach wejściowych, takich jak dźwięk, tekst i obrazy.

2. Implikacje etyczne: Głównymi parametrami GenAI są kwestie etyczne, takie jak naruszenia prywatności danych, stronniczość i wzmacnianie treści oraz generowanie treści o charakterze nadużyciowym. Musimy opracować etyczne ramy wdrażania procesów oraz transparentności i rozliczalności mechanizmów danych.

3. Skalowalność: Obsługa dużych zbiorów danych stanowi ogromne wyzwanie, zwłaszcza w kontekście skalowania danych. Aby trenować dane, należy opracować najlepsze architektury i rozwiązania

obliczeniowe dla obliczeń rozproszonych, a także aplikacje GenAI, aby móc wykorzystywać GenAI w rzeczywistych aplikacjach na dużą skalę.

4. Interpretowalność i kontrola: Aby budować zaufanie i utrzymywać dane, należy rozwijać bardziej interoperacyjne modele i interfejsy w sposób przyjazny dla użytkownika oraz generować dane wyjściowe w sposób generowany, co pozwoli na bardziej niezawodne tworzenie danych.

5. Generalizacja i odporność: Ograniczenia w korzystaniu z modelu GenAI, trudności z adaptacją oraz tworzenie ataków adwersyjnych. Musimy skupić się na generalizacji i odporności dla różnych scenariuszy i dziedzin.

Możliwości

Powinniśmy rozwijać bardziej ekspresyjne i wszechstronne systemy GenAI do tworzenia treści, interakcji narracyjnych i interakcji człowiek-komputer.

1. Systemy interaktywne i adaptacyjne: Rozwój bardziej interaktywnych i adaptacyjnych systemów GenAI, zapewniających spersonalizowane doświadczenia i współpracę w czasie rzeczywistym. Jest to pomocne w przypadku technologii i dziedzin takich jak technologie wspomagające.

2. Aplikacje specyficzne dla danej dziedziny: W przypadku innowacji i technik GenAI w określonych dziedzinach i aplikacjach. Uwzględniając unikalne potrzeby i wymagania różnych dziedzin, można zrewolucjonizować różne sektory, takie jak urbanistyka, opieka zdrowotna i finanse.

3. Etyka w projektowaniu: Kwestie etyczne są jednym z głównych czynników decydujących o tym, czy technologia jest wykorzystywana etycznie. Rozwój społeczeństwa systemowego w sposób korzystny dla beneficjenta.

4. Współpraca i dzielenie się wiedzą: GenAI tworzy wiedzę poprzez dzielenie się wiedzą i wspólną pracę. Dzięki współpracy, zaangażowaniu społeczności i otwartemu forum możemy zintensyfikować działania.

Aspekty etyczne w generatywnej sztucznej inteligencji (GenAI)

GenAI ma potencjalne zastosowania w różnych obszarach. Niektóre z problemów etycznych, które należy omówić, dotyczą GenAI [→68]. W tej sekcji omówimy niektóre wyzwania, takie jak prywatność danych i stronniczość algorytmów, a także kluczową rolę sztucznej inteligencji i jej wpływ na społeczeństwo.

Prywatność i bezpieczeństwo danych

Głównym czynnikiem, który należy wziąć pod uwagę, jest konieczność sprawdzenia, czy dane są chronione. Dostęp do systemu GenAI i trenowanie go z dużą ilością danych, w tym danych wrażliwych, wiąże się z ryzykiem naruszenia prywatności osób i koniecznością pozyskania danych. Naukowcy muszą przede wszystkim skupić się na szyfrowaniu danych oraz zapewnieniu ich bezpieczeństwa i prywatności.

Błąd algorytmiczny

Głównym problemem w sztucznej inteligencji (AI) jest błąd w trenowaniu danych, a także błąd w samej analizie. Jest on wykorzystywany w różnych dziedzinach, takich jak opieka zdrowotna, gry, w celu zapewnienia stabilności systemów AI i ich stronniczości oraz w celu rozwijania doświadczeń i kontekstów.

Wpływ społeczny

GenAI wywarło wpływ na społeczeństwo. Może usprawnić pracę, np. określić, nad czym pracować, jak się uczyć, a także kwestie artystyczne. Manipulacja danymi i związane z nią problemy, takie jak identyfikacja kradzieży i manipulacja danymi, mają na celu ulepszenie modelu, współpracę z każdym, a także wzajemny rozwój i współpracę.

Strategie rozwiązywania problemów etycznych

Obawy etyczne to:

1. Zasady etycznego projektowania: Podczas projektowania i budowania modelu, niektóre z zasad modelu, które są brane pod uwagę, to: przejrzystość danych, uczciwość, rozliczalność danych i ich inkluzywność.

2. Komisje ds. przeglądu etycznego: Musimy sprawdzić, czy dane są gromadzone i gromadzone w odpowiedni sposób.

3. Szkolenia etyczne: Ludzie wiedzą, jak się szkolić i jak pracować we właściwy sposób, wraz z GenAI, badaczami i decydentami, aby prawidłowo szkolić dane.

4. Zaangażowanie społeczne: Działamy i angażujemy się w działania różnych grup społecznych, takich jak społeczności i organizacje, aby chronić prawa ludzi oraz systemy GenAI. Aby wzmocnić priorytety i wartości społeczeństwa.

5. Nadzór regulacyjny: Tworzymy zasady i regulacje społeczne, aby wdrażać je w społeczeństwie oraz chronić uczciwość i prywatność danych. Postępując zgodnie z tymi krokami, możemy rozwijać GenAI w dobrej formie, nie wyrządzając żadnej szkody społeczeństwu.

Projektowanie zorientowane na człowieka w generatywnej sztucznej inteligencji (GenAI)

GenAI rewolucjonizuje sposób, w jaki pracujemy w społeczeństwie, dając beneficjentowi miejsce, gdzie pojawia się innowacja, a zorientowanie na człowieka odgrywa kluczową rolę.

Zrozumienie potrzeb i preferencji użytkowników

Tworząc systemy GenAI, musimy zdecydować, co rozwijać i jakie korzyści przyniesie to społeczeństwu. Musimy wchodzić w interakcje z różnymi ludźmi, aby uzyskać wgląd w sytuację. W ten sposób poznajemy preferencje i specyficzne potrzeby, tworząc system przyjazny dla użytkownika.

Wspieranie kreatywności i kontroli użytkowników

Projektowanie zorientowane na człowieka to rozwijanie określonego kształtu i doświadczeń za pomocą GenAI. Możemy tworzyć interfejsy, a użytkownicy mają wiele możliwości personalizacji. Możemy tworzyć pętle sprzężenia zwrotnego i mechanizmy adaptacji, aby system uczył się i dostosowywał do preferencji danych. W ten sposób zainwestowaliśmy w ten proces.

Zapewnienie dostępności i inkluzywności

Inkluzywność jest kluczowym elementem projektowania zorientowanego na człowieka. Musimy myśleć, że systemy AI są dostępne i użyteczne dla każdego i dla wszystkich grup odbiorców. Musimy być scentralizowani podczas tworzenia systemu, uwzględniając język, kulturę i dostęp fizyczny, tworząc interfejsy użytkownika i interakcje. Dzięki temu możemy skutecznie zbudować system.

Promowanie etycznego i odpowiedzialnego użytkowania

Musimy zastanowić się nad ryzykiem i korzyściami płynącymi z korzystania z GenAI. Musimy stworzyć zabezpieczenia w naszych systemach, aby zapewnić prywatność i bezpieczeństwo naszych danych oraz

zapobiec szkodliwym skutkom. Zapewnienie przejrzystości i kontroli nad danymi to główne czynniki, które należy wziąć pod uwagę przy wdrażaniu zasad etycznych.

Projektowanie iteracyjne i ciągłe doskonalenie

Projektowanie zorientowane na człowieka opiera się na ciągłym uczeniu się i doskonaleniu. Musimy stale rozmawiać z użytkownikami, zbierać opinie i wprowadzać zmiany w oparciu o zdobytą wiedzę. Pomaga nam to nadążać za potrzebami użytkowników i dostosowywać się do nowych technologii. Wdrażając kulturę innowacji i projektowania zorientowanego na użytkownika, możemy zapewnić, że systemy GenAI pozostaną istotne i użyteczne dla wszystkich w dłuższej perspektywie. Krótko mówiąc, projektowanie zorientowane na człowieka jest niezwykle ważne dla tworzenia systemów GenAI, które pomagają ludziom. Stawiając użytkowników na pierwszym miejscu i utrzymując ich potrzeby i preferencje w centrum procesu projektowania, możemy tworzyć technologię, która jest inspirująca, inkluzywna i etyczna. A o to właśnie chodzi, prawda?

Wnioski

W rozdziale omówiono otwarte problemy i przyszłe kierunki rozwoju GenAI, dotyczące obecnego stanu rzeczy, rozwoju nowych rozwiązań i pełnego potencjału danych. Niektóre z ważnych czynników to sposób wykorzystania głębokiego uczenia się i jego rozwój w nadchodzącej dziedzinie, a także sposób omówienia etyki i wyzwań, skalowanie modeli danych oraz zapewnienie generowania danych w wiarygodnej próbie i wysokiej jakości. W tym rozdziale omówiono również sposób wykorzystania różnych obszarów w tej dziedzinie, znajdowanie nowych luk w architekturach i strategiach oraz zrozumienie luk semantycznych. Wykorzystanie GenAI przekłada się na lepszą przyszłość w dziedzinie nauki, biznesu i społeczeństwa. Jest ono wykorzystywane do personalizacji danych, adaptacji danych i tworzenia aplikacji, transformując różne sektory, takie jak medycyna, tworzenie danych i sektor finansowy. Musimy uwzględnić wpływ społeczny, problemy techniczne i różne dziedziny. Ponadto, współpraca z badaczami i praktykami z różnych środowisk, takimi jak politycy i interesariusze, może ulepszyć GenAI z korzyścią dla wszystkich i wesprzeć wpływ społeczny. Aby stawić czoła szansom i wyzwaniom, przed którymi stoją badacze i praktycy, konieczne jest konsekwentne finansowanie badań interdyscyplinarnych, ustanawianie standardów etycznych i najlepszych praktyk w zakresie otwartości danych, odpowiedzialności za dane i ich różnorodności w rozwoju i wykorzystaniu innowacyjnych rozwiązań GenAI. Ponieważ dziedzina GenAI zmienia się tak szybko, istnieje potrzeba ciągłego uczenia się, adaptacji i refleksji. Aby tworzyć nowe pomysły, musimy tworzyć dane w sposób etyczny i uwzględniać inkluzywne uczenie się.