**Generatywna sztuczna inteligencja i studia LLM: Studium przypadku w finansach**

**Streszczenie**

Generatywna sztuczna inteligencja (GenAI) i duże modele językowe (LLM) wywołują rewolucję w różnych branżach, a sektor finansowy jest jednym z obszarów silnie dotkniętych. Tu analizuje się zróżnicowany wpływ GenAI i LLM na sektor finansowy, ze szczególnym uwzględnieniem tego, w jaki sposób technologie te umożliwiają tworzenie nowych treści danych z istniejących zestawów danych w celu usprawnienia procesu decyzyjnego, oceny ryzyka, spersonalizowanych usług bankowych i zaangażowania klientów. Instytucja finansowa, taka jak bank, może wykorzystać te rozwijające się technologie do lepszej analizy predykcyjnej i świadczenia usług doradztwa finansowego. W niniejszym rozdziale analizuje się niedawną ewolucję GenAI i LLM w sektorze finansowym i jej implikacje. Oprócz ram wykorzystania tych technologii w celu uzyskania przewagi konkurencyjnej, omówiono również ich zastosowania, perspektywy i wyzwania. Słowa kluczowe: sztuczna inteligencja, generatywna sztuczna inteligencja, duże modele językowe, finanse, transformer

**Wprowadzenie**

Systemy komputerowe oparte na sztucznej inteligencji (AI) potrafią się uczyć i dokonywać wyborów, podobnie jak ludzie. Wykorzystując metody uczenia maszynowego (ML), komputery uczą się z określonego zestawu danych, analizując je bez konieczności stosowania jawnych procedur krok po kroku. Metody te wyszukują wzorce w danym zbiorze danych. Niedawno wprowadzone modele generatywnej AI, znane również jako GenAI, oparte na technikach ML, mogą generować nowe teksty, obrazy, muzykę, a nawet filmy z komunikatów tekstowych. Generatywne, wstępnie wytrenowane modele dużego języka (LLM) oparte na transformatorach (GPT) mają zdolność rozumienia i generowania języka ludzkiego. Od ogólnych idei po konkretne zastosowania, najnowsze modele GenAI wykazały, że mogą naśladować i wzmacniać ludzką inteligencję, zarówno pod względem długości, jak i szerokości. W przeszłości nastąpiły drastyczne zmiany w sposobie, w jaki instytucje finansowe przetwarzają dane, uzyskują wgląd i podejmują decyzje. Przełomowy rozwój GenAI i LLM jest głównym czynnikiem dramatycznych zmian w sektorze finansowym. W tym rozdziale omawiamy, jak GenAI i LLM zrewolucjonizowały globalny sektor finansowy. Specyficzne połączenie tych dwóch technologii zmienia oblicze sektora finansowego dzięki unikalnej zdolności do analizy danych i podejmowania trafnych decyzji strategicznych dla organizacji. GenAI wzbudziło duże zainteresowanie w wielu dziedzinach, w tym w finansach, od czasu wprowadzenia sztucznej inteligencji. Istnieje wiele obszarów sektora finansowego, w których zastosowanie GenAI pomogłoby w efektywniejszej analizie danych finansowych, uzyskaniu wglądu w rynek i uproszczeniu złożonej dynamiki zachowań rynkowych. Modele GenAI są w stanie generować treści, które wyglądają podobnie do tych tworzonych przez ludzi, pokazując ich kreatywne i poznawcze zdolności. Godną uwagi zaletą LLM jest jego zdolność do czytania i pisania zdań tak jak ludzie, z zadziwiającą dokładnością. Z drugiej strony, włączenie GenAI do LLM w subdomenie finansów w obliczu tych złożonych krajobrazów, w których działają wszystkie branże, będzie kluczowe dla profesjonalistów, którzy mają do czynienia z ogromną ilością informacji i komplikacjami w podejmowaniu decyzji, takich jak zarządzający aktywami z sektora usług finansowych. Włączenie GenAI, wraz z LLM, do sektora finansowego będzie kluczowe dla zarządzających aktywami w branży usług finansowych, którzy przetwarzają duże ilości informacji i realizują złożone procesy decyzyjne, na przykład dla zarządzających aktywami. W tym rozdziale analizujemy, co wspiera GenAI, jak działają LLM i jakie są ich możliwe zastosowania, wykorzystując szczegółowe studium przypadku z perspektywy finansowej. Dlatego też dogłębnie analizujemy GenAI, złożoność LLM i wykorzystujemy je jako studium przypadku zastosowania w sektorze finansowym. GenAI, szeroka kategoria obejmująca modele tworzące nowe treści, takie jak tekst, dźwięk lub obrazy, wykorzystuje duże modele językowe jako kluczowe narzędzie. LLM, trenowane na ogromnych ilościach danych tekstowych, doskonale

rozumieją wzorce językowe i generują tekst o jakości ludzkiej, oparty na podpowiedziach lub kontynuacji istniejących sekwencji. Rysunek  przedstawia hierarchiczny widok AI, ML, głębokiego uczenia (DL), Gen AI i LLM.

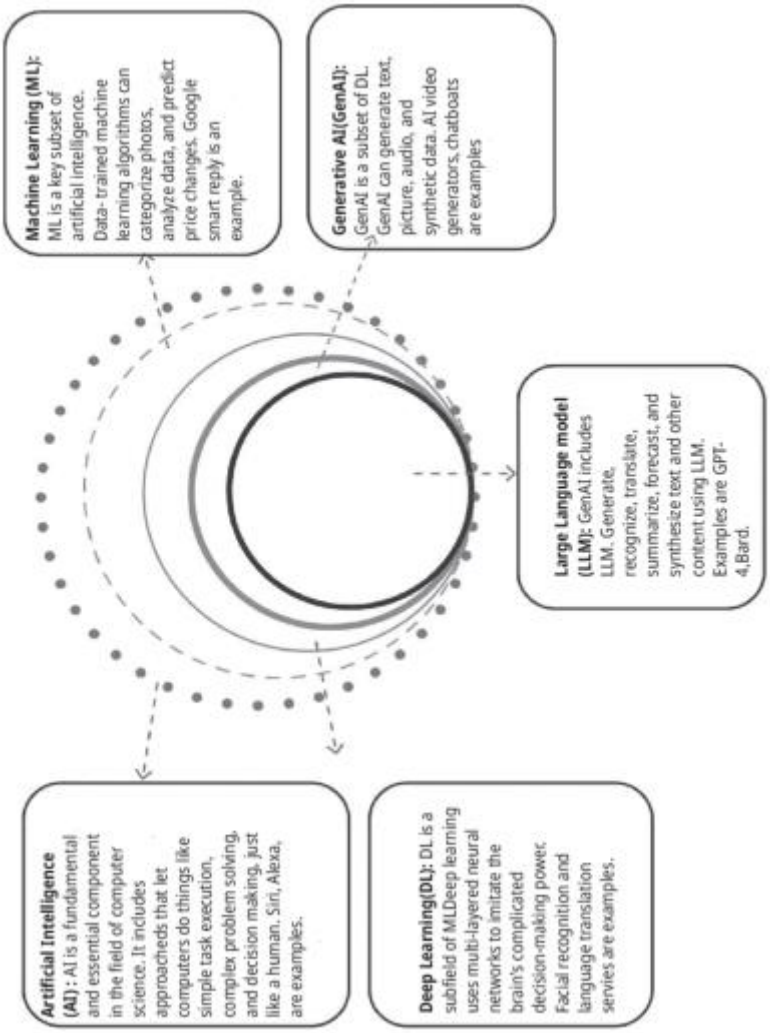


**Zrozumienie generatywnej sztucznej inteligencji (AI) i dużych modeli językowych (LLM)**

Systemy AI to programy komputerowe, które mogą tworzyć prognozy, sugestie lub dokonywać wyborów w oparciu o cele wyznaczone przez ludzi. Trendy digitalizacji obserwowane od dawna, w tym te oparte na sztucznej inteligencji (AI), uległy przyspieszeniu i nasileniu w okresie pandemii. Tradycyjna AI, czyli ML, koncentruje się na zadaniach analitycznych, podczas gdy GenAI została stworzona w celu generowania własnych treści. Ten wynalazek może zrewolucjonizować każdą branżę, zwiększyć ludzką kreatywność i rozszerzyć możliwości maszyn. Rozwój GenAI był ekscytujący, a na przestrzeni lat osiągnięto wiele godnych uwagi kamieni milowych. Podobnie jak wcześniejsze generacje AI, GenAI wykorzystuje złożone modele matematyczne, ogromne zasoby obliczeniowe i ogromny wkład pracy ludzkiej w szkolenia/rozwój/wdrożenie . GenAI to termin używany do opisania technik obliczeniowych zdolnych do generowania nowego tekstu, obrazów lub materiałów audiowizualnych z danych treningowych . GenAI wykorzystuje modele bazowe (duże modele AI), które mogą wykonywać wiele zadań jednocześnie i wykonywać różne zadania, takie jak sumowanie, pytania i odpowiedzi oraz klasyfikacja, między innymi. Modele podstawowe mogą być dostosowane do konkretnych przypadków użycia z minimalną ilością informacji o próbce i niskim poziomem szkolenia. Głównym celem GenAI jest

symulacja interakcji międzyludzkiej. Łączy uczenie nadzorowane (przewidywanie następnego słowa w zdaniu na podstawie poprzednich) i uczenie nienadzorowane (odszyfrowywanie struktury języka bez etykiet) . Główna część GenAI jest trenowana na rozległych zestawach danych, a także na istniejących już materiałach. GenAI to ogólny termin obejmujący wiele metod i modeli, które mogą generować nowe instancje danych, przypominające przykłady szkoleniowe pod względem swoich właściwości. Generatywne sieci przeciwstawne (GAN), modele autoregresyjne lub autokodery wariacyjne to niektóre z technik zaliczanych do tej kategorii. Na przykład w finansach, tam gdzie istnieją, GenAI zapewnia możliwości generowania syntetycznych zestawów danych finansowych, ulepszania istniejących zestawów danych i symulowania warunków rynkowych. GPT-3.5 to przykład nowatorskiej GenAI zbudowanej na LLM. Ta wersja ChatGPT jest darmowa. Od listopada 2022 roku, kiedy OpenAI uruchomiło ChatGPT, chatbota opartego na generatywnej sztucznej inteligencji, obserwuje się gwałtowny wzrost aktywności. Wykorzystanie ataków, testy kryminalistyczne i kreatywne odkrywanie zyskały popularność dzięki systemowi i jego zasadom . Język jest prawdopodobnie najpotężniejszym narzędziem, którego ludzkość używa do wyrażania idei, myśli i uczuć . Bez zaawansowanych algorytmów sztucznej inteligencji maszyny nie są w stanie rozumieć ani mówić językiem ludzkim. Docelowo badania nad sztuczną inteligencją mają na celu stworzenie maszyn, które potrafią czytać jak ludzie, a także pisać i mówić jak oni. Przetwarzanie języka naturalnego (NLP) to gałąź sztucznej inteligencji dedykowana temu celowi. W NLP modele językowe służą do przewidywania lub sugerowania słów i fraz, zdań, w oparciu o kontekstowo prawdopodobne lub prawdopodobne, że mówiący zamierza ich użyć. Ewolucja od statystycznych modeli języka (SLM) rozpoczyna się od przejścia do neuronowych modeli języka (NLM), wstępnie wytrenowanych modeli języka (PLM) i dużych modeli języka (LLM). Modele SLM reprezentują sekwencje słów za pomocą prostych rozkładów prawdopodobieństwa, podczas gdy neuronowe analizują złożone wzorce językowe, wykorzystując swoje sieci obliczeniowe. Modele PLM wykorzystują ogromne korpusy i uczenie maszynowe do gromadzenia ogólnych informacji językowych, podczas gdy modele LLM dodają więcej danych, mocy obliczeniowej i algorytmów, aby tworzyć rozbudowane, ekspresywne i elastyczne języki. Zaawansowane systemy sztucznej inteligencji, znane jako duże modele języka (LLM), potrafią rozumieć ludzi. Studenci, którzy ukończą program LLM, są szkoleni na jednych z największych na świecie zbiorów danych, często mierzonych w petabajtach (1 milion GB). Źródłami danych szkoleniowych są książki, czasopisma, strony internetowe, a także inne teksty dostępne w domenach publicznych. Modele te wykorzystują DL do rozumienia i generowania języka zbliżonego do ludzkiego. Nowoczesne aplikacje, takie jak generowanie treści, tłumaczenie języków, chatboty obsługi klienta, analiza finansowa, badania naukowe i zaawansowane wyszukiwanie w internecie, opierają się na modelach LLM. W sztucznej inteligencji modele językowe to systemy programowe, które pozwalają ludziom rozumieć, tworzyć lub manipulować językiem. Niektóre modele łączą obrazy z tekstami i innymi rodzajami mediów. Transformatory, zapoczątkowane przez Vaswaniego i innych , są prekursorami obecnych modeli uczenia się języka (LLM). Transformator wykorzystuje „mechanizm uwagi" do przypisywania wag słowom w zdaniu, dzięki czemu model jest bardziej zdolny do rozumienia złożonych wzorców i zależności. Model transformatora składa się z kodera i dekodera, przy czym oba posiadają wiele warstw samouwagi i sieci neuronowych z sprzężeniem zwrotnym, które stanowią jego komponenty. Zależności odległościowe w sekwencjach mogą być skutecznie obsługiwane za pomocą tej architektury. W związku z tym metoda ta znacząco poprawia wydajność modelu języka i interpretację tekstu .

**Modele językowe w finansach**

Od ponad dziesięciu lat uczenie maszynowe (ML) i sztuczna inteligencja (AI) wywierają ogromny wpływ na sektor usług finansowych. Niektóre z niezwykłych postępów, jakie osiągnięto dzięki tym technologiom, obejmują ulepszone wyceny i lepsze podstawowe wskaźniki oszustw. Obecnie GenAI zwiastuje nową erę dla sektora bankowego. Dlatego w sektorze usług finansowych GenAI jest coraz

częściej wykorzystywane do zwiększenia efektywności operacyjnej, na przykład w wykrywaniu oszustw, ocenie ryzyka, prognozowaniu inwestycji i obsłudze klienta. GenAI ma przewagę nad obserwacją ludzką, ponieważ umożliwia ocenę złożonych informacji w celu ujawnienia niejasnych wzorców. W rezultacie instytucje finansowe są w stanie podejmować bardziej świadome decyzje, co prowadzi do rozsądnego ograniczania ryzyka. Różnorodność zastosowań tego typu AI oraz rosnące zapotrzebowanie na dokładne i niezawodne rozwiązania finansowe doprowadziły do gwałtownego rozwoju GenAI w sektorze finansowym. Duzi gracze na tym rynku, w tym Amazon Web Services, Microsoft Corporation i IBM Corporation, intensywnie inwestują w badania i rozwój (R&D), aby rozszerzyć swoje możliwości GenAI na nowe rynki. Wykorzystanie danych w modelach LLM może przynieść znaczne oszczędności bankom, a także innym dostawcom usług finansowych, między innymi dzięki lepszej automatyzacji i wzrostowi efektywności. Według szacunków McKinsey, wdrożenie GenAI może prowadzić do wzrostu przychodów w sektorze bankowym nawet o 3–5% rocznie pod względem produktywności. Oznacza to dodatkowe roczne zyski, sięgające od 200 do 340 miliardów dolarów. Architektura modeli języka ekonomicznego (LLM) składa się z frameworka i algorytmów zaprojektowanych specjalnie do przetwarzania danych i informacji ekonomicznych. Rysunek 2 przedstawia te frameworki.

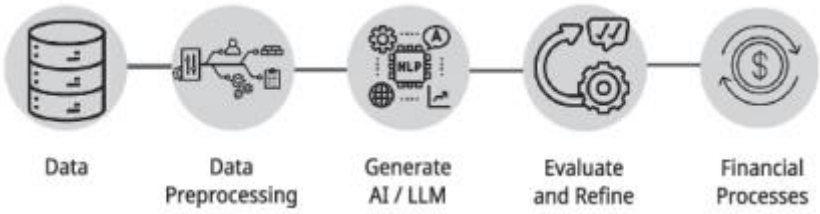


W latach 2017–2024 ewolucja finansowych LLM (FinLLM) przesunęła się od początkowej eksploracji w stronę zaawansowanych narzędzi branżowych, które zostały włączone do systemów finansowych. Właśnie z takim postępem oś czasu na →rysunku 12.3 rozpoczyna się od wynalezienia architektury transformatorowej  w 2017 r., która stanowi podstawę dla wszystkich innych LLM.

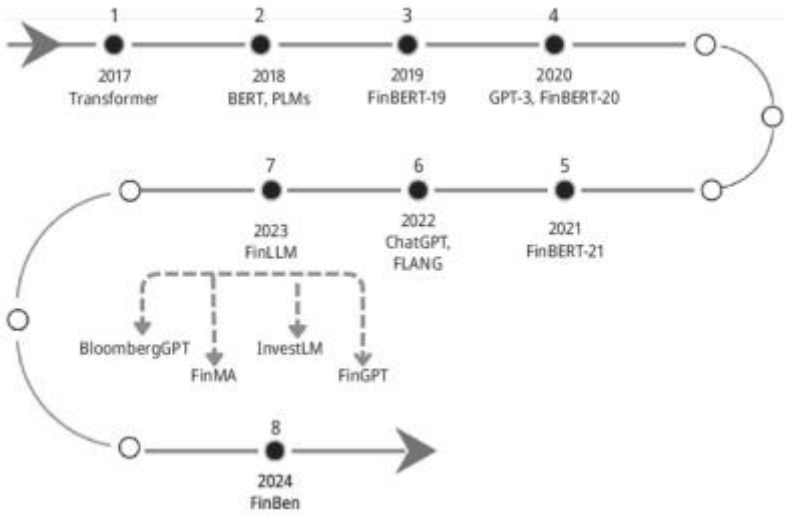


Rok 2018 był ważnym kamieniem milowym, ponieważ powstał BERT [→13]; był to początek nowej ery wstępnie wytrenowanych modeli i doprowadził do drastycznych zmian w NLP. Osiągnięcie zespołu

OpenAI w 2019 r. z GPT-2 pokazało liczne możliwości wykorzystania modeli na dużą skalę w szerokim zakresie zadań. Doprowadziło to do powstania modeli specjalistycznych, takich jak te ukierunkowane na finanse. Istnieją dwa główne typy modeli języka finansowego, takie jak wstępnie wytrenowane modele języka finansowego (FinPLM) i FinLLM. Zazwyczaj FinPLM-y to dopracowane wersje pochodzące z istniejących modeli ogólnego przeznaczenia, takich jak BERT. Modele te są następnie specjalnie dostosowywane do celów finansowych – FinBERT-19, FinBERT-20 i FinBert-21 . Warto zauważyć, że w roku 2022 modele LJ przeznaczone dla sektora finansowego odnotowały duży postęp dzięki wydaniu ChatGPT i FLANG. Wykorzystując architekturę GPT, ChatGPT osiągnął znaczący postęp w dziedzinie konwersacyjnej sztucznej inteligencji, co podniosło poprzeczkę standardów interakcji z klientami w sektorze finansowym. Ponadto, dzięki metodzie wstępnego trenowania ELECTRA, FLANG autorstwa Shaha i inni stał się silniejszym modelem języka finansowego pod względem dokładności niż jego poprzednicy. Uwydatnia to, jak wyspecjalizowane AI mogą być wykorzystywane do poprawy zaangażowania klientów i pogłębiania zrozumienia złożonych koncepcji finansowych stosowanych w branży. Bardziej złożony i autonomiczny trend w dziedzinie technologii finansowych jest widoczny w postępie narzędzi sztucznej inteligencji finansowej w latach 2023-2024, w tym FinBen i Fin-LLM. W tym okresie pojawił się FinLLM jako zaawansowany model języka finansowego nowej generacji, który usprawnił między innymi ocenę ryzyka, przetwarzanie danych finansowych i badania inwestycyjne. Ponadto inne modele, takie jak BloombergGPT, FinMA, InvestLM i FinGPT, zostały wprowadzone jako specjalistyczne modele finansowe GenAI, zapewniające sektorowi finansowemu specjalistyczną wiedzę z zakresu FinLLM . W 2024 roku będziemy świadkami wprowadzenia FinBen . Celem FinBen jest ciągła ocena programów LLM w finansach i wspieranie rozwoju sztucznej inteligencji poprzez regularną aktualizację zadań i modeli.

**Zastosowania modeli językowych w finansach**

Wykorzystanie GenAI w biznesie i finansach może przynieść liczne korzyści, takie jak zwiększona efektywność, redukcja kosztów i uproszczona dostępność. Przewiduje się, że wykorzystanie AI wzrośnie w nadchodzących latach. GenAI, a zwłaszcza modele językowe, takie jak GPT, mogą być wykorzystywane na wiele sposobów w finansach. Mogą one pomóc w analizie finansowej, ocenie ryzyka, wykrywaniu oszustw, a nawet w raportach finansowych lub prognozach rynkowych. W tym artykule przyjrzymy się kilku przykładom analiz wykorzystujących najnowsze narzędzia GenAI, takie jak ChatGPT 3.5, ChatGPT 4 i Gemini. Wdrożenie tej technologii prowadzi do transformacji relacji z klientami, uproszczenia operacji i rozwoju zwinnych branż opartych na danych. Opisujemy również kilka istotnych najnowszych prac z zakresu ekonomii i finansów. Poniżej znajduje się przykład zastosowania finansowego z wykorzystaniem LLM.

**Zarządzanie ryzykiem**

Zarządzanie ryzykiem finansowym jest głównym zastosowaniem sztucznej inteligencji w sektorze finansowym. Zastosowanie technologii GAN daje nadzieję na złagodzenie pewnych charakterystycznych przeszkód napotykanych w sektorze finansowym, szczególnie w zakresie dostępności i analizy danych. Generując syntetyczne dane finansowe o najwyższej jakości, sieci GAN stanowią potencjalnie korzystne narzędzie do wzbogacania analizy ryzyka, gwarantując przestrzeganie standardów regulacyjnych i wspierając innowacje w obszarze usług finansowych. Pomimo pewnych ograniczeń związanych z sieciami GAN, takich jak niestabilność modeli, złożoność rynków finansowych i możliwość generowania mylących danych, sieci te dają nadzieję na zrewolucjonizowanie modelowania finansowego, zarządzania ryzykiem i innych usług finansowych w nadchodzących latach Sieci GAN są umieszczane w nadzorowanym środowisku uczenia się i są bardziej odpowiednie do zadań klasyfikacyjnych dzięki nowo zaprojektowanej funkcji straty. Generują one również pełne rozkłady prawdopodobieństwa warunkowego zwrotów cenowych na podstawie historycznych wartości. Różne

atrybuty kredytobiorców i pożyczek, oceniane za pomocą modeli uczenia maszynowego i uczenia maszynowego (ML) dostarczają cennych informacji na temat czynników determinujących ryzyko kredytowe. Z drugiej strony, niektóre z bardziej zaawansowanych podejść, które można tu uwzględnić, to sieci neuronowe, maszyny wektorów nośnych i drzewa decyzyjne, w przeciwieństwie do regresji logistycznej . GenAI jest użyteczna w zrozumieniu potencjalnych podatności związanych z ryzykiem operacyjnym poprzez symulowanie scenariuszy awarii lub zakłóceń operacyjnych. Podobnie, pomaga bankom lepiej zrozumieć swoje portfele kredytowe, co przekłada się na lepsze zarządzanie portfelem poprzez identyfikację potencjalnych możliwości i ryzyk dywersyfikacji. Ponadto AI oferuje przydatne informacje, które pomagają bankom zapewnić lepszą obsługę klienta i lepsze dostosowanie swoich produktów. AI wnosi istotny wkład w testy warunków skrajnych i analizę scenariuszy, gdzie imituje szereg warunków ekonomicznych w celu oceny ich wpływu na portfele kredytowe. Wspiera strategiczne zarządzanie ryzykiem .

**Wykrywanie oszustw**

Digitalizacja zmienia globalne systemy płatności w sektorze finansowym. W następstwie pandemii zarówno klienci, jak i firmy przesunęli swoją uwagę w stronę bardziej innowacyjnych platform cyfrowych. Ta rewolucja zwiększyła wydajność i zmniejszyła tarcia dla klientów, banków i sprzedawców, ale jednocześnie wykładniczo zwiększyła liczbę oszustw w usługach finansowych na światowym rynku płatności cyfrowych. Dzięki trenowaniu na historycznych danych o oszustwach, systemy sztucznej inteligencji (AI) mogą identyfikować subtelne korelacje i wzorce, które ludzie lub tradycyjne systemy mogłyby przeoczyć, a tym samym wykrywać oszustwa finansowe. Podejście oparte na GenAI może znacznie usprawnić wykrywanie oszustw finansowych. Wraz z postępem technologicznym oszustwa finansowe staną się bardziej złożone i zwodnicze. Algorytmy wykorzystujące GenAI mogą umożliwić oszustom przeprowadzanie bardziej wyrafinowanych i ukierunkowanych ataków, utrudniając wykrywanie oszustw. GenAI automatycznie trenuje algorytm wykrywania oszustw i znajduje wzorce i anomalie oszustw, wykorzystując ogromne syntetyczne zbiory danych . Eksperci mogą oceniać wyniki identyfikacji i zwiększać jej dokładność. Informacje zwrotne od ludzi trenują model wykrywania poprzez uczenie wzmacniające. Modele oparte na GenAI mogą wykrywać oszustwa szybciej i skuteczniej, ponieważ uczą się i doskonalą . Wykorzystanie modeli LLM, najszerzej stosowanej metody GenAI, umożliwia analizę trendów transakcyjnych i wykrywanie oszustw w czasie rzeczywistym. W rezultacie klienci mogą być chronieni, a potencjalne straty finansowe mogą zostać zapobiegnięte.

**Symulacja rynku i prognozowanie**

Aby ocenić i udoskonalić strategie handlowe, modele generatywne umożliwiają symulację szerokiego zakresu okoliczności rynkowych. Pozwala to traderom dostosowywać się do stale zmieniającej się dynamiki rynku. Potencjalnie, dzięki tej optymalizacji, strategie mogą być bardziej odporne na wahania i zmienność rynku. Ta możliwość umożliwia traderom dokonywanie terminowych i efektywnych ocen dzięki wykorzystaniu najnowszych danych rynkowych. Prognozowanie finansowe i ekonomiczne jest częstym zastosowaniem tej strategii badawczej. Symulacje rynku finansowego z wykorzystaniem GenAI mogą dostarczyć syntetycznych danych, które są uderzająco podobne do rzeczywistych sytuacji rynkowych. Prognozowanie trendów rynkowych, wycena aktywów i ocena ryzyka mogą być realizowane za pomocą tych sztucznych zbiorów danych. Umożliwiając zarządzającym portfelami symulowanie różnorodnych scenariuszy rynkowych w celu oceny strategii, funkcjonalność ta wspomaga budowę portfeli inwestycyjnych o większej odporności . ChatGPT i inne narzędzia LLM mogą przewidywać zwroty z rynku akcji za pomocą analizy sentymentu na podstawie nagłówków wiadomości. W analizie sentymentu ChatGPT przewyższa standardowe podejścia.

**Handel algorytmiczny**

Handel algorytmiczny, często nazywany handlem programowym, to podejście inwestycyjne wykorzystywane przez dużych inwestorów instytucjonalnych do szybkiej realizacji dużej liczby zleceń . Ten styl handlu wykorzystuje szybkość i moc obliczeniową komputerów do wykorzystywania okazji handlowych wykraczających poza możliwości człowieka, często działając w ułamkach sekundy. Handel algorytmiczny jest powszechnie stosowany na rynkach finansowych do realizacji transakcji blokowych poprzez rozbicie ich na mniejsze zlecenia, co pozwala na zarządzanie kosztami i ryzykiem związanym z wpływem na rynek. Obejmuje strategie, które mogą być proste, takie jak realizacja zleceń w określonym czasie, lub trudne, wymagające szczegółowej wiedzy o mikrostrukturze rynku, a także zaawansowanych modeli matematycznych do przewidywania cen. Interdyscyplinarny charakter tworzenia i wdrażania algorytmicznych strategii handlowych przejawia się w połączeniu finansów, matematyki, informatyki i analizy danych. Handel algorytmiczny ma tę zaletę, że obniża koszty transakcyjne dzięki najlepszym cenom realizacji, które zmniejszają wpływ rynku na ceny aktywów będących przedmiotem obrotu. Pozwala również uniknąć sytuacji, w których ręczne zawieranie transakcji mogłoby przynieść błędne rezultaty; daje traderom możliwość przetestowania swoich koncepcji na danych historycznych, zanim zostaną one zaimplementowane w postaci kodu programistycznego.

**E-commerce i obsługa klienta**

Branża handlu detalicznego przeszła znaczącą transformację dzięki e-commerce, czyli kupowaniu i sprzedawaniu towarów i usług online. Jest on niezwykle prosty, oferuje większy wybór, a także prostsze sposoby porównywania produktów lub cen. Obsługa klienta w e-commerce ma obecnie kluczowe znaczenie, biorąc pod uwagę, że może ona albo budować, albo niszczyć firmy, prowadząc do znacznych wahań w lojalności klientów, poziomie satysfakcji i postrzeganiu marki. Zasadniczo obsługa klienta w e-commerce musi coraz częściej obejmować różne aspekty, takie jak natychmiastowe odpowiedzi e-mail i czat, szybkie zwroty i wymiany, spersonalizowane porady zakupowe oraz proaktywne rozwiązywanie problemów. Ponadto nie można pominąć chatbotów z obsługą sztucznej inteligencji, które wykorzystują algorytmy NLP do tworzenia spersonalizowanych rekomendacji opartych na uczeniu maszynowym i automatycznej pomocy po zakupie. Te usprawnienia podkreślają również znaczenie obsługi klienta w zapewnieniu płynnego doświadczenia zakupowego . W związku z tym nie można przecenić znaczenia działu obsługi klienta w e-commerce, ponieważ wpływa on na to, czy klienci pozostaną z nimi, czy też przeniosą swoją lojalność do innych firm. Zadowoleni klienci, którzy są zadowoleni z jakości usług świadczonych przez platformę e-commerce, prawdopodobnie powrócą po kolejne zakupy lub polecą tę stronę innym, ułatwiając w ten sposób organiczny rozwój poprzez marketing szeptany. Z drugiej strony, niewystarczająca obsługa klienta może skutkować negatywnymi opiniami w mediach społecznościowych, co może zaszkodzić reputacji firmy i utrudnić jej pozyskiwanie nowych klientów poprzez rekomendacje. Chatboty i wirtualni asystenci wspierani przez LLM znacząco przekształcili obsługę klienta w branży e-commerce. Są w stanie pomóc w rekomendacjach produktów, odpowiadać na pytania konsumentów oraz zarządzać zwrotami i reklamacjami. Gigant e-commerce, Amazon, wykorzystuje LLM do usprawnienia interakcji z klientami i optymalizacji procesów wsparcia. Banki mogą zapewnić swoim klientom bardziej spersonalizowane i istotne doświadczenie bankowe, korzystając z GenAI. GenAI może ocenić sytuację finansową danej osoby, analizując dochody, wydatki i cele oszczędnościowe. Na podstawie tych informacji GenAI rekomenduje spersonalizowane produkty i usługi finansowe.

**Analiza sentymentu**

Analiza sentymentu kwantyfikuje opinie w nieoznaczonych danych tekstowych, klasyfikując je jako pozytywne, negatywne lub neutralne. Może to ujawnić kierunek makroskopowych wzorców w źródłach informacji na dużą skalę, co jest trudnym i czasochłonnym procesem dla analityków. Co ważne, internetowe źródła tekstowe mogą napędzać ruchy rynkowe i dawać przewagę konkurencyjną tym, którzy potrafią je wykorzystać. Wiele dostępnych narzędzi i podejść do analizy sentymentu finansowego jest niezrównanych pod względem możliwości radzenia sobie z wysoce skomplikowanym dyskursem finansowym. FinBERT wykorzystuje wariant BERT, zaprojektowany do interpretacji tekstów finansowych . Model jest wstępnie trenowany z wykorzystaniem ogromnego korpusu, który z czasem budowano, przeszukując literaturę branżową. Financial PhraseBank działa jako zbiór danych bazowych, wykorzystywany do trenowania wielu modeli w zakresie kategoryzowania i rozumienia unikalnych sentymentów obecnych w zdaniach dotyczących wiadomości finansowych. Z drugiej strony, VADER, wraz z towarzyszącą mu listą słów sentymentalnych Loughran-McDonald, został stworzony i zoptymalizowany z myślą o dyskusjach w mediach społecznościowych i formalnych raportach [→30]. Różne narzędzia do różnych celów! FinLlama idzie o krok dalej, wplatając dogłębną analizę sentymentu finansowego w zaawansowaną architekturę LLaMA. Jeśli jednak szukasz czegoś prostszego, TextBlob może być tym, czego potrzebujesz; jest łatwy w użyciu, ale oferuje ograniczoną funkcjonalność . LLM są wykorzystywane przez firmy finansowe do analizy nastrojów w mediach społecznościowych i wiadomościach rynkowych oraz do udzielania wskazówek dotyczących strategii handlowych. Istnieją przykłady funduszy hedgingowych i firm inwestycyjnych, które z powodzeniem wykorzystały LLM, aby dowiedzieć się więcej o nastrojach rynku i podejmować decyzje inwestycyjne w oparciu o rzeczywiste dane . FinLlama to system, który dostraja wstępnie wytrenowany LLM przy użyciu specjalistycznych, oznaczonych i publicznie dostępnych zestawów danych dotyczących wiadomości finansowych. FinLlama ma na celu usprawnienie analizy sentymentu finansowego przy jednoczesnej minimalizacji zużycia zasobów dzięki precyzyjnemu dostrajaniu parametryzowanemu (PEFT) i 8-bitowej kwantyzacji z LoRA.. Wykazano, że ChatGPT przewyższa tradycyjne metody analizy sentymentu. Wreszcie, T5 pokazuje, jak wszechstronne może być oprogramowanie NLP ogólnego przeznaczenia, dostosowane do bankowości. Te udoskonalenia dowodzą dynamicznego charakteru NLP, czyniąc je użytecznym narzędziem do prognozowania rynku i strategii inwestycyjnych.

**Wyzwania i rozważania etyczne dotyczące modeli językowych w finansach**

Kwestia wrażliwości danych ekonomicznych i potencjalnego wpływu na działania wynikającego z ich wyników rodzi szereg problemów etycznych i rozważań w odniesieniu do modeli językowych w finansach. Oto niektóre z najważniejszych kwestii i wątpliwości etycznych:

**Dezinformacja i fałszywe wiadomości**

Dezinformacja, fikcyjne firmy i fałszywe wiadomości finansowe rozprzestrzeniają się lotem błyskawicy i mają dalekosiężne skutki dla całej światowej gospodarki. Absolwenci studiów prawniczych (LLM) przechodzą szkolenia z wykorzystaniem obszernych zbiorów danych; jednak zbiory te mogą zawierać błędy lub nieścisłości. Absolwent studiów prawniczych (LLM) udzielający porad finansowych może wzmacniać te uprzedzenia i wprowadzać inwestorów w błąd. Absolwenci studiów prawniczych (LLM) mogą mieć trudności ze zrozumieniem subtelności terminologii finansowej, a także zawiłych relacji między różnymi czynnikami wpływającymi na rynek. Może to prowadzić do tworzenia nadmiernie uproszczonych lub wprowadzających w błąd danych finansowych. Chociaż ChatGPT został specjalnie zaprojektowany do wykrywania i eliminowania fałszywych informacji , wciąż istnieją wątpliwości co do jego zdolności do zagwarantowania wiarygodności przetwarzanych informacji. Nawet po przejściu wielu szkoleń z zakresu danych, ChatGPT może nadal popełniać błędy w analizie nastrojów rynkowych i prognozach finansowych, jeśli przypadkowo ujawni fałszywe informacje. Co więcej, stale zmieniająca

się charakterystyka fałszywych informacji wymaga ciągłego szkolenia, aby ChatGPT mógł rozpoznawać i eliminować nowe źródła dezinformacji .

**Prywatność i bezpieczeństwo danych**

Wdrażając GenAI i rozbudowane modele językowe w sektorze finansowym, prywatność i bezpieczeństwo danych mają kluczowe znaczenie. Ich zdolność do przetwarzania ogromnych ilości informacji jest imponująca, ale oznacza to również konieczność zachowania ścisłej poufności, integralności i kontroli dostępu. Wiemy to już jednak; wszystko to jest częścią zgodności z przepisami. Europejskie Ogólne Rozporządzenie o Ochronie Danych (RODO) chroni dane osobowe, podczas gdy na poziomie stanowym w Stanach Zjednoczonych również obowiązują przepisy, które priorytetowo traktują ochronę prywatności. Szyfrowanie zawsze będzie miało swoje miejsce w słońcu, jeśli chodzi o środki bezpieczeństwa – szyfrowanie, a także bezpieczne rozwiązania do przechowywania danych i solidne zarządzanie dostępem. Kwestie etyczne powinny być priorytetem przy ocenie danych finansowych. Każdy kraj ma odrębne przepisy i polityki, co uniemożliwia opracowanie planu cyberataku w nieskoordynowanym środowisku [→39]. Ponieważ modele uczenia maszynowego mogą siać spustoszenie, rozpowszechniając stronnicze lub nieprawdziwe informacje w branży, na której tak bardzo polegamy, dalsze badania nad tymi protokołami są niezbędne, aby technologie AI mogły się rozwijać.

**Jakość danych i stronniczość**

Do uczenia maszynowego niezbędne są dane wysokiej jakości. Do celów szkoleniowych i walidacyjnych instytucje finansowe potrzebują ustrukturyzowanych, wysokiej jakości informacji, zanim będą mogły wdrożyć rozwiązania bankowe oparte na sztucznej inteligencji. Jakość i kompletność danych dostarczanych sztucznej inteligencji decyduje o jej zdolności do prognozowania i dostarczania analiz. Rynki finansowe zmieniają się szybko, dlatego dane mają kluczowe znaczenie. Rozwój rynku może nie być odzwierciedlony w szacunkach sztucznej inteligencji opartych na nieaktualnych danych. Kolejnym kluczowym problemem jest stronniczość danych. Dane wykorzystywane do szkolenia sztucznej inteligencji mogą odzwierciedlać przeszłe niesprawiedliwości. Modele sztucznej inteligencji obarczone stronniczością mogą nasilać dyskryminację. System sztucznej inteligencji (AI) do oceny zdolności kredytowej z wykorzystaniem stronniczych danych szkoleniowych może niesprawiedliwie naśladować pożyczki udzielane pewnym grupom. Wiele czynników powoduje, że statystyki finansowe są niezrównoważone; mogą to być dynamika rynku, uprzedzenia ludzkie, historyczne nierówności i inne zróżnicowane przyczyny]. Modele AI generowane na podstawie takich danych mogą zatem wzmacniać te uprzedzenia. Pierwszym z nich jest błąd fazy uczenia ucieleśniony w modelu z powodu skośnych zestawów danych, co prowadzi do stronniczych wyników . Po drugie, istnieje błąd algorytmu, który występuje podczas wnioskowania, niezależnie od zestawu danych szkoleniowych używanego przez model . Wykorzystanie błędnych, niekompletnych lub stronniczych danych do trenowania i napędzania modeli AI może znacząco wpłynąć na dokładność i niezawodność ich analiz i prognoz.

**Zarządzanie ryzykiem**

Wykorzystanie modeli sztucznej inteligencji (AI) w finansach zwiększy efektywność i umożliwi podejmowanie lepszych decyzji. Ponieważ automatyzacja przejmuje pracę ludzi, ta zmiana może znacznie zaoszczędzić pieniądze i zwiększyć produktywność. Problem w tym, że obecnie grozi nam nadmierne poleganie na AI. Bez dobrego zarządzania organizacje mogą popaść w nieprzewidziane problemy finansowe, a nawet doprowadzić do krachu na rynkach. Od dłuższego czasu modelowanie ryzyka finansowego wykorzystuje zaawansowane techniki uczenia maszynowego (ML) do identyfikacji oszustw, analizy wiarygodności kredytowej i przewidywania potencjalnych strat. Przykładem takiego modelu jest model opracowany przez McKinsey & Company, który wykorzystuje wiele warstw

sztucznych sieci neuronowych do wykrywania przypadków oszustw finansowych, gdzie inne tradycyjne metody mogłyby nie być skuteczne , na przykład gdy czyjeś dane dotyczące bezpieczeństwa konta zostały skradzione i są wykorzystywane do dokonywania niechcianych transakcji. Ponieważ banki potrzebują wiarygodnych danych o tym, kto jest godny zaufania w kwestiach finansowych, modele uczenia maszynowego przeszukują je wszystkie w poszukiwaniu oznak, które mogłyby podnieść lub obniżyć ich ocenę kredytową . Korzystanie z tych modeli daje znacznie dokładniejsze wyniki niż tradycyjne systemy scoringowe, ponieważ nie ograniczają się one tylko do określonych cech, takich jak wiek. Innym sposobem, w jaki modele uczenia maszynowego pomagają bankom, jest prognozowanie bankructwa lub niewypłacalności firm [→51]. Porównując bieżące sprawozdania z danymi z przeszłości i trendami, obliczają one prawdopodobieństwo rychłego bankructwa firmy. Tego rodzaju prognozy pomagają inwestorom wycofać się, gdy widzą nadchodzące problemy, zanim będzie za późno.

**Brak wiedzy dziedzinowej**

Zarządzanie przedsiębiorstwem obejmuje różne branże, z różnorodną terminologią, normami operacyjnymi i wyzwaniami. Ogólne modele sztucznej inteligencji, takie jak LLM, doskonale radzą sobie z językami obcymi i łatwo im przetwarzać lub generować prace pisemne w różnych dziedzinach; mają jednak trudności z radzeniem sobie z problemami specyficznymi dla danej branży na rynkach finansowych. Hadi i inni oraz Gu i inni zwrócili uwagę na trudności, jakie te modele mają ze zrozumieniem problemów na rynkach finansowych i zastosowaniem rozumowania opartego na zdrowym rozsądku w procesach decyzyjnych. Ograniczenia te ujawniają się z powodu tego, jak bardzo ogólne są te modele trenowane na dużych zbiorach danych, co sprawia, że nie posiadają one wiedzy na poziomie eksperckim w określonych branżach. Tak naprawdę nie do tego stworzono LLM, więc nie możemy ich zbytnio winić. Ich dane treningowe są tak obszerne, że można je zastosować niemal wszędzie; oczywiście, pomaga im to udzielać spójnych odpowiedzi, które pasują do każdej sytuacji, ale nie sięgają wystarczająco głęboko, aby mogły być wykorzystywane jako eksperckie narzędzie do podejmowania decyzji. Sytuacje wymagające specjalistycznej wiedzy branżowej mogą prowadzić do błędnych decyzji, jeśli jedynym branym pod uwagę kryterium są studia magisterskie (LLM) .

**Ograniczone możliwości wielojęzyczne**

System globalnych finansów jest silnie powiązany z różnymi grupami demograficznymi. Dlatego komunikacja i analiza informacji w wielu językach jest korzystna i niezbędna. Rynki finansowe mają charakter międzynarodowy, a interesariusze i źródła danych są rozproszone w różnych krajach. Aby współdziałać między globalnymi rynkami finansowymi, z których każdy komunikuje się w swoim własnym języku, konieczne jest posiadanie umiejętności komunikacji wielojęzycznej, aby ułatwić bezproblemową interakcję i zapewnić dokładne analizy danych finansowych, raporty i wiadomości z różnych środowisk językowych. Jednakże, jak zauważono, modele sztucznej inteligencji o ograniczonych możliwościach wielojęzycznych stoją przed poważnymi wyzwaniami w przetwarzaniu i generowaniu treści w różnych językach.

**Halucynacje**

Główną cechą LLM jest ich zdolność do generowania kontekstowo istotnych tekstów na szeroki zakres tematów. Pomimo imponujących możliwości, LLM nie są pozbawione wad; Jednym z istotnych problemów jest zjawisko „halucynacji", w którym modele generują fałszywe lub wprowadzające w błąd informacje. W literaturze zidentyfikowano różne czynniki mogące powodować ten problem. Jedną z głównych przyczyn halucynacji są niedokładne lub fałszywe informacje zawarte w zestawach danych treningowych. Modele LLM są zazwyczaj trenowane z wykorzystaniem ogromnych ilości danych pochodzących z internetu, które mogą zawierać informacje niewiarygodne. Halucynacja oparta na danych jest istotna w finansach, ponieważ modele finansowe są trenowane z wykorzystaniem danych

z różnych źródeł, w tym internetu. W związku z tym do zestawów danych mogą przedostać się nieścisłości. Nawet w przypadku idealnych zestawów danych, trening modelu może również powodować halucynacje, ponieważ model próbuje dopasować dane, optymalizując złożone interakcje między różnymi ukrytymi warstwami modelu podczas procesu trenowania. Zlokalizowanie tego typu błędów jest trudne ze względu na „czarną skrzynkę" modeli DL. Innym źródłem problemu są komunikaty wysyłane przez użytkownika podczas korzystania z modelu. Słabe, niespójne lub sprzeczne dane wejściowe mogą wprowadzać zamieszanie w modelu, co z kolei może generować niedokładne odpowiedzi .

**Niewystarczająca wiedza o zachowaniach człowieka**

Dużym problemem dla zastosowań sztucznej inteligencji (AI) na rynkach finansowych jest brak wiedzy o zachowaniach człowieka. Przewidywanie alokacji zasobów przez osoby fizyczne lub przedsiębiorstwa nie jest łatwe. Oprócz czynników ekonomicznych, na ludzi wpływają uprzedzenia psychologiczne i emocje, a także szersze trendy społeczne. Model AI, który został wytrenowany na historycznych zbiorach danych, ma trudności z rozpoznaniem tych problemów. Alokacja środków finansowych przez osoby fizyczne i firmy może być naprawdę trudna. Czynniki ekonomiczne odgrywają rolę, ale istnieją również uprzedzenia psychologiczne, emocje i szersze trendy społeczne, które wpływają na ludzkie decyzje. Takie złożoności mogą być nieuchwytne dla modeli AI, które zostały wytrenowane na rozległych zbiorach danych reprezentujących wieloletnią historię finansową. Na przykład, może się zdarzyć, że nikt nie zwróci uwagi na podstawy ekonomiczne, gdy znany influencer w mediach społecznościowych zarekomenduje okazję inwestycyjną za pośrednictwem swojej platformy. Dzieje się tak, ponieważ rynek reaguje bardziej na nastroje ludzkie niż na dane ekonomiczne, co stanowi wyzwanie dla modeli opartych na danych. Innym przykładem jest wystąpienie nieoczekiwanych wydarzeń globalnych, takich jak pandemia COVID-19, która całkowicie zmieniła nawyki zakupowe. W okresie pandemii COVID-19 wprowadzono wiele lockdownów i panowała niepewność gospodarcza. Spowodowało to znaczące zmiany w zachowaniach konsumentów. Zmiany te nie byłyby przewidywalne przez tradycyjne modele danych oparte na wcześniejszej aktywności. To wyzwanie wymaga, aby modele sztucznej inteligencji (AI) w finansach uwzględniały dane z psychologii i socjologii. Dzięki temu sztuczna inteligencja będzie mogła lepiej zrozumieć, co napędza ludzkie decyzje finansowe, ponieważ będzie uwzględniać takie czynniki, jak modelowanie strachu kontra awersja do ryzyka lub mentalność stadna, a także to, jak wpływają na nie emocje, takie jak chciwość czy strach

**Kwestie etyczne**

Wykorzystanie GenAI w finansach wiąże się z zagadnieniami etycznymi, które wynikają z jego potencjalnego wpływu na stabilność rynku, uczciwe traktowanie klientów i kwestie prywatności. Ważne jest, aby zapewnić, że nie wystąpią niezamierzone konsekwencje, takie jak ułatwianie nielegalnych działań lub pogłębianie się nierówności finansowych, poprzez wprowadzenie odpowiednich zabezpieczeń. Instytucje finansowe muszą zmagać się z dylematami etycznymi, od stronniczości algorytmicznej, przez naruszenie prywatności, po reperkusje dla grup wrażliwych wynikające z decyzji podejmowanych przez sztuczną inteligencję . Instytucje finansowe potrzebują kompleksowych zasad etycznych dotyczących sztucznej inteligencji. Wytyczne te powinny regulować produkcję, dyspersję i wykorzystanie LLM w sposób uczciwy, przejrzysty i odpowiedzialny.

**Ciągły monitoring i doskonalenie**

Ciągłe dążenie do jakości danych jest niezbędne, aby modele AI w finansach były produktywne. Jest to ciągły proces mający na celu zapewnienie jakości danych finansowych. Istnieje wiele powodów, dla których należy stale monitorować jakość danych finansowych. Jest to kluczowe dla utrzymania produktywności modeli AI w czasie z następujących powodów. Dane finansowe podlegają ciągłym

zmianom. Głównym czynnikiem, który modele AI generowałyby wiarygodne wyniki, jest jakość danych wejściowych. Niska jakość danych może spowodować, że model AI generowałby niewiarygodne lub potencjalnie szkodliwe wyniki. Dlatego niezbędna jest regularna ocena danych, aby modele AI pozostały produktywne i wiarygodne. Należy zauważyć, że sytuacja finansowa zmienia się drastycznie w czasie, a zatem dane zebrane w przeszłości mogą nie odzwierciedlać obecnej rzeczywistości. Na sektor finansowy wpływa wiele czynników, takich jak wprowadzanie nowych przepisów, trendy rynkowe i zachowania klientów. Każda zmiana tych cech może wprowadzić niespójności lub stronniczość do danych. Zaufanie odgrywa kluczową rolę w podejmowaniu decyzji finansowych. Dlatego instytucje finansowe muszą to uwzględnić, wdrażając technologie AI. Jednym z głównych czynników jest odpowiedzialne zarządzanie danymi. Istnieje również wiele innych czynników. Sposób, w jaki model AI podejmuje decyzje, jest również ważny dla interesariuszy, aby zrozumieć te procesy. Dlatego pożądane jest inwestowanie w budowanie modeli, które można interpretować. Takie modele pomogą interesariuszom zrozumieć powody podejmowania decyzji. Wzmocniłoby to zaufanie do modeli AI. Innymi czynnikami utrudniającymi zaufanie do modeli AI są prywatność danych i stronniczość modeli, którymi należy się proaktywnie zająć. Dane finansowe są wrażliwe. Dlatego należy nadać najwyższy priorytet solidnym środkom bezpieczeństwa. Środki te muszą chronić dane przed nieautoryzowanym dostępem i manipulacją. Są one niezbędne do budowania zaufania do technologii AI. Instytucje finansowe muszą zapewnić, że ich modele AI pozostaną niezawodne, produktywne i godne zaufania. Takie niezawodne i godne zaufania systemy ostatecznie przyczynią się do powstania bardziej solidnego i odpowiedzialnego ekosystemu finansowego.

**Główne modele FinTech**

**BloombergGPT**

BloombergGPT, zawierający 50 miliardów parametrów, został stworzony z myślą o określonym zestawie celów i możliwości. Nie jest jednak pozbawiony wad. Został zbudowany w oparciu o obszerną bazę danych finansowych Bloomberga. Model koncentruje się na podejmowaniu decyzji finansowych. Zamiast modeli LLM ogólnego przeznaczenia, BloombergGPT został stworzony z myślą o modelu LLM, który ma rozwiązywać problemy specyficzne dla sektora finansowego, oferując doskonałą wydajność w takich zadaniach, jak analiza sentymentu, rozpoznawanie jednostek nazwanych i prognozowanie finansowe . BloombergGPT jest w stanie sprostać tym wymaganiom, ponieważ przeszedł niezwykły harmonogram szkoleń w połączeniu z mieszanymi zbiorami danych. Najpierw został przeszkolony na 363 miliardach tokenów z „FinPile", czyli dużej stercie dokumentów finansowych o wartości ponad trzystu miliardów tokenów zebranych z archiwów Bloomberga. Przeszedł kolejną rundę szkoleń po dodaniu do swojego systemu kolejnych 345 miliardów tokenów z publicznych zbiorów danych. Dzięki temu BloombergGPT nie tylko posiada doskonałą wiedzę na temat finansów, ale także utrzymuje konkurencyjną wydajność w ogólnych testach porównawczych NLP. Jak widać po 50 miliardach parametrów, ten finansowy gigant znacznie poprawił się w analizie liczb i trendów ekonomicznych. Pomimo postępów, ograniczenia BloombergGPT są odnotowane w dokumentacji. Zgodnie z dokumentacją, uczenie i wydajność modelu w dużej mierze zależą od jakości zbiorów danych finansowych użytych do jego zbudowania. To duży krok naprzód w dziedzinie sztucznej inteligencji w danej dziedzinie, ale jeśli podczas uczenia pominięto zbyt wiele ważnych szczegółów, możliwości są ograniczone. Co więcej, podobnie jak inne modele LLM, BloombergGPT nie jest idealny pod względem stronniczości i uczciwości. Oznacza to, że musimy stale dążyć do tego, aby nasze modele były jak najbardziej obiektywne podczas ich trenowania i testowania w praktyce.

**FinGPT-HPC**

Wprowadzenie FinGPT-HPC w 2024 roku było przełomem w dziedzinie finansów dla LLM [→61]. W przeciwieństwie do swoich poprzedników, których wymagania dotyczące zasobów obliczeniowych wymagały całkowitej powierzchni w metrach kwadratowych, FinGPT-HPC będzie uosobieniem wydajności. Model osiąga to poprzez inteligentne zastępowanie tradycyjnych, wymagających dużej mocy obliczeniowej warstw ich smukłymi wersjami. Rezultat? Znacznie szybszy i bardziej wydajny pod względem pamięci model LLM, dostosowany do zadań finansowych. Ma to bezpośredni wpływ na koszty i oszczędności, umożliwiając nawet systemom o ograniczonych zasobach wykonywanie FinGPT-HPC i zwiększając jego dostępność we wdrożeniu. Co więcej, model ten bardzo dobrze sprawdza się w zadaniach finansowych, charakteryzuje się stosunkowo wysoką dokładnością i wydajnością. To nowoczesne podejście ma na celu umożliwienie w przyszłości zastosowania zaawansowanej sztucznej inteligencji w sektorze finansowym bez większych problemów.

**FinBERT**

FinBERT to specjalna adaptacja modelu BERT do języka używanego w dziedzinie finansów. Dopracowanie modelu BERT z dokumentami finansowymi pozwala na zrozumienie subtelności w świecie finansów, takich jak sentyment i kontekst, co byłoby niemożliwe w przypadku modeli języka ogólnego. To dopracowanie pomoże im wykonywać różne zadania z większą dokładnością w porównaniu z modelami języka ogólnego przeznaczenia. FinBERT znalazł zastosowanie między innymi w analizie sentymentu tekstów finansowych, monitorowaniu zgodności z ryzykiem, prognozowaniu finansowym, automatyzacji obsługi klienta oraz ekstrakcji informacji finansowych z nieustrukturyzowanych danych. Skupienie się modelu na konkretnej dziedzinie zapewnia następujące dodatkowe korzyści: lepsze zrozumienie pojęć finansowych związanych z daną dziedziną oraz większą dokładność w wielu zadaniach ważnych dla podejmowania decyzji finansowych, takich jak automatyzacja złożonych analiz finansowych. FinBERT został opracowany poprzez wstępne trenowanie na ogromnym korpusie dokumentów finansowych w celu dopracowania zdolności modelu do rozpoznawania i interpretowania specyficznych wzorców języka używanego w finansach. Mówiąc w uproszczeniu, FinBERT stanowi postęp w dziedzinie zastosowań NLP w finansach – doskonałe narzędzie do eksperymentów, ponieważ jest bardzo potężnym narzędziem do analizy, zapewniania zgodności i obsługi klienta w branży.

**T5: Transformator transferu tekstu do tekstu**

Ponadto, jego najnowocześniejsze możliwości NLP, w które wyposażony jest model T5 (Transformator transferu tekstu do tekstu), znalazły zastosowanie w bardzo wielu obszarach sektora finansowego – od efektywności operacyjnej, przez jakość podejmowania decyzji, a nawet interakcje z klientami [→62]. Dzięki generowaniu tekstu i zrozumieniu informacji, T5 pomoże w automatycznym raportowaniu finansowym, realizowanym przez robo-doradców, a także w niuansowej analizie sentymentów i monitorowaniu zgodności z przepisami. To samo w dużym stopniu przyczynia się do testowania elastyczności T5 w różnych innych zastosowaniach, od wykrywania oszustw, przez chatboty oferujące doskonałą obsługę klienta, aż po strategie handlowe dla celów algorytmicznych. Kolejną rolą jest zarządzanie ryzykiem, zarządzanie finansami osobistymi oraz analiza i zarządzanie kontraktami finansowymi. Zdolność T5 do syntezy i analizy ogromnych wolumenów danych finansowych i tekstów pozwala instytucjom finansowym na uzyskanie głębszego wglądu, automatyzację najbardziej wymagających procesów i oferowanie spersonalizowanych porad, co wyraźnie sygnalizuje transformacyjny efekt, jaki zwiastuje ta technologia. Oprócz tych modeli, w finansach istnieje kilka modeli, takich jak FinAraT5 i FinSQL. Porównanie omówionych powyżej modeli przedstawiono w Tabeli
.

| Feature | BloombergGPT | FinGPT-HPC | FinBERT | T5 |
|---|---|---|---|---|
| **Primary focus** | Financial news and data analysis – sentiment analysis, named entity recognition, news classification, and question answering | Financial applications with high-performance computing | Financial sentiment analysis | General-purpose text tasks |
| **Training data** | Financial news, reports, and market data | Large-scale financial datasets | Financial forums and news | C4 (Colossal Clean Crawled Corpus), including diverse text |
| **Model architecture** | GPT-based | GPT-based, with optimizations for HPC | BERT-based | Encoder-decoder architecture |
| **Key applications** | Real-time market analysis and automated reporting | Risk assessment and algorithmic trading | Sentiment analysis in finance | Text summarization, translation, and question answering |
| **Performance** | Optimized for speed and accuracy in financial contexts | Designed for computational efficiency at scale | Fine-tuned for understanding financial sentiment | Highly versatile across many NLP tasks |
| **Availability** | Proprietary | Open source, offers a cost-effective solution for training | Open source (variants) | Open source |
| **Pretrained/fine-tuning** | Pretrained on financial data; may require fine-tuning for specific tasks | Pretrained for financial applications; customizable | Pretrained, with options for further fine-tuning | Pretrained, highly adaptable for fine-tuning |

**Wnioski i przyszłe kierunki rozwoju**

Podsumowując, rozwój GenAI, wraz z LLM, to prawdziwy przełom dla branży finansowej. Pojawiają się w związku z tym ogromne możliwości uproszczenia złożonych procesów, podejmowania strategicznych decyzji i pogłębiania analiz marketingowych poprzez zaawansowaną analizę danych. W rzeczywistości, w obliczu wyzwań związanych z finansami, dużymi zbiorami danych i złożonymi, stale zmieniającymi się alternatywami, nie sposób przecenić znaczenia tej technologii w usprawnianiu operacji i symulowaniu ludzkich osądów. Są to cenne narzędzia, które prawdopodobnie odegrają nieocenioną rolę, szczególnie dla zarządzających aktywami, którzy chcą zrozumieć złożoność dużych zbiorów danych i podejmować świadome decyzje oraz planować strategicznie. Modele omówione w tym rozdziale podkreślają transformacyjną moc GenAI, w szczególności LLM, dla finansów, wysuwając na pierwszy plan siłę, która może napędzać innowacje i tworzyć wartość. W przyszłości jednak wskazane byłoby rozpoczęcie oceny i wykorzystania szerokiego zakresu zastosowań, które potencjalnie można wykorzystać w branży usług finansowych dzięki tym technologiom. Może to obejmować niezwykle krytyczną analizę kwestii etycznych dotyczących odpowiedzialnego wdrażania, zapobiegania

nadużyciom oraz zagwarantowania przejrzystości i uczciwości zautomatyzowanych procesów decyzyjnych. Co więcej, te modele predykcyjne są stale rozwijane i udoskonalane; dlatego wymagają one ukierunkowanej pracy, zarówno w celu zwiększenia dokładności, jak i badania nowych zastosowań oraz dostosowania się do zmieniającego się otoczenia finansowego. Oznacza to, że ciągłe badania i współpraca różnych myśli i umysłów mogą jedynie dodatkowo pogłębić zrozumienie nowych metod modelowania ekonomicznego, wstępnego przetwarzania danych i optymalizacji modeli. To z kolei uwalnia dalszy potencjał analityki predykcyjnej w świecie finansów, umożliwiając zwiększenie efektywności, innowacji i strategicznego wglądu. To właśnie na tym założeniu dalsza droga charakteryzuje się eksploracją, wyzwaniami i szansami, a także silnym zaangażowaniem w innowacyjne kwestie etyczne i wspólne badania, co wzmacnia siłę GenAI i LLM w dążeniu do przekształceń niezbędnych w branży usług finansowych.