

जनरेटिव आर्टिफिशियल इंटेलिजेंस फंडामेंटल



1. परिचय

कृत्रिम बुद्धिमत्ता 21वीं सदी के अर्थशास्त्र की प्रेरक शक्तियों में से एक बन गई है, विशेष रूप से जनरेटिव कृत्रिम बुद्धिमत्ता के विकास के कारण। यह आलेख बताता है कि जनरेटिव आर्टिफिशियल इंटेलिजेंस क्या है और इसकी नींव क्या है, बड़े भाषा मॉडल पर विशेष ध्यान दिया गया है। एक संक्षिप्त ऐतिहासिक समीक्षा विश्लेषण करती है कि एआई आज तक कैसे विकसित हुआ है और फिर सबसे प्रासंगिक मॉडल और तकनीक प्रस्तुत करता है। अब तक उपयोग की गई तकनीकों की सीमाओं और चुनौतियों का विश्लेषण किया गया है और बताया गया है कि कैसे जनरेटिव आर्टिफिशियल इंटेलिजेंस समस्या समाधान के लिए नए और बेहतर विकल्प प्रदान करता है। इन प्रौद्योगिकियों के उपयोग से जुड़े नैतिक और सामाजिक पहलू भी बहुत प्रासंगिक हैं और इस पूरे पेपर में इनका पता लगाया गया है। अंत में, भविष्य के रुझानों के साथ-साथ दुनिया को बदलने के लिए इस तकनीक की क्षमता के बारे में लेखकों के दृष्टिकोण को भी प्रस्तुत किया गया है।

2. परिभाषा और बुनियादी बातें

यह खंड जनरेटिव आर्टिफिशियल इंटेलिजेंस (एआई) का वर्णन करता है, इसके सबसे महत्वपूर्ण और विभेदक तत्वों पर जोर देता है। इसके बाद कृत्रिम बुद्धिमत्ता के विकास की एक संक्षिप्त समीक्षा की गई है और इसने जेनेरिक एआई के उद्भव को कैसे जन्म दिया है जैसा कि हम आज जानते हैं। अंत में, आज हम जहां हैं वहां तक एआई की प्रगति का सारांश प्रस्तुत किया गया है।

2.1. जेनेरेटिव एआई क्या है?

जेनेरेटिव एआई को कृत्रिम बुद्धिमत्ता की एक शाखा के रूप में परिभाषित किया गया है, जो मौजूदा डेटा का केवल विश्लेषण या उस पर कार्य करने के विपरीत, नई सामग्री तैयार करने में सक्षम है, जैसा कि विशेषज्ञ सिस्टम करते हैं (वासवानी एट अल., 2017)। यह अब तक उपयोग की जाने वाली बुद्धिमान प्रणालियों पर एक वास्तविक विकास है, जो उदाहरण के लिए, तंत्रिका नेटवर्क, केस-आधारित तर्क प्रणाली, आनुवंशिक एल्गोरिदम, फ्रजी लॉजिक (गुयेन एट अल., 2013) या हाइब्रिड एआई मॉडल (गाला) पर आधारित हैं। एट अल., 2016; अब्राहम एट अल., 2009; कोरचाडो एट अल., 2021) और मॉडल और एल्गोरिदम जो विशिष्ट समस्याओं के लिए विशिष्ट डेटा का उपयोग करते थे और इनपुट डेटा के आधार पर एक विशिष्ट उत्तर उत्पन्न करते थे।

जेनेरेटिव आर्टिफिशियल इंटेलिजेंस में कॉर्पस या डेटासेट पर प्रशिक्षित भेदभावपूर्ण या परिवर्तनकारी मॉडल शामिल होते हैं, जो इनपुट जानकारी को उच्च-आयामी अव्यक्त स्थान में मैप करने में सक्षम होते हैं। इसके अलावा, इसमें एक जेनेरेटिव मॉडल है जो स्टोकेस्टिक व्यवहार को संचालित करता है, हर प्रयास में उपन्यास सामग्री बनाता है, यहां तक कि समान इनपुट उत्तेजनाओं के साथ भी। ये मॉडल विशिष्ट पद्धति के आधार पर, बिना पर्यवेक्षित, अर्ध-पर्यवेक्षित या पर्यवेक्षित शिक्षण कर सकते हैं। हालांकि इस पेपर का उद्देश्य जेनेरेटिव एआई की पूरी क्षमता प्रस्तुत करना है, लेकिन वहां से सामान्यीकरण करने के लिए बड़े भाषा मॉडल (एलएलएम) पर ध्यान केंद्रित किया गया है (चांग एट अल., 2023)। एलएलएम जेनेरेटिव आर्टिफिशियल इंटेलिजेंस (एआई) की एक उपश्रेणी है। जेनेरेटिव एआई उन मॉडलों और तकनीकों को संदर्भित करता है जिनमें नई और मूल सामग्री उत्पन्न करने की क्षमता होती है, और इस डोमेन के भीतर, एलएलएम टेक्स्ट उत्पन्न करने में विशेषज्ञ होते हैं। ओपनएआई के जीपीटी (जेनेरेटिव प्री-ट्रेंड ट्रांसफार्मर) जैसे एलएलएम को मूल रूप से टेक्स्ट उत्पन्न करने के लिए प्रशिक्षित किया जाता है, या टेक्स्ट के पैराग्राफ के साथ सवालों के जवाब देने के लिए प्रशिक्षित किया जाता है (गुआन एट अल., 2020)। एक बार प्रशिक्षित होने के बाद, यह पूर्ण वाक्य और पैराग्राफ उत्पन्न कर सकता है जो सुसंगत हैं और, कई मामलों में, मनुष्यों द्वारा लिखे गए वाक्यों से अप्रभेद्य हैं, बस एक प्रारंभिक उत्तेजना या संकेत से (मैडोटो एट अल., 2021)। जबकि जेनेरेटिव एआई में ऐसे मॉडल भी शामिल हैं जो अन्य प्रकार की सामग्री उत्पन्न कर सकते हैं जैसे कि छवियां (जैसे, DALL-E, ओपनएआई से भी) या संगीत, एलएलएम विशेष रूप से भाषा के क्षेत्र पर ध्यान केंद्रित करते हैं (एडम्स, एट अल., 2023)। इसलिए एलएलएम को व्यापक श्रेणी का एक हिस्सा या उपसमूह माना जा सकता है

जेनेरेटिव एआई.

एलएलएम तंत्रिका नेटवर्क हैं जो अनुक्रमिक डेटा को संसाधित करने के लिए डिज़ाइन किए गए हैं (बुबेक एट अल., 2023)। एलएलएम को पाठ्य सामग्री (डिजिटल किताबें, डेटाबेस, इंटरनेट से जानकारी, आदि) पर प्रशिक्षित किया जा सकता है; इनपुट टेक्स्ट का उपयोग पिछली जानकारी के आधार पर अनुक्रम में शब्द-दर-शब्द टेक्स्ट उत्पन्न करना सीखने के लिए किया जा सकता है। इन एलएलएम के निर्माण में ट्रांसफार्मर शायद सबसे व्यापक रूप से उपयोग किए जाने वाले मॉडल हैं (वान ओसवाल्ड एट अल., 2023)। बड़े पैमाने के भाषा मॉडल (एलएलएम) विशेष रूप से ट्रांसफार्मर का उपयोग नहीं करते हैं, हालांकि ट्रांसफार्मर, विशेष रूप से वासवानी एट अल द्वारा पेपर "अटेंशन इज़ ऑल यू नीड" में पेश की गई वास्तुकला। 2017 में, प्राकृतिक भाषा प्रसंस्करण कार्यों के लिए विशेष रूप से प्रभावी साबित हुए हैं (नाडकर्णी एट अल., 2011) और जीपीटी और बीईआरटी जैसे कई लोकप्रिय एलएलएम का आधार रहे हैं। हालांकि, ट्रांसफार्मर के लोकप्रिय होने से पहले, आवर्तक तंत्रिका नेटवर्क (आरएनएन) और उनके वेरिएंट, जैसे एलएसटीएम (लॉन्ग शॉर्ट-टर्म मेमोरी) और जीआरयू (गेटेड रिकरेंट यूनिट्स) नेटवर्क, आमतौर पर प्राकृतिक भाषा प्रसंस्करण कार्यों में अनुक्रमों को मॉडल करने के लिए उपयोग किए जाते थे। (शेरस्टिंस्की, 2020; टैंग एट अल., 2020)।

जैसे-जैसे कृत्रिम बुद्धिमत्ता और प्राकृतिक भाषा प्रसंस्करण के क्षेत्र में अनुसंधान आगे बढ़ रहा है, यह संभव है कि नए आर्किटेक्चर और दृष्टिकोण सामने आएँ जिनका उपयोग भविष्य के एलएलएम में ट्रांसफार्मर के साथ या इसके बजाय किया जा सकता है। इस प्रकार, हालांकि ट्रांसफार्मर वर्तमान में एलएलएम के लिए एक प्रमुख आर्किटेक्चर हैं, वे उपयोग किए जाने वाले एकमात्र आर्किटेक्चर नहीं हैं, लेकिन जब नया पाठ तैयार करने की बात आती है जो व्याकरणिक रूप से सही और अर्थपूर्ण रूप से सार्थक है (वासवानी एट अल.) तो वे सबसे विश्वसनीय में से एक हैं। 2017)। यह तीन विशिष्ट तत्वों के कारण है: (ए) पहला स्थितीय कोडिंग तंत्र का उपयोग है, जो नेटवर्क को एक वाक्य के भीतर किसी शब्द को एक स्थिति निर्दिष्ट करने की अनुमति देता है ताकि यह स्थिति नेटवर्क के इनपुट डेटा का हिस्सा हो। इसका मतलब यह है कि शब्द क्रम की जानकारी नेटवर्क की संरचना के हिस्से के बजाय स्वयं डेटा का हिस्सा बन जाती है, ताकि जैसे ही नेटवर्क को प्रशिक्षित किया जाए, बहुत सारे पाठ्य डेटा के साथ, यह सीखता है कि स्थितिगत कोडिंग की व्याख्या कैसे की जाए और शब्दों को सुसंगत रूप से कैसे क्रमबद्ध किया जाए। प्रशिक्षण में प्रयुक्त डेटा; (बी) दूसरे, ध्यान (बहदानव एट अल., 2014), जो शब्दों को एक-दूसरे से जोड़ने के लिए एल्गोरिदम विकसित करके एक भाषा से दूसरी भाषा में पाठ के सार्थक अनुवाद के लिए एक तंत्र के रूप में उभरा और इस प्रकार उन्हें पर्याप्त रूप से उपयोग करना जानता है। प्रसंग; (सी) अंत में, आत्म-ध्यान या ऑटोरेग्रेसिव ध्यान, लिंग और क्रम के अलावा भाषा की विशेषताओं के बेहतर ज्ञान की अनुमति देता है, जैसे कि पर्यायवाची शब्द, जिन्हें कई उदाहरणों के विश्लेषण के माध्यम से पहचाना जाता है।

क्रिया संयुग्मन, विशेषण आदि के लिए भी यही सच है। पिछले दृष्टिकोण जो शब्द आवृत्तियों के आधार पर महत्व प्रदान करते हैं, किसी शब्द के वास्तविक अर्थ महत्व को गलत तरीके से प्रस्तुत कर सकते हैं; इसके विपरीत, आत्म-ध्यान मॉडल को इनपुट टेक्स्ट के भीतर दीर्घकालिक अर्थ संबंधों को पकड़ने की अनुमति देता है, भले ही वह टेक्स्ट विभाजित हो और समानांतर में संसाधित हो (वासवानी एट अल., 2017)। पाठ निर्माण भी सामग्री और अनुक्रम बनाने के बारे में है, उदाहरण के लिए, प्रोटीन, ऑडियो, कंप्यूटर कोड या शतरंज चाल (एल्लौडो एट अल., 2023)।

ट्रांसफार्मर के विकास में एल्गोरिदम स्तर पर प्रगति, उदाहरण के लिए, वर्तमान कम्प्यूटेशनल क्षमता और बिना लेबल वाले डेटा के साथ पूर्व-प्रशिक्षण और प्रशिक्षण (फाइन ट्यूनिंग) को परिष्कृत करने की क्षमता ने इस महान एआई क्रांति को प्रेरित किया है। मॉडल का प्रदर्शन काफी हद तक गणना के पैमाने पर निर्भर करता है, जिसमें प्रशिक्षण के लिए उपयोग की जाने वाली कम्प्यूटेशनल शक्ति की मात्रा, मॉडल मापदंडों की संख्या और डेटासेट का आकार शामिल है। एलएलएम के पूर्व-प्रशिक्षण के लिए सैकड़ों या हजारों जीपीयू और हफ्तों से लेकर महीनों तक समर्पित प्रशिक्षण समय की आवश्यकता होती है। उदाहरण के लिए, यह अनुमान लगाया गया है कि 175 बिलियन मापदंडों वाले GPT-3 मॉडल के लिए 300 बिलियन टोकन पर प्रशिक्षित एक एकल प्रशिक्षण की अकेले कम्प्यूटेशनल लागत में पाँच मिलियन डॉलर खर्च हो सकते हैं।

एलएलएम को बड़ी मात्रा में बिना लेबल वाले डेटा पर पूर्व-प्रशिक्षित किया जा सकता है। उदाहरण के लिए, जीपीटी को बिना लेबल वाले टेक्स्ट डेटा पर प्रशिक्षित किया जाता है, जो इसे स्पष्ट मार्गदर्शन के बिना मानव भाषा में पैटर्न सीखने की अनुमति देता है (रेडफोर्ड और नरसिम्हन, 2018)। चूंकि लेबल रहित डेटा लेबल किए गए डेटा की तुलना में बहुत अधिक प्रचलित है, यह एलएलएम को बहुत बड़े प्रशिक्षण कोष में प्राकृतिक भाषा के बारे में सीखने की अनुमति देता है (ब्राउन एट अल., 2020)। परिणामी मॉडल का उपयोग कई अनुप्रयोगों में किया जा सकता है क्योंकि इसका प्रशिक्षण कार्यों के किसी विशेष सेट के लिए विशिष्ट नहीं है।

सामान्य-उद्देश्य वाले एलएलएम को आउटपुट उत्पन्न करने के लिए "फाइन-ट्यून" किया जा सकता है जो किसी भी विशिष्ट कॉन्फिगरेशन (ओयांग एट अल।, 2022; लियू एट अल।, 2023) के पूर्ववर्तियों से मेल खाता है, जिसे फाइन ट्यूनिंग के रूप में जाना जाता है। उदाहरण के लिए, एक एलएलएम किसी दिए गए प्रश्न के कई संभावित उत्तर उत्पन्न कर सकता है, लेकिन उनमें से कुछ गलत या पक्षपातपूर्ण हो सकते हैं। इस मॉडल को ठीक करने के लिए, मानव विशेषज्ञ एक इनाम फंक्शन को प्रशिक्षित करने के लिए आउटपुट को रैंक कर सकते हैं जो कुछ उत्तरों को दूसरों पर प्राथमिकता देता है। इस तरह के परिशोधन से मॉडल की गुणवत्ता में काफी सुधार हो सकता है, जिससे एक सामान्य-उद्देश्य वाला मॉडल किसी विशेष समस्या को हल करने के लिए उपयुक्त हो सकता है (ओयांग एट अल।, 2022)।

2.2. एआई से जनरेटिव एआई तक का इतिहास और विकास

आर्टिफिशियल इंटेलिजेंस कंप्यूटर विज्ञान और प्रौद्योगिकी का एक क्षेत्र है जो कंप्यूटर सिस्टम के विकास से संबंधित है जो ऐसे कार्य कर सकता है जिनके लिए आमतौर पर मानव बुद्धि की आवश्यकता होती है, जैसे कि सीखना, निर्णय लेना, समस्या निवारण, धारणा और प्राकृतिक भाषा (रसेल और नॉरविग, 2014)। ट्यूरिंग ने कृत्रिम बुद्धिमत्ता के केंद्रीय प्रश्न को संबोधित किया: "क्या मशीनें सोच सकती हैं?" (ट्यूरिंग, 1950)। इसके तुरंत बाद, यह जॉन मैककार्थी ही थे जिन्होंने 1956 में "कृत्रिम बुद्धिमत्ता" शब्द गढ़ा और लिस्प प्रोग्रामिंग भाषा के विकास में योगदान दिया, जो कई लोगों के लिए एआई का प्रवेश द्वार रहा है (मैककार्थी एट अल।, 2006)। वह, मार्विन मिंस्की (एमआईटी), लोटफाली ए. ज़ादेह (बर्कले विश्वविद्यालय, कैलिफ़ोर्निया) या जॉन हॉलैंड (मिशिगन विश्वविद्यालय) जैसे अन्य लोगों के साथ, अग्रणी रहे हैं (ज़ादेह, 2008)। उनके काम से रुझान, मॉडल और एल्गोरिदम सामने आए हैं। उनके काम से विचारधारा के स्कूलों का निर्माण हुआ है और इसके आधार पर प्रणालियाँ बनाई गई हैं, जिससे चिकित्सा जैसे क्षेत्रों में वास्तविक प्रगति हुई है।

इस प्रकार, कृत्रिम बुद्धिमत्ता की शाखाएँ जैसे प्रतीकात्मक तर्क, विशेषज्ञ प्रणालियाँ, तंत्रिका नेटवर्क (कोरचाडो एट अल।, 2000), फ़ज़ी लॉजिक, प्राकृतिक भाषा प्रसंस्करण, आनुवंशिक एल्गोरिदम, कंप्यूटर विज्ञान, मल्टी-एजेंट सिस्टम (गॉजालेज-ब्रियोन्स एट अल।)। 2018) या सामाजिक मशीनें (हेंडलर और मुलवेहिल, 2016; चामोसो एट अल।, 2019) उभरी हैं। इन सभी शाखाओं को उप-शाखाओं में और इन्हें अन्य शाखाओं में इस प्रकार विभाजित किया गया है कि आज विशेषज्ञता का स्तर ऊँचा है।

अधिकांश जटिल प्रणालियाँ अनेक तत्वों से प्रभावित होती हैं; वे कई डेटा स्रोतों को उत्पन्न करते हैं, या उनसे संबंधित होते हैं, वे समय के साथ विकसित होते हैं, और ज्यादातर मामलों में, उनमें विशेषज्ञ ज्ञान की एक डिग्री होती है (पेर्रेज़-पॉस एट अल।, 2023)। इस संबंध में, यह स्पष्ट प्रतीत होता है कि विभिन्न स्तरों पर या विभिन्न स्रोतों से डेटा का विश्लेषण करने वाली कनेक्शनवादी तकनीकों के साथ ज्ञान को मॉडलिंग करने में सक्षम प्रतीकात्मक प्रणालियों का संयुक्त उपयोग वैश्विक समाधान प्रदान कर सकता है। ऐसी समस्याओं का पता लगाना मुश्किल नहीं है, उदाहरण के लिए, चिकित्सा के क्षेत्र में, जहाँ ज्ञान मॉडलिंग उतना ही महत्वपूर्ण है जितना कि अकेले रोगी डेटा का विश्लेषण। मॉडल फ़्यूज़न का एक उदाहरण आनुवंशिक विश्लेषण के लिए जीन-सीबीआर प्लेटफॉर्म था। एक ओर, इसने कई तंत्रिका नेटवर्क और फ़ज़ी सिस्टम (डियाज़ एट अल., 2006; हर्नान्डेज़-नीवेस एट अल., 2021) के साथ केस-आधारित तर्क प्रणाली के साथ वितरित पद्धतिगत ढाँचे का उपयोग किया। यह मॉडल मायलोमा के विश्लेषण को सुविधाजनक बनाने के लिए बनाया गया था।

1970/80 का दशक कृत्रिम बुद्धिमत्ता और वितरित कंप्यूटिंग के लिए एक महत्वपूर्ण अवधि थी (जनबी एट अल., 2022)। महान परिवर्तन का समय, इंटरनेट के चलन के साथ, ऐसे समय में जब दुनिया एक नई सदी के करीब पहुंच रही थी और जहाँ कंप्यूटिंग दुनिया का ध्यान एआई की प्रगति की तुलना में इंटरनेट की क्षमता पर अधिक केंद्रित था। यह तथ्य, हार्डवेयर सीमाओं, एआई में उद्योग की अरुचि और विघटनकारी विचारों की कमी के साथ मिलकर इस क्षेत्र में ठहराव की अवधि की शुरुआत में योगदान दिया, जिसे "एआई विटर" के रूप में जाना जाता है।

लेकिन सर्दी के बाद गर्मी आती है और यह सदी के मोड़ पर आया, जिसे हम गहन शिक्षण और कन्वेंशनल न्यूरल नेटवर्क (सीएनएन) कहते हैं। यह एक प्रमुख अवधारणा थी जिसने सूचना से निपटने के हमारे तरीके में आमूल-चूल परिवर्तन ला दिया। ये नेटवर्क मशीन लर्निंग तकनीकों का उपयोग कुछ अलग तरीके से करते हैं जिस तरह से उनकी मूल रूप से कल्पना की गई थी

(बेंगियो, 2009; पेरेज़-पॉस एट अल., 2021; हर्नांडेज़ एट अल., 2021)। अन्य मॉडलों के विपरीत, उनमें कई छिपी हुई परतें होती हैं जो इनपुट डेटा से सुविधाओं और पैटर्न को तेजी से जटिल और अमूर्त तरीके से निकालने की अनुमति देती हैं (पारिख एट अल., 2022)। यहां, एक एकल एल्गोरिदम विभिन्न दृष्टिकोणों से एक समस्या का समाधान करता है।

ये मॉडल पहले और बाद का प्रतिनिधित्व करते हैं और हमारे काम करने के तरीके में क्रांतिकारी बदलाव लाएंगे। ज्ञान सृजन के इन नए मॉडलों का उपयोग करके डिजिटल, भौतिक और जैविक प्रौद्योगिकियों के अभिसरण के माध्यम से सिस्टम बनाने की हमारी क्षमता के कारण यह पांचवीं औद्योगिक क्रांति की शुरुआत है (कोर्चाडो, 2023)। यदि हम तेजी से आगे बढ़ने वाली दुनिया में रहते थे, तो अब हमें निरंतर गति की दुनिया के लिए तैयारी करनी चाहिए। जो लोग इन प्रगतियों के साथ तालमेल बनाए रखेंगे, वे आने वाले वर्षों में अपने व्यवसाय, मूल्य सृजन और सेवा के अवसरों में तेजी से वृद्धि देखेंगे।

डीप लर्निंग मशीन लर्निंग की एक उपश्रेणी है जो मॉडल की संरचना और कार्य से प्रेरित एल्गोरिदम पर केंद्रित है, जिसे कृत्रिम तंत्रिका नेटवर्क कहा जाता है (चान, एट अल., 2016; कोथदिया एट अल., 2022, अलीज़ादेहसानी एट अल., 2023)। ये नेटवर्क, खासकर जब उनमें कई (गहरी) परतें हों, विभिन्न एआई कार्यों में बेहद प्रभावी साबित हुए हैं। गहन शिक्षण-आधारित जेनेरेटर मॉडल स्वचालित रूप से डेटा का प्रतिनिधित्व करना सीख सकते हैं और मूल डेटा के वितरण के समान नए उत्पन्न कर सकते हैं।

सीएनएन तंत्रिका नेटवर्क का एक विशेष वर्ग है जिसे एक छवि जैसी ग्रिड जैसी संरचना के साथ डेटा संसाधित करने के लिए डिज़ाइन किया गया है। वे कंप्यूटर विज्ञान कार्यों के केंद्र में हैं। जेनेरिक एआई के संदर्भ में, सीएनएन को छवियां उत्पन्न करने के लिए अनुकूलित किया गया है। उदाहरण के लिए, जेनेरिक एंटागोनिस्टिक नेटवर्क (जीएनएन) अक्सर यथार्थवादी छवियां उत्पन्न करने के लिए अपने जेनेरेटर और विभेदकों में सीएनएन का उपयोग करते हैं।

2014 में इयान गुडफेलो और उनके सहयोगियों द्वारा पेश किए गए GAN में दो तंत्रिका नेटवर्क, एक जेनेरेटर और एक विवेचक शामिल हैं, जिन्हें एक साथ प्रशिक्षित किया जाता है (गुडफेलो एट अल., 2014)। जेनेरेटर डेटा (जैसे छवियां) उत्पन्न करने का प्रयास करता है, जबकि विवेचक वास्तविक डेटा और उत्पन्न डेटा के बीच अंतर करने का प्रयास करता है। जैसे-जैसे प्रशिक्षण आगे बढ़ता है, जेनेरेटर विवेचक को धोखा देने वाला डेटा बनाने में बेहतर और बेहतर होता जाता है। छवि-संबंधी कार्यों के लिए CNN का उपयोग अक्सर GAN आर्किटेक्चर में किया जाता है। दूसरी ओर, उदाहरण के लिए, वैरिएबल ऑटोएन्कोडर्स (वीएई), तंत्रिका नेटवर्क (वेई और महमूद, 2020) पर आधारित एक अन्य प्रकार के जेनेरेटिव मॉडल हैं। जीएनएन के विपरीत, वीएई स्पष्ट रूप से डेटा के लिए संभाव्यता वितरण को मॉडल करता है और प्रशिक्षित करने के लिए परिवर्तनीय अनुमान तकनीकों का उपयोग करता है। इसके अलावा, पिक्सेल-आधारित मॉडल (सु एट अल., 2021) गहन शिक्षण पर आधारित जेनेरेटिव एआई फ्रेमवर्क हैं और आवर्ती तंत्रिका नेटवर्क या सीएनएन का उपयोग करके पिक्सेल-दर-पिक्सेल आधार पर छवियां उत्पन्न करते हैं।

डीप लर्निंग, विशेष रूप से कन्वेन्शनल नेटवर्क, कई जेनेरिक एआई मॉडल के विकास और सफलता में मौलिक उपकरण रहे हैं, विशेष रूप से वे जो छवि निर्माण पर केंद्रित हैं। इन तकनीकों ने कई मामलों में वास्तविक सामग्री से अप्रभेद्य सामग्री उत्पन्न करने के लिए मॉडलों की क्षमता में महत्वपूर्ण प्रगति की है।

उदाहरण के लिए, ChatGPT ने हमारे जीवन में आकर उन्हें बदल दिया है, और हमने शायद ही इस पर ध्यान दिया हो। कुछ लोगों ने इसके बारे में केवल सुना है, दूसरों ने अवसरों पर इसका उपयोग किया है, और हम में से कई पहले से ही परियोजनाओं पर काम कर रहे हैं और इस तकनीक के साथ मूल्य उत्पन्न कर रहे हैं। पाठ लिखने, एल्गोरिदम उत्पन्न करने, तर्कसंगत प्रस्तावों को संश्लेषित करने और उत्पन्न करने की इस उपकरण की क्षमता असाधारण है, लेकिन यह केवल हिमशैल का टिप है। इसका उपयोग पहले से ही ग्राहक सेवा, चिकित्सा डेटा विश्लेषण, निर्णय समर्थन और निदान आदि के लिए सिस्टम बनाने के लिए किया जा रहा है।

लेकिन चैटजीपीटी बाज़ार में अपनी जगह बनाने वाली पहली ऐसी प्रणाली है। कई अन्य मॉडल और उपकरण हैं: बार्ड, एक्सएलनेट, टी5, रोबर्टा, बेडरॉक, वू डाओ, निमो, एलएलएएम 2, आदि। इस तरह की तकनीक साक्ष्य और नैदानिक के आधार पर अधिक सटीक निदान प्रणालियों के विकास की अनुमति देगी। रिकॉर्ड, टेलीमेडिसिन का अधिक व्यापक उपयोग, पुराने रोगियों की उनके घरों में निगरानी के लिए प्रणाली आदि। इस संबंध में, चिकित्सा क्षेत्र के लिए बहुत रुचि के एल्गोरिदम का उपयोग किया जा रहा है।

विभिन्न स्तरों पर विकसित किए गए, जैसे ट्रांसफार्मर, ऑटोएनकोडर, गहरी ऊर्जा-आधारित जेनरेटिव मॉडल, प्रोटोटाइप के परिवर्तनीय अनुमान मॉडल, कारण अनुमान के साथ सुदृढीकरण सीखने की प्रणाली, कुछ नाम। एआई में हमारे रहने और काम करने के तरीके को मौलिक रूप से बदलने की क्षमता है, लेकिन यह गोपनीयता और सुरक्षा के मामले में महत्वपूर्ण नैतिक चुनौतियां भी पेश करता है, जिन्हें संबोधित करने की आवश्यकता है।

2.3. पारंपरिक एआई से जेनरेटिव एआई में बदलाव

कृत्रिम बुद्धिमत्ता (एआई) का इतिहास समृद्ध और आकर्षक है और बाकी सभी चीजों की तरह इसकी भी अलग-अलग व्याख्याएं और प्रमुख तत्व हो सकते हैं। यहां कुछ पारलौकिक तत्वों का सारांश दिया गया है जो हमें पहले कृत्रिम न्यूरॉन की उपस्थिति से लेकर पहले ट्रांसफार्मर के निर्माण और चैटजीपीटी के लोकप्रिय होने तक इस क्षेत्र के विकास का त्वरित विश्लेषण करने की अनुमति देता है:

1. कृत्रिम न्यूरॉन (1943): वॉरेन मैककुलोच और वाल्टर पिट्स ने "नर्वस एक्टिविटी में निहित विचारों का एक तार्किक कैलकुलस" प्रकाशित किया, जहां एक जैविक न्यूरॉन का एक सरलीकृत मॉडल, जिसे मैककुलोच-पिट्स न्यूरॉन के रूप में जाना जाता है, प्रस्तुत किया गया था। इस मॉडल को पहला कृत्रिम न्यूरॉन माना जाता है और यह कृत्रिम तंत्रिका नेटवर्क (मैककुलोच और पिट्स, 1943) का आधार है।
2. परसेप्ट्रॉन (1957-1958): फ्रैंक रोसेनब्लैट ने सिंगल-लेयर न्यूरल नेटवर्क के लिए सबसे सरल पर्यवेक्षित शिक्षण एल्गोरिदम, परसेप्ट्रॉन की शुरुआत की। हालांकि इसकी क्षमताएं सीमित थीं (उदाहरण के लिए, यह XOR समस्या को हल नहीं कर सका), इसने तंत्रिका नेटवर्क के भविष्य के विकास की नींव रखी (रोसेनब्लैट, 1958)।
3. एआई विटर (1970-1980): शुरुआती मॉडल की सीमाएं और कम्प्यूटेशनल क्षमता की कमी के कारण एआई अनुसंधान के लिए उत्साह और फंडिंग में गिरावट आई। इस अवधि के दौरान, तंत्रिका नेटवर्क एआई समुदाय का फोकस नहीं थे (मूर, 2006)।
4. बैकप्रॉपेगेशन (1986): रुमेलहार्ट, हिंटन और विलियम्स ने मल्टीलेयर न्यूरल नेटवर्क के प्रशिक्षण के लिए बैकप्रॉपेगेशन एल्गोरिदम की शुरुआत की (रुमेलहार्ट एट अल., 1986)। इस एल्गोरिदम ने तंत्रिका नेटवर्क में रुचि को पुनर्जीवित करना शुरू कर दिया। आवर्ती नेटवर्क, जो बैकप्रॉपेगेशन का उपयोग करते हैं, प्रत्येक शब्द पर व्यक्तिगत और क्रमिक रूप से ध्यान देते हैं। ये नेटवर्क क्रमिक रूप से संचालित होते हैं। इन नेटवर्कों में, प्रशिक्षण में प्रत्येक शब्द के प्रकट होने के क्रम पर विचार किया जाता है। 1980 के दशक के अंत और 1990 के दशक की शुरुआत में सामने आए आवर्ती नेटवर्क के संदर्भ में, डेटा के अनुक्रमों को संसाधित करने के लिए आरएनएन विकसित और बनाए गए थे। इन नेटवर्कों को प्रशिक्षित करने के लिए, बैकप्रॉपेगेशन थू टाइम तकनीक (बीपीटीटी) का उपयोग किया जाता है। आरएनएन समय के साथ एक "स्थिति" बनाए रख सकते हैं, जो उन्हें समय श्रृंखला भविष्यवाणी और प्राकृतिक भाषा प्रसंस्करण जैसे कार्यों के लिए उपयुक्त बनाता है। हालांकि, पारंपरिक आरएनएन को ग्रेडिएंट लुप्त होने और ग्रेडिएंट विस्फोट जैसी समस्याओं का सामना करना पड़ा। जैसे-जैसे आवर्तक नेटवर्क अनुच्छेद मूल्यांकन/पीढ़ी के माध्यम से आगे बढ़ते हैं, वे संदर्भ खो देते हैं, जो कि पाठ लंबा होने पर एक समस्या है। इस समस्या को अन्य नेटवर्कों द्वारा बैकप्रॉपेगेशन, लॉन्ग शॉर्ट-टर्म मेमोरी (LSTM) के साथ हल किया गया था, जो होक्रैडर और शिमडुबर (1997) द्वारा पेश किया गया था, जो लुप्त हो रही ग्रेडिएंट समस्या से निपटने के लिए डिज़ाइन किए गए RNN का एक विशेष संस्करण था। LSTM दीर्घकालिक निर्भरता सीख सकते हैं और ट्रांसफार्मर के आगमन तक प्राकृतिक भाषा प्रसंस्करण और अन्य अनुक्रमिक कार्यों में कई प्रगति के केंद्र में रहे हैं। इन नेटवर्कों में सीखने के प्रत्येक चरण में, गणितीय संचालन शामिल होते हैं जो पैराग्राफ की शुरुआत में जो सीखा गया था उसे भूलने से रोकते हैं। हालांकि, इन नेटवर्कों में अपने प्रशिक्षण को समानांतर करने की असंभवता से संबंधित अन्य समस्याएं हैं, जिससे बड़े मॉडल का निर्माण व्यावहारिक रूप से असंभव हो जाता है। इस प्रकार के नेटवर्क में, सभी प्रशिक्षण अनुक्रमिक होते हैं।
5. डीप लर्निंग और कन्वेन्शनल न्यूरल नेटवर्क्स (कन्वेन्शनल न्यूरल नेटवर्क्स, सीएनएन, 2012): 2012 में, एलेक्स क्रिजेव्स्की, इलिया सुतस्केवर और जेफ्री हिंटन ने एक जटिल तंत्रिका नेटवर्क प्रस्तुत किया जिसने इमेजनेट छवि वर्गीकरण चुनौती को बड़े अंतर से जीता।

(क्रिजेव्स्की एट अल., 2012)। इस घटना ने तंत्रिका नेटवर्क में नए सिरे से रुचि के साथ "डीप लर्निंग" युग की शुरुआत को चिह्नित किया जो 2006 में लोकप्रिय होना शुरू हुआ, जिस वर्ष "एआई विंटर" का अंत शुरू हुआ। ये नेटवर्क विशेष रूप से वर्गीकरण और छवि प्रसंस्करण के लिए उपयुक्त हैं, परंतु में संरचित हैं और तीन मुख्य घटकों में व्यवस्थित हैं: संकेंद्रित परतें, सक्रियण परतें और क्लस्टरिंग परतें। कनवल्शनल परतें फिल्टर या कर्नेल के माध्यम से छवियों से महत्वपूर्ण विशेषताओं को निकालने के लिए जिम्मेदार हैं। फिल्टर छवि पर ग्लाइड होते हैं, विशिष्ट किनारों, आकृतियों या पैटर्न का पता लगाने के लिए गणितीय संचालन करते हैं। सक्रियण परतों में, गैर-रैखिकता जोड़ने और जटिल संबंधों को सीखने के लिए नेटवर्क की क्षमता को बढ़ाने के लिए सक्रियण फंक्शन (जैसे ReLU) लागू किए जाते हैं। अंत में, क्लस्टरिंग परतें छवि प्रतिनिधित्व के आकार को कम करती हैं, मापदंडों की संख्या को कम करती हैं और नेटवर्क को प्रसंस्करण में अधिक कुशल बनाती हैं। जैसे-जैसे जानकारी इन परतों से गुजरती है, सीएनएन अधिक अमूर्त और जटिल विशेषताओं को पहचानना सीखता है, जिससे वस्तुओं, लोगों या किसी अन्य चीज़ की पहचान की जा सकती है जिसे पहचानने की आवश्यकता होती है। इस क्षेत्र में बड़े पैमाने पर सूचना प्रसंस्करण प्रणालियों के निर्माण और समानांतर परियोजनाओं के विकास के लिए किए गए कार्यों ने आज उपयोग किए जाने वाले ट्रांसफार्मर को जन्म दिया है (गेरोन, 2022)।

6. **ट्रांसफार्मर (2017):** वासवानी एट अल. पेपर "अटेंशन इज़ ऑल यू नीड" में ट्रांसफॉर्मर आर्किटेक्चर की शुरुआत की। ध्यान तंत्र पर आधारित यह वास्तुकला, प्राकृतिक भाषा प्रसंस्करण कार्यों के लिए अत्यधिक प्रभावी साबित हुई और जीपीटी सहित कई बाद के मॉडलों का आधार बन गई। LSTM और गहन शिक्षण जैसे बैकप्रॉपेगेशन मॉडल की तुलना में इन नेटवर्कों का लाभ सीखने को समानांतर करने की उनकी क्षमता में निहित है। आवर्ती तंत्रिका नेटवर्क (आरएनएन) या दृढ़ तंत्रिका नेटवर्क (सीएनएन) के विपरीत, ट्रांसफार्मर डेटा की एक निश्चित अनुक्रमिक या स्थानिक संरचना पर भरोसा नहीं करते हैं, जो उन्हें समानांतर में जानकारी संसाधित करने और डेटा में दीर्घकालिक निर्भरता को पकड़ने की अनुमति देता है। इस संबंध में, शब्द एम्बेडिंग की अवधारणा, जो ट्रांसफार्मर सीखने का आधार है, उल्लेख के लायक है। यह पाठ वेक्टरिकरण के लिए प्राकृतिक भाषा प्रसंस्करण के अंतर्गत एक तकनीक है। ट्रांसफॉर्मर एक पाठ में सभी शब्दों का समानांतर में विश्लेषण करना संभव बनाते हैं और इस तरह, नेटवर्क का प्रसंस्करण और निर्माण तेज होता है। जैसा कि ऊपर बताया गया है, यह ध्यान दिया जाना चाहिए कि इन नेटवर्कों को भारी मात्रा में डेटा और बहुत शक्तिशाली हार्डवेयर की आवश्यकता होती है। उदाहरण के लिए, GPT-3 को 175 बिलियन पैरामीटर और 45 TB डेटा के साथ बनाया गया था, और GPT-4 को 1000,000,000,000,000 मिलियन पैरामीटर और TB की एक बड़ी लेकिन अज्ञात संख्या के साथ बनाया गया था।
7. **जीपीटी और चैटजीपीटी (2018-2020):** OpenAI ने जेनरेटिव प्री-ट्रैंड ट्रांसफार्मर (GPT) मॉडल श्रृंखला लॉन्च की। 2019 में जारी GPT-2 ने सुसंगत और यथार्थवादी पाठ उत्पन्न करने की प्रभावशाली क्षमता का प्रदर्शन किया। 2020 में जारी GPT-3 ने इन क्षमताओं को और बढ़ाया और ChatGPT (अब्दुल्ला एट अल., 2022) जैसे चैट-आधारित अनुप्रयोगों को लोकप्रिय बनाया। इस उत्पाद में प्रभावशाली प्रवेश शक्ति है, जो 2 महीने में 100 मिलियन उपयोगकर्ताओं तक पहुंच गया है, जबकि इंस्टाग्राम जैसे अन्य प्लेटफार्मों को उपयोगकर्ताओं की समान संख्या तक पहुंचने में 26 महीने लगे हैं (फेसबुक 54 महीने या ट्विटर 65 महीने)।

इन सात तत्वों को निष्कर्षों और तथ्यों की एक कालानुक्रमिक सूची के रूप में माना जा सकता है जो एआई के विकास को उसकी उत्पत्ति से लेकर आज जेनरेटिव एआई के रूप में जाना जाता है।

3. बड़े भाषा मॉडल

इस खंड में, हम बड़े भाषा मॉडल (एलएलएम) पेश करते हैं। एक सामान्य परिभाषा के बाद, चयनित सफलता की कहानियों पर चर्चा की जाती है (इटोह और ओकाडा, 2023)। एक विस्तृत अध्ययन करने के बजाय, इरादा उन एलएलएम को उजागर करना है जो वर्तमान में सबसे अधिक प्रासंगिक हैं और उनके विशिष्ट पहलुओं पर टिप्पणी करना है।

3.1. बड़े भाषा मॉडल को परिभाषित करना

बड़े भाषा मॉडल कृत्रिम बुद्धिमत्ता मॉडल हैं जिन्हें प्राकृतिक भाषा को संसाधित करने और उत्पन्न करने के लिए डिज़ाइन किया गया है। इन मॉडलों को बड़ी मात्रा में पाठ पर प्रशिक्षित किया जाता है, जो उन्हें अनुवाद, पाठ निर्माण और प्रश्न उत्तर जैसे जटिल भाषा-संबंधित कार्य करने में सक्षम बनाता है।

ट्रांसफार्मर वास्तुकला में प्रगति और उपलब्ध कम्प्यूटेशनल क्षमता में वृद्धि के कारण एलएलएम बड़े पैमाने पर लोकप्रिय हो गए हैं। इन मॉडलों की विशेषता कई पैरामीटर हैं, जो उन्हें मानव भाषा की जटिलता को पकड़ने और मॉडल करने की अनुमति देते हैं।

बड़े भाषा मॉडल ने प्राकृतिक भाषा प्रसंस्करण के क्षेत्र में क्रांति ला दी है और इसमें कई विशिष्ट विशेषताएं हैं। ये एलएलएम के सबसे विशिष्ट तत्व हैं:

- बड़ी संख्या में पैरामीटर: एलएलएम, जैसा कि नाम से पता चलता है, बड़े हैं। उदाहरण के लिए, GPT-3, सबसे प्रसिद्ध एलएलएम में से एक, में 175 बिलियन पैरामीटर हैं। मापदंडों की यह विशाल संख्या उन्हें मानव भाषा की जटिलता को पकड़ने और मॉडल करने की अनुमति देती है।
- बड़ा कोष प्रशिक्षण: एलएलएम को विशाल डेटासेट पर प्रशिक्षित किया जाता है जो इंटरनेट के बड़े हिस्से, जैसे किताबें, लेख और वेबसाइटों तक फैला हुआ है। इससे उन्हें भाषा और विविध विषयों का व्यापक सामान्य ज्ञान प्राप्त करने की अनुमति मिलती है।
- पाठ निर्माण क्षमता: एलएलएम ऐसे पाठ उत्पन्न कर सकते हैं जो सुसंगत, धाराप्रवाह और, कई मामलों में, मानव-लिखित पाठ से अप्रभेद्य हैं। वे निबंध लिख सकते हैं, सवालों के जवाब दे सकते हैं, कविता बना सकते हैं और बहुत कुछ कर सकते हैं।
- सीखने का स्थानांतरण: एक बार बड़े कोष पर प्रशिक्षित होने के बाद, एलएलएम को अपेक्षाकृत कम मात्रा में कार्य-विशिष्ट डेटा के साथ विशिष्ट कार्यों के लिए "ट्यून" किया जा सकता है। इसे "ट्रांसफर लर्निंग" के रूप में जाना जाता है और यही एक कारण है कि एलएलएम इतने बहुमुखी हैं।
- ट्रांसफार्मर आर्किटेक्चर का उपयोग: अधिकांश आधुनिक एलएलएम, जैसे जीपीटी और बीईआरटी, एक ट्रांसफार्मर आर्किटेक्चर पर आधारित हैं, जो डेटा में संबंधों को पकड़ने के लिए ध्यान तंत्र का उपयोग करता है।
- मल्टीमॉडल क्षमता: जबकि एलएलएम पारंपरिक रूप से पाठ पर ध्यान केंद्रित करते हैं, हाल के मॉडल मल्टीमॉडल क्षमताओं की खोज कर रहे हैं, जिसका अर्थ है कि वे एक साथ पाठ और छवियों जैसे कई प्रकार के डेटा को समझ और उत्पन्न कर सकते हैं।
- कार्यों में सामान्यीकरण: विशिष्ट वास्तुशिल्प परिवर्तनों की आवश्यकता के बिना, एक एलएलएम अनुवाद से लेकर पाठ निर्माण से लेकर प्रश्न उत्तर तक कई प्रकार के कार्य कर सकता है। अक्सर, मॉडल को सही संकेत या प्रोत्साहन प्रदान करने की आवश्यकता होती है।
- नैतिक चुनौतियाँ और पूर्वाग्रह: क्योंकि एलएलएम को इंटरनेट डेटा पर प्रशिक्षित किया जाता है, वे उस डेटा में मौजूद पूर्वाग्रहों को प्राप्त कर सकते हैं और उन्हें कायम रख सकते हैं। इससे इन मॉडलों के नैतिक उपयोग और इन पूर्वाग्रहों को संबोधित करने और कम करने की आवश्यकता के बारे में चिंताएं और चर्चाएं शुरू हो गई हैं।

इसी तरह, विभिन्न एलएलएम मॉडलों की वृद्धि समय के साथ तेजी से बढ़ रही है, प्रत्येक एलएलएम डेवलपर विभिन्न आवश्यकताओं और संसाधन स्तरों को पूरा करने के लिए विभिन्न प्रकार के अनुप्रयोगों पर काम कर रहा है। इसमें कई मापदंडों वाले बड़े मॉडल और कम मापदंडों वाले छोटे मॉडल दोनों शामिल हैं। OpenAI और Google जैसी कंपनियां लगातार बढ़ती संख्या में मापदंडों के साथ मॉडल विकसित कर रही हैं, जहां ये मॉडल बहुत विविध और जटिल कार्यों से निपटने में सक्षम हैं और अक्सर अनुप्रयोगों की एक विस्तृत श्रृंखला में उत्कृष्ट प्रदर्शन करते हैं। हालांकि, META कंपनी के Llama 2 मॉडल के मामले ने मॉडल के विभिन्न पैरामीटरयुक्त संस्करणों के कारण हंगामा पैदा कर दिया है और इसे कम हार्डवेयर प्रदर्शन वातावरण में चलाने में सक्षम होने के लिए अनुकूलित किया जा रहा है। निम्नलिखित तालिका 1 इनमें से कुछ मॉडलों के संबंध में डेटा दिखाती है:

तालिका 1. एलएलएम मॉडल।

मॉडल नाम	कंपनी	पैरामीटर्स की संख्या	प्रशिक्षण सूचना मात्रा	वेबसाइट
जीपीटी-3	ओपनएआई	175 अरब	लगभग। 570GB (वेबटेक्स्ट, किताबें, अन्य)	https://openai.com/
बर्ट-बड़े	गूगल	340 मिलियन	विकिपीडिया + बुककोर्पस	https://research.google/pubs/pub45413/
T5 (टेक्स्ट-टू-टेक्स्ट ट्रांसफार्मर)	गूगल एआई	संस्करण के आधार पर भिन्न होता है (60 मिलियन से 11 बिलियन तक)	C4 (सामान्य क्रॉल)	https://ai.googleblog.com/2020/02/खोज-ट्रांसफर-लर्निंग-साथ-t5.एचटीएमएल
रोबर्टा	फेसबुक एआई	संस्करण के आधार पर भिन्न होता है (रोबर्टा-लार्ज के लिए 355 मिलियन तक)	WebText, OpenWebText और अन्य सहित कई डेटासेट	https://ai.meta.com/blog/रोबर्टा-ए-अनुकूलित-स्व-प्रशिक्षण-के-लिए-विधि-पर्यवेक्षित-एनएलपी-सिस्टम/
एक्सएलनेट	गूगल/सीएमयू	340 मिलियन तक	विकिपीडिया और बुककोर्पस सहित विभिन्न डेटासेट	https://github.com/zihangdai/xlnet
क्लिप	ओपनएआई	281 मिलियन	इंटरनेट छवियाँ + संबद्ध पाठ	https://openai.com/research/क्लिप
DALL-ई	ओपनएआई	लगभग। 12 बिलियन (जीपीटी-3 पर आधारित)	छवियाँ और पाठ विवरण	https://openai.com/research/से-ई
कॉल 2	मेटा एआई	1000 करोड़	1000 मिलियन शब्द	https://github.com/फेसबुकरिसच/लामा
वू दाओ	बीजिंग आर्टिफिशियल इंटेलिजेंस अकादमी (बीएएआई)	1.75 ट्रिलियन	4.9 टेराबाइट टेक्स्ट और कोड	https://www.baai.ac.cn/
लाएमडीए	गूगल एआई	137 अरब	गूगल डेटाबेस	https://bard.google.com/
हथेली	गूगल एआई	540 अरब	गूगल डेटाबेस	https://bard.google.com/

3.2. बड़े भाषा मॉडल के प्रकार

एलएलएम के कुछ प्रकार और उनकी प्रमुख विशेषताओं और संभावनाओं की पहचान इस प्रकार है:

1. ऑटोरेग्रेसिव मॉडल:

- जीपीटी (जेनेरेटिव प्री-ट्रैंड ट्रांसफार्मर): OpenAI द्वारा विकसित, GPT एक ऑटोरेग्रेसिव मॉडल है जो शब्द-दर-शब्द आधार पर टेक्स्ट उत्पन्न करता है। इसके कई संस्करण हैं, जिनमें GPT-3 सबसे नवीनतम और 2021 में अंतिम अपडेट के समय उन्नत है।

2. द्विदिश मॉडल वर्गीकरण:

- **BERT** (ट्रांसफॉर्मर्स से द्विदिश एनकोडर प्रतिनिधित्व): Google द्वारा विकसित, BERT एक मॉडल है जिसे द्विदिश रूप से प्रशिक्षित किया जाता है, जिसका अर्थ है कि यह एक वाक्य में शब्द के बाएँ और दाएँ दोनों पक्षों के संदर्भ पर विचार करता है। यह पढ़ने की समझ और पाठ वर्गीकरण कार्यों के लिए विशेष रूप से उपयोगी है।

3. अनुक्रम-से-अनुक्रम मॉडल:

- **T5** (टेक्स्ट-टू-टेक्स्ट ट्रांसफर ट्रांसफार्मर): Google द्वारा विकसित, T5 सभी भाषा प्रसंस्करण कार्यों को टेक्स्ट-टू-टेक्स्ट रूपांतरण समस्या के रूप में व्याख्या करता है। उदाहरण के लिए, "अनुवाद", "सारांश" और "प्रश्न उत्तर" को टेक्स्ट इनपुट से टेक्स्ट आउटपुट में परिवर्तन के रूप में नियंत्रित किया जाता है।
- **BART** (द्विदिशात्मक और ऑटो-प्रतिगामी ट्रांसफार्मर): Facebook AI द्वारा विकसित, BART पीढ़ी और समझ के कार्यों के लिए BERT और GPT की सुविधाओं को जोड़ता है।

4. मल्टीमॉडल मॉडल:

- **सीएलआईपी** (विपरीत भाषा-छवि पूर्व-प्रशिक्षण) और **DALL·ई**: Open-nAI द्वारा विकसित, ये मॉडल कंप्यूटर विज्ञान और प्राकृतिक भाषा प्रसंस्करण को जोड़ते हैं। जबकि CLIP प्राकृतिक भाषा के संदर्भ में छवियों को समझने में सक्षम है, DALL-E पाठ्य विवरण से छवियाँ उत्पन्न करता है।
- **वू डीएओबीजिंग एकेडमी ऑफ आर्टिफिशियल इंटेलिजेंस** द्वारा बनाया गया एक गहन शिक्षण भाषा मॉडल है जिसमें मल्टीमॉडलिटी विशेषताएं हैं। इसे टेक्स्ट और छवि डेटा दोनों पर प्रशिक्षित किया गया है, इसलिए यह दोनों कार्यों से निपट सकता है। इसे कई मापदंडों (1.75 ट्रिलियन) के साथ प्रशिक्षित किया गया था।

4. जनरेटिव एआई के क्षेत्र में प्रासंगिक एल्गोरिदम

जनरेटिव आर्टिफिशियल इंटेलिजेंस मुख्य रूप से अप्रशिक्षित शिक्षण तकनीकों पर आधारित है। यह पर्यवेक्षित शिक्षण मॉडल से भिन्न है जिन्हें अपने प्रशिक्षण चरण को व्यवस्थित करने के लिए लेबल किए गए डेटा की आवश्यकता होती है। जेनेरेटिव एडवरसैरियल नेटवर्क (जीएएन) या वैरिएबल ऑटोएनकोडर (वीएई) जैसे अनपर्यवेक्षित शिक्षण मॉडल में ऐसी लेबलिंग बाधाओं की अनुपस्थिति, बड़े और अधिक विषम डेटासेट के उपयोग की अनुमति देती है, जिसके परिणामस्वरूप ऐसे सिमुलेशन होते हैं जो वास्तविक दुनिया के परिदृश्यों की बारीकी से नकल करते हैं (गुडफेलो एट अल., 2016)। इन जेनेरेटिव मॉडल का मुख्य लक्ष्य आंतरिक संभाव्यता वितरण $P(x)$ को समझना है जिसका डेटासेट पालन करता है। एक बार जब मॉडल सक्षम रूप से प्रशिक्षित हो जाता है, तो इसमें डेटा 'x' के नए नमूने उत्पन्न करने की क्षमता होती है जो सांख्यिकीय रूप से मूल डेटासेट के अनुरूप होते हैं। ये संश्लेषित नमूने सीखे गए वितरण से लिए गए हैं, इस प्रकार स्वास्थ्य देखभाल, वित्त और रचनात्मक उद्योगों (बैडू-अणु और ओवसु अंसाह, 2023) जैसे विभिन्न क्षेत्रों में जेनेरेटिव मॉडल की प्रयोज्यता का विस्तार होता है।

जेनेरिक एआई के परिदृश्य में विशेष रूप से दो प्रमुख आर्किटेक्चर का प्रभुत्व है: जेनेरिक एडवरसैरियल नेटवर्क (जीएएन) और जेनेरिक प्री-प्रशिक्षित ट्रांसफार्मर (जीपीटी)। GAN दोहरा तंत्रिका नेटवर्क के माध्यम से संचालित होते हैं, जिसमें एक जनरेटर और एक विवेचक शामिल होता है। जनरेटर सिंथेटिक डेटा उत्पन्न करता है, जबकि विवेचक इस डेटा की प्रामाणिकता का मूल्यांकन करता है। यह प्रतिकूल तंत्र लगातार तब तक जारी रहता है जब तक कि विवेचक वास्तविक और सिंथेटिक संपत्तियों के बीच अंतर नहीं कर पाता, इस प्रकार उत्पन्न सामग्री को मान्य करता है (हू, 2022; जोवानोविक, 2022)। GAN का उपयोग मुख्य रूप से ग्राफिक्स, भाषण निर्माण और वीडियो संश्लेषण (Hu, 2022) में अनुप्रयोगों के लिए किया जाता है।

विभिन्न आर्किटेक्चर जैसे जीएएन, जीपीटी मॉडल और विशेष रूप से वैरिएबल ऑटोएनकोडर्स (वीएई) से बहुमुखी योगदान मिलता है। उत्तरार्द्ध न केवल जेनेरेटिव मॉडलिंग का एक संभाव्य दृष्टिकोण प्रदान करता है, बल्कि अंतर्निहित जटिल डेटा की अधिक लचीली समझ की भी अनुमति देता है।

वितरण (किंगमा और वेलिंग, 2013)। इसके अलावा, मल्टीमॉडल सिस्टम के आगमन ने, जो एक ही वास्तुकला में विविध डेटा प्रकारों का सामंजस्य स्थापित करता है, जटिल पैटर्न पहचान और डेटा संश्लेषण की क्षमता को फिर से परिभाषित किया है। यह विकास बढ़ती जटिलता और बारीकियों को दर्शाता है जिसे जेनेरिक एआई पकड़ सकता है।

वीई और मल्टीमॉडल सिस्टम के बीच की बातचीत जेनेरेटिव एआई की अगली सीमा का उदाहरण है। यह न केवल अधिक सटीकता का वादा करता है, बल्कि ऐसे परिणाम उत्पन्न करने की क्षमता भी देता है जो संदर्भ में समृद्ध हैं और विभिन्न प्रकार के डेटा के बीच भिन्नताओं से अवगत हैं। इस संदर्भ में, जेनेरिक एआई एक मात्र डेटा-जेनेरेटिंग टूल से एक प्रगतिशील अंतःविषय मंच के रूप में विकसित हुआ है जो विभिन्न उद्योगों में बारीकियों को समझने और जटिल समस्याओं को हल करने में सक्षम है (जोरान, 2021)।

4.1. स्टोकेस्टिक अव्यक्त अभिनेता-आलोचक: एक अव्यक्त चर मॉडल के साथ गहन सुदृढीकरण सीखना

डीप रीइन्फोर्समेंट लर्निंग (आरएल) एल्गोरिदम छवि अवलोकनों से सीधे सीखने के लिए उच्च क्षमता वाले नेटवर्क का लाभ उठाता है। हालाँकि, ये उच्च-आयामी अवलोकन स्थान चुनौतियाँ पेश करते हैं क्योंकि नीति को अब दो समस्याओं का समाधान करना होगा: प्रतिनिधित्व सीखना और कार्य सीखना।

यह पेपर स्टोकेस्टिक लेटेंट एक्टर-क्रिटिक (एसएलएसी) एल्गोरिदम का प्रस्ताव करता है, जो उच्च-आयामी छवि इनपुट से सीधे जटिल निरंतर नियंत्रण कार्यों के लिए नीतियों को सीखने के लिए एक उच्च-प्रदर्शन, उच्च दक्षता वाली आरएल विधि है। एसएलएसी विशेष रूप से एक स्टोकेस्टिक अव्यक्त स्थिति की शुरुआत के माध्यम से बड़े अवलोकन स्थानों द्वारा उत्पन्न चुनौतियों का समाधान करता है जो निर्णय लेने के लिए प्रत्येक स्थिति से प्रासंगिक जानकारी का सारांश देता है।

इस तरह, एसएलएसी अभिनेता-आलोचक राज्य प्रतिनिधित्व सीखने और सबसे उपयुक्त कार्रवाई निर्धारित करने की सामान्य समस्या को दो विशेष प्रक्रियाओं में विभाजित करता है। एक ओर, एनकोडर मॉड्यूल अवलोकन जानकारी को कार्य के लिए उपयोगी अव्यक्त प्रतिनिधित्व में संपीड़ित करने के लिए जिम्मेदार है। दूसरी ओर, पारंपरिक अभिनेता-आलोचक जटिल मूल छवि इनपुट को सीधे संसाधित करने की आवश्यकता के बिना, स्थितियों का मूल्यांकन करने और सर्वोत्तम कार्रवाई का चयन करने के लिए इस अव्यक्त स्थिति का उपयोग करता है। एसएलएसी एक एकल एकीकृत ढांचे में आरएल के साथ स्टोकेस्टिक अनुक्रमिक मॉडल को एकीकृत करने के लिए एक अभिनव और मजबूत तकनीक का प्रस्ताव करता है। यह एक संक्षिप्त अव्यक्त प्रतिनिधित्व बनाकर पूरा किया जाता है, जिसे बाद में मॉडल द्वारा उत्पन्न अव्यक्त स्थान के भीतर आरएल का संचालन करने के लिए उपयोग किया जाता है। प्रायोगिक परीक्षणों से संकेत मिलता है कि यह दृष्टिकोण अंतिम परिणामों और नमूनों के कुशल उपयोग के मामले में मॉडल-मुक्त और मॉडल-आधारित दोनों प्रतिस्पर्धियों के प्रदर्शन से बेहतर है, खासकर विभिन्न श्रेणियों में।

जटिल छवि-आधारित नियंत्रण कार्य।

आरएल के लिए जेनेरेटिव पर्यावरण मॉडल के संदर्भ में, ये निष्कर्ष अव्यक्त प्रतिनिधित्व सीखने के महत्व पर जोर देते हैं जो छवियों से सुदृढीकरण सीखने में तेजी ला सकता है, जो मशीन लर्निंग और जेनेरेटिव आर्टिफिशियल इंटेलिजेंस के क्षेत्र में एक महत्वपूर्ण प्रगति का प्रतिनिधित्व करता है।

पारंपरिक गहन सुदृढीकरण सीखने (डीआरएल) प्रतिमानों में, जैसे कि क्यू-लर्निंग या नीति ग्रेडिएंट, उद्देश्य फंक्शन को अक्सर अपेक्षित प्रदर्शन को अधिकतम करने के लिए अनुकूलित किया जाता है जे(में) के रूप में परिभाषित:

$$J(\theta) = E_{\tau \sim \pi_\theta} \left[\sum_{t=0}^{\infty} \gamma^t R(z_t, a_t) \right]$$

जहां τ एक प्रक्षेपवक्र का प्रतिनिधित्व करता है और γ छूट कारक है।

एक अव्यक्त चर मॉडल के साथ डीआरएल के संदर्भ में, एक अव्यक्त स्थान z का समावेश अमूर्तता की एक अतिरिक्त परत जोड़ता है। विशेष रूप से, राज्य s को एक अव्यक्त चर z द्वारा प्रतिस्थापित या संवर्धित किया जाता है, जो बदले में राज्य का एक कार्य हो सकता है जेड = एफ(एस) या अप्रशिक्षित डेटा से सीखा जा सकता है।

$$J(\theta, \phi) = E_{\tau, z \sim \pi_{\theta, \phi}} \left[\sum_{t=0}^{\infty} \gamma^t R(z_t, a_t) \right]$$

जहाँ ϕ अव्यक्त चर मॉडल के पैरामीटर हैं और नीति π अब न केवल वातानुकूलित है एस लेकिन z पर भी। इस दृष्टिकोण की सफलता सीखे गए अव्यक्त स्थान की गुणवत्ता में निहित है और यह इष्टतम निर्णय लेने के लिए आवश्यक बारीकियों को कितनी अच्छी तरह पकड़ता है। यह अनुसंधान की एक आशाजनक दिशा है, और यहां की प्रगति संभावित रूप से डीआरएल में जटिल, उच्च-आयामी, आंशिक रूप से अवलोकन योग्य निर्णय लेने की समस्याओं से निपटने के तरीके में क्रांतिकारी बदलाव ला सकती है।

4.2. वीडियो: डिफ्यूजन मॉडल के साथ हाई-डेफिनिशन वीडियो जेनरेशन

स्थानिक और लौकिक सुपर-रिज़ॉल्यूशन वीडियो मॉडल की अनुक्रमिक संरचना एक सरल वास्तुकला को प्रदर्शित करती है, क्योंकि यह न केवल पिक्सेल-स्तरीय निष्ठा को बढ़ाती है, बल्कि उत्पन्न फ्रेमों के बीच अस्थायी सुसंगतता भी सुनिश्चित करती है (सिमोनियन और ज़िसरमैन, 2014; जी एट अल।, 2018)। यह पहले उन अनुप्रयोगों के लिए विशेष रूप से फायदेमंद है जिनके लिए गतिशील दृश्य प्रतिपादन और द्रव गति प्रतिपादन की आवश्यकता होती है; पारंपरिक छवि-आधारित जेनरेटिव मॉडल उन शर्तों को पूरा नहीं करते हैं (जियांग एट अल., 2018)। इसके अलावा, सिस्टम की टेक्स्ट-टू-हाई-डेफिनिशन वीडियो आउटपुट की ओर बढ़ने की क्षमता, जो इसकी पूरी तरह से दृढ़ वास्तुकला द्वारा संभव बनाई गई है, स्थिर छवि पीढ़ी पर एक महत्वपूर्ण प्रगति का प्रतिनिधित्व करती है। पारंपरिक जेनरेटर मॉडल में, वीडियो निर्माण के लिए कम्प्यूटेशनल जटिलता अक्सर खराब होती है, जिससे उच्च-परिभाषा परिणाम कम्प्यूटेशनल रूप से अव्यवहार्य हो जाते हैं (वॉड्रिक एट अल., 2016)। इसके विपरीत, मॉड्यूलर छवि-वीडियो कैस्केड संरचना अधिक कुशल संसाधन आवंटन की सुविधा प्रदान करती है, जिससे काफी कम समय में उच्च गुणवत्ता वाले वीडियो नमूने को सक्षम किया जा सकता है (तुल्यकोव एट अल., 2018)।

मौजूदा छवि-वीडियो वास्तुकला में प्रसार मॉडल का एकीकरण प्रौद्योगिकियों का एक सम्मोहक संलयन उत्पन्न करता है जो इसकी उत्पादक क्षमताओं को बढ़ाने में मदद कर सकता है। 0 से 1 की सीमा के साथ अस्थायी घटक को पेश करके, प्रसार मॉडल उत्पन्न वीडियो को अस्थायी रूप से सुसंगत स्तर की स्टोकेस्टिसिटी और गैन्जुलैरिटी प्रदान करता है, जिससे वीएई (किंगमा एंड वेलिंग, 2013; हो एट अल) के उच्च-स्तरीय प्रतिनिधित्व को समृद्ध किया जाता है। (2020)।

इस हाइब्रिड मॉडल को वैचारिक रूप से दो चरणों में संचालित होते हुए देखा जा सकता है: पहला, वीएई एनकोडर(एक्स) एनकोडर फ़ंक्शन इनपुट x से एक गुप्त चर z की गणना करता है। यह z बाद में प्रसार मॉडल के लिए प्रारंभिक शर्त के रूप में कार्य करता है, जो अनिवार्य रूप से इसके समीकरणों में $\$x\$$ की भूमिका को पूरा करता है। अगला, एक समय-निर्भर डीनोइज़िंग फ़ंक्शन $डी_{\theta}(साथ_{\theta})$, पेश किया गया है, जो उच्च-स्तरीय प्रतिनिधित्व को परिष्कृत करता है-

समय के साथ वीएई की स्थिति। यह एक संश्लेषण क्रिया में परिणत होता है एक्स^न (जेड, टी) = डिकोडर(साथ) + डी_θ(साथ_θ), इस प्रकार

एक समृद्ध, अस्थायी रूप से सुचारु आउटपुट का आयोजन।

प्रसार मॉडल के लिए उद्देश्य फ़ंक्शन $L(x)$ तब बन जाता है:

$$L(x) = \mathbb{E}_{\theta} \left[\left\| \hat{z}_{\theta}(साथ_{\theta}, \lambda_{\theta}) - z \right\|_2^{0,1} \right] + \mathbb{E}_{\theta} \left[\left\| \hat{z}_{\theta}(साथ_{\theta}, \lambda_{\theta}) - z \right\|_2 \right]$$

यहाँ $\hat{z}_{\theta}(साथ_{\theta}, \lambda_{\theta}) = डी_{\theta}(साथ_{\theta}) + डी_{\theta}(साथ_{\theta}, \lambda_{\theta})$ ।

इस तरह, प्रसार मॉडल समय के साथ वीएई द्वारा उत्पन्न उच्च-स्तरीय अभ्यावेदन को समायोजित करना सीखता है, इस प्रकार एक समृद्ध, अस्थायी रूप से सुचारु जेनरेटर मॉडल प्रदान करता है जो दोनों आर्किटेक्चर की ताकत का लाभ उठाता है।

4.3. मोशन डिफ्यूज़: डिफ्यूज़न मॉडल के साथ टेक्स्ट-संचालित मानव मोशन जेनरेशन

पाठ-आधारित मानव गति निर्माण के लिए मोशनडिफ्यूज़ आर्किटेक्चर में, हानि कार्यों के डिज़ाइन पर विशेष ध्यान दिया जाना चाहिए जो मॉडल में एम्बेडेड ध्यान संरचना के साथ संरेखित होते हैं। यह देखते हुए कि मोशन डिफ्यूज़ टेक्स्ट और मोशन स्पेस के बीच संबंधों को व्यवस्थित करने के लिए ध्यान तंत्र का उपयोग करता है, दो प्रमुख हानि फ़ंक्शन महत्वपूर्ण महत्व के हो सकते हैं।

ग्लाइड मॉडल जैसे विशेष हानि कार्यों को शामिल करने से मोशनडिफ्यूज़ ढांचे को और अधिक परिष्कृत किया जा सकता है, विशेष रूप से पाठ-आधारित मानव गति पीढ़ी के लिए इसके अद्वितीय दृष्टिकोण के साथ। मोशनडिफ्यूज़ में, समीकरण द्वारा निर्देशित स्टोकेस्टिक शोर शब्द का समावेश

$\alpha_t = 1 - \beta_t$, $\bar{\alpha}_t = \sum_{s=0}^t \alpha_s$, हानि फ़ंक्शन नवाचार के लिए एक दिलचस्प अवसर प्रदान करता है।

मूल मोशनडिफ्यूज़ पद्धति में, मॉडल इसके बजाय शोर शब्द की भविष्यवाणी करने पर ध्यान केंद्रित करता है का एक्सप्लैट, ग्लाइड फ़्रेमवर्क के अनुरूप (निकोल एट अल., 2021)। इसे माध्य वर्ग त्रुटि (MSE) हानि फ़ंक्शन द्वारा कैप्चर किया जाता है:

$$L_{\text{MSE}} = \sum_{t=0}^T \mathbb{E} \left[\left\| \frac{1}{\sqrt{\alpha_t}} \left(x_t - \theta \left(\sum_{s=0}^{t-1} \alpha_s \right) \right) \right\|^2 \right]$$

निम्नलिखित विशेष हानि कार्यों के एकीकरण पर विचार करें:

तौर-तरीकों के बीच ध्यानात्मक संरेखण का नुकसान

यह हानि फ़ंक्शन सुनिश्चित करता है कि पाठ और गति स्थानों के बीच ध्यान वितरण संरेखित हैं। चूंकि ध्यान स्कोर α_t और α_m मीटर पर क्रमशः पाठ और गति एनकोडर से प्राप्त होते हैं, नुकसान को दोनों के बीच कुल्बैक-लीबलर विचलन के रूप में परिभाषित किया जा सकता है:

$$L_{\text{attention}} = KL(a_t \| a_m)$$

यह हानि मॉडल को पाठ और गति डोमेन दोनों में शब्दार्थ रूप से समान क्षेत्रों पर ध्यान देने के लिए प्रोत्साहित करती है, इस प्रकार तौर-तरीकों के बीच बेहतर संरेखण को प्रोत्साहित करती है।

पाठ-निर्देशित गति निष्ठा हानि

यह सुनिश्चित करने के लिए कि उत्पन्न गति केवल कोई गति नहीं है, बल्कि वह गति है जो विशेष रूप से पाठ विवरण के साथ संरेखित होती है, एक पाठ-निर्देशित गति निष्ठा हानि पेश की जा सकती है। यह उत्पन्न गति से निकाली गई उच्च-स्तरीय विशेषताओं और पाठ द्वारा निर्देशित सुविधाओं के बीच स्थिरता को मापेगा। होने देना एफ_g और एफ_m उच्च-स्तरीय पाठ और गति विशेषताएँ बनें:

$$L_{\text{fidelity}} = \|F_t - F_m\|_1$$

इन हानि कार्यों को पारंपरिक जनरेटिव हानियों जैसे माध्य वर्ग त्रुटि (एमएसई) या जनरेटिव प्रतिकूल हानि के साथ युग्मित करने से यह सुनिश्चित होता है कि मोशन डिफ्यूज़ ऐसी गतियाँ उत्पन्न करता है जो न केवल गुणात्मक रूप से अच्छी हैं, बल्कि पाठ्य विवरणों के साथ अच्छी तरह से संरेखित भी हैं। इससे ऐसे प्रस्ताव उत्पन्न करने में कुछ चुनौतियों का समाधान होगा जो विविध और पाठ्य रूप से सुसंगत हैं।

इन हानि कार्यों को मॉडल के भीतर ध्यान तंत्र के साथ जटिल रूप से जोड़कर, मोशनडिफ्यूज़ पाठ्य विवरणों द्वारा निर्देशित अधिक सूक्ष्म, अस्थायी रूप से सुसंगत और प्रासंगिक रूप से प्रासंगिक गति अनुक्रमों की सुविधा प्रदान कर सकता है।

इन विशिष्ट हानि कार्यों को एक एकीकृत हानि अवधि में विलय करके, हम लिखने में सक्षम हैं:

$$L_{total} = \lambda_1 L_{MSE} + \lambda_2 L_{attention} + \lambda_3 L_{fidelity}$$

यहाँ, λ_1 , λ_2 , λ_3 हाइपरपैरामीटर हैं जो विभिन्न हानि घटकों के बीच संतुलन को नियंत्रित करते हैं।

4.4. टेक्स्ट, ऑडियो और वीडियो जेनरेशन में डिफ्यूजन मॉडल और अव्यक्त स्पेस डायनेमिक्स का उद्भव

यह संभाव्य डीनोइजिंग डिफ्यूजन डीनोइजिंग मॉडल (डीडीपीएम) के क्षेत्र में एक हालिया नवाचार है। पारंपरिक डीडीपीएम के विपरीत, एलडीएम अव्यक्त स्थान में काम करते हैं और पाठ्य प्रतिनिधित्व पर सशर्त होते हैं (रोम्बच एट अल., 2022)। यह कई सशर्त प्रसार चरणों को शामिल करते हुए चरण-दर-चरण दानेदार उत्पादन प्रक्रिया की अनुमति देता है।

हानि फंक्शन को शोर स्थान (ξ) में माध्य वर्ग त्रुटि के रूप में सावधानीपूर्वक परिभाषित किया गया है $\sim \text{एन}(0, \text{आई})$ । गणितीय रूप से, इसे इस प्रकार तैयार किया जा सकता है:

$$L_\theta = \| \xi_\theta(z_t, t, c) - \xi \|_{2,2}$$

कहाँ ए एक छोटा सा सकारात्मक स्थिरांक है और एक्स डीनोइजिंग नेटवर्क का प्रतिनिधित्व करता है। यह हानि फंक्शन स्टोकेस्टिक ग्रेडिएंट डिसेंट के साथ यादृच्छिक शब्द टी को अनुकूलित करके कुशल प्रशिक्षण की अनुमति देता है। यह ध्यान देने योग्य है कि यह दृष्टिकोण प्रतिकूल प्रतिक्रिया की आवश्यकता के बिना साक्ष्य निचली सीमा (ईएलबीओ) को अनुकूलित करके प्रसार मॉडल को कुशलतापूर्वक प्रशिक्षित करने की अनुमति देता है, जिसके परिणामस्वरूप उल्लेखनीय रूप से विश्वसनीय पुनर्निर्माण होते हैं जो जमीनी सच्चाई वितरण से मेल खाते हैं (हआंग एट अल., 2023)।

2023 में, जनरेटिव आर्टिफिशियल इंटेलिजेंस परिदृश्य एक भूकंपीय बदलाव के दौर से गुजर रहा है, जो मुख्य रूप से प्रसार मॉडल की परिपक्वता द्वारा चिह्नित है। पाठ क्षेत्र में, जबकि प्राकृतिक भाषा समझ और पीढ़ी में उनकी बहुमुखी प्रतिभा के लिए ट्रांसफार्मर की सराहना की जाती थी, प्रसार मॉडल अब नवाचार की एक नई लहर को उत्प्रेरित कर रहे हैं, जो अधिक मजबूत सामान्यीकरण क्षमताओं के साथ सूक्ष्म भाषा मॉडल पेश करते हैं। वे पहले के मॉडलों के मौलिक कार्य का विस्तार कर रहे हैं, भावना विश्लेषण, अमूर्त सारांश और बहुत कुछ में जटिलता और प्रयोज्यता की परतें जोड़ रहे हैं (निकोल एट अल., 2021)। ऑडियो क्षेत्र में, मक-एन-ऑडियो जैसे मॉडल उन्नत प्रसारण तकनीकों (झाओ एट अल., 2023) का उपयोग करके टेक्स्ट-टू-ऑडियो (टी2ए) पीढ़ी में क्रांति ला रहे हैं। वे लंबे, निरंतर सिग्नल डेटा की अंतर्निहित जटिलता को संबोधित करते हैं, जिससे पिछले तरीकों जैसे कि वेवगेन और मेलगेन को संघर्ष करना पड़ा। इसके परिणामस्वरूप उच्च निष्ठा ऑडियो पीढ़ी और सूक्ष्म अर्थ संबंधी समझ प्राप्त होती है पिछली विधियों से आमूल-चल परिवर्तन।

वीडियो पीढ़ी को हाई-डिफिनिशन प्रसारण मॉडल द्वारा भी मजबूत किया गया है, जो रिजॉल्यूशन सीमाओं से आगे बढ़ रहा है, जो अक्सर पुराने GAN-आधारित तरीकों को परेशान करता है। यहाँ, फोकस न केवल पिक्सेल-स्तरीय विवरण पर है, बल्कि वीडियो फ्रेम के बीच अर्थ संबंधी सुसंगतता पर भी है, इस प्रकार उत्पन्न सामग्री के यथार्थवाद में एक नया मानक प्राप्त किया जा रहा है (रोम्बच एट अल., 2022)।

क्रॉस-मोडल जेनरेटिव लर्निंग में, प्रसार मॉडल के साथ एकीकृत स्टोकेस्टिक अव्यक्त अभिनेता-आलोचक मॉडल का आगमन विभिन्न डेटा प्रकारों के बीच सहज और अधिक सटीक अनुवाद की संभावना प्रदान करता है। ये हाइब्रिड मॉडल टेक्स्ट, ऑडियो और वीडियो तौर-तरीकों में हाई-डिफिनिशन, हाई-फाई-डेलिटी जेनरेशन के लिए क्षमताओं को अनलॉक करना शुरू कर रहे हैं (हरनोज़ा एट अल., 2018)।

कुल मिलाकर, टेक्स्ट, ऑडियो और वीडियो प्रसारण मॉडल में ये प्रगति मल्टीमॉडल जेनरेटर एआई के भविष्य के लिए मंच तैयार कर रही है जो अपने अनुप्रयोगों में अधिक समृद्ध, अधिक गतिशील और अधिक दूरगामी है, इस प्रकार डेटा के व्यापक परिदृश्य में क्रांति ला रही है। विश्लेषण, सामग्री निर्माण और स्वचालित निर्णय लेना।

5. जीपीटी पर चैट करें, इसकी क्षमता और इसका लाभ कैसे उठाएं

5.1. जीपीटी का विवरण

जेनरेटिव प्री-प्रशिक्षित ट्रांसफार्मर (जीपीटी) मॉडल प्राकृतिक भाषा प्रसंस्करण (एनएलपी) और कृत्रिम बुद्धिमत्ता (एआई) के क्षेत्र में एक महत्वपूर्ण नवाचार का प्रतिनिधित्व करते हैं। OpenAI द्वारा विकसित, GPT मॉडल ट्रांसफार्मर आर्किटेक्चर पर आधारित हैं, जिसे वासवानी एट अल द्वारा पेश किया गया था। (2017)।

जीपीटी मॉडल को पाठ के बड़े समूह पर पूर्व-प्रशिक्षित किया जाता है और फिर विशिष्ट कार्यों पर ट्यून किया जाता है, जिससे उन्हें ऐसा पाठ उत्पन्न करने की अनुमति मिलती है जो सुसंगत, व्याकरणिक रूप से सही और अक्सर मानव-निर्मित पाठ से अप्रभेद्य होता है (रेडफोर्ड एट अल।, 2019)।

जीपीटी मॉडल ध्यान की कई परतों और मल्टी-हेड ध्यान के संयोजन का उपयोग करते हैं, जिससे उन्हें डेटा में विभिन्न प्रकार की विशेषताओं और संबंधों को पकड़ने की अनुमति मिलती है। पाठ को समझने और उत्पन्न करने के लिए जीपीटी मॉडल की क्षमता ने मशीन अनुवाद, रचनात्मक पाठ निर्माण और प्रश्न उत्तर (ब्राउन एट अल।, 2020) सहित विभिन्न अनुप्रयोगों में प्रगति की है।

5.1.1. वास्तुकला और ध्यान

वासवानी एट अल द्वारा प्रस्तुत ट्रांसफार्मर वास्तुकला। (2017), ने प्राकृतिक भाषा प्रसंस्करण के क्षेत्र में क्रांति ला दी है और अनुक्रमों के मॉडलिंग के तरीके में एक आदर्श बदलाव का प्रतिनिधित्व करता है।

पारंपरिक आवर्ती आर्किटेक्चर (बहदानों, चो, और बेंगियो, 2014) के विपरीत, ट्रांसफार्मर पुनरावृत्ति को खत्म करते हैं और इसके बजाय डेटा में निभरता को पकड़ने के लिए ध्यान तंत्र का उपयोग करते हैं।

आर्किटेक्चर में दो मुख्य भाग होते हैं: एनकोडर और डिकोडर; दोनों समान परतों के ढेर से बने हैं जिनमें दो मुख्य उपपरतें हैं: एक मल्टी-हेड अटेंशन सबलेयर और एक फीड-फॉरवर्ड नेटवर्क। मल्टी-हेड ध्यान मॉडल को इनपुट के विभिन्न हिस्सों पर एक साथ ध्यान देने की अनुमति देता है, इस प्रकार जटिल और दीर्घकालिक संबंधों को कैप्चर करता है। फॉरवर्ड फीड-फॉरवर्ड नेटवर्क में शामिल हैं a एक गैर-रेखीय सक्रियण फ़ंक्शन के बाद सरल रेखिक परिवर्तन।

ट्रांसफार्मर


ट्रांसफार्मर आर्किटेक्चर की एक प्रमुख विशेषता प्रत्येक सबलेयर (हे, झांग, रेन, और सन, 2016) के आसपास अवशिष्ट कनेक्शन को जोड़ना है, इसके बाद परत सामान्यीकरण (बीए, किरिस, और हिटन, 2016) है। यह प्रशिक्षण की सुविधा प्रदान करता है और ग्रेडिएंट्स को नेटवर्क के माध्यम से अधिक आसानी से प्रवाहित करने की अनुमति देता है। ध्यान, अवशिष्ट कनेक्शन और परत सामान्यीकरण का संयोजन ट्रांसफार्मर को अत्यधिक समानांतर और कम्प्यूटेशनल रूप से कुशल बनाने की अनुमति देता है, जिसके कारण विभिन्न एनएलपी कार्यों (डेवलिन, चांग, ली, और टुटानोवा, 2018) में उन्हें व्यापक रूप से अपनाया गया है, देखें चित्र 1।

ट्रांसफार्मर वास्तुकला में ध्यान एक केंद्रीय अवधारणा है। यह आउटपुट के प्रत्येक शब्द को उत्पन्न करते समय मॉडल को इनपुट के विभिन्न हिस्सों का वजन करने की अनुमति देता है, जो गहरी प्रासंगिक समझ की सुविधा प्रदान करता है। ध्यान को तीन मुख्य घटकों में वर्णित किया जा सकता है:

क्वैरीज़, कुंजियाँ और मान: ध्यान की गणना क्वैरीज़, कुंजियाँ और मानों का उपयोग करके की जाती है, जो इनपुट में शब्दों के वेक्टर प्रतिनिधित्व हैं। क्वैरीज़ और कुंजियाँ ध्यान का भार निर्धारित करती हैं, जबकि आउटपुट उत्पन्न करने के लिए मूल्यों को इन भारों के अनुसार भारित किया जाता है (वासवानी और अन्य 2017)।


मल्टी-हेड ध्यान: मल्टी-हेड ध्यान मॉडल को इनपुट के विभिन्न हिस्सों पर एक साथ ध्यान देने की अनुमति देता है। ध्यान का प्रत्येक "शीर्ष" पाठ में विभिन्न संबंधों पर ध्यान केंद्रित कर सकता है, और सभी शीर्षों के आउटपुट को अंतिम प्रतिनिधित्व बनाने के लिए संयोजित किया जाता है।

ऑटोरेग्रेसिव ध्यान: जीपीटी के मामले में, ऑटोरेग्रेसिव ध्यान का उपयोग किया जाता है, जहां प्रत्येक शब्द केवल अनुक्रम में पिछले शब्दों पर ध्यान दे सकता है। यह सुनिश्चित करता है कि पाठ निर्माण कारणात्मक और सुसंगत तरीके से किया जाता है (रेडफोर्ड एट अल., 2018; ब्राउन एट अल., 2020), चित्र 2 देखें।




चित्र 1. ट्रांसफार्मर - मॉडल आर्किटेक्चर (ओपनएआई, 2023)।

led Dot-Product Attention



Multi-Head Attention



चित्र 2. (बाएं) स्केल उत्पाद बिंदु पर ध्यान दें। (दाएं) मल्टी-हेड ध्यान में ध्यान की कई परतें समानांतर में चलती हैं (ओपनएआई, 2023)।

परतों और फ़ीड-फ़ॉरवर्ड नेटवर्क

ट्रांसफॉर्मर आर्किटेक्चर में परतों की एक श्रृंखला होती है, प्रत्येक में एक मल्टी-हेड ध्यान परत होती है जिसके बाद एक सघन रूप से जुड़ा हुआ फ़ीड-फ़ॉरवर्ड नेटवर्क होता है। प्रशिक्षण को सुविधाजनक बनाने और स्थिरता में सुधार करने के लिए प्रत्येक चरण में अवशिष्ट कनेक्शन और परत सामान्यीकरण लागू किया जाता है (हे एट अल., 2016; बा एट अल., 2016)।

5.1.2. पूर्व-प्रशिक्षण और फाइन-ट्यूनिंग

ट्रांसफॉर्मर-आधारित भाषा मॉडल को विकसित करने और अपना देने की प्रक्रिया में ओपनएआई जीपीटी मॉडल का पूर्व-प्रशिक्षण और फाइन-ट्यूनिंग दो महत्वपूर्ण चरण हैं। विशेष रूप से, जीपीटी प्राकृतिक भाषा प्रसंस्करण अनुसंधान में एक अग्रणी प्रतिमान है और सुसंगत और प्रासंगिक रूप से प्रासंगिक पाठ की पीढ़ी में एक महत्वपूर्ण प्रगति का प्रतिनिधित्व करता है।

जीपीटी प्री-ट्रेनिंग

जीपीटी मॉडल के निर्माण में पूर्व-प्रशिक्षण प्रारंभिक चरण है और यह ज्ञान हस्तांतरण के मुख्य विचार पर आधारित है। इस चरण के दौरान, मॉडल को बड़ी मात्रा में अनटैग किए गए पाठ्य डेटा पर प्रशिक्षित किया जाता है। यह वह जगह है जहां जीपीटी गहरे स्तर पर भाषाई, शब्दार्थ और प्रासंगिक पैटर्न सीखता है। यह प्रक्रिया एक ऑटोरिगेशन कार्य का उपयोग करके की जाती है, जहां मॉडल पिछले शब्दों के आधार पर वाक्य में अगले शब्द की भविष्यवाणी करता है (वासवानी एट अल., 2017)। ट्रांसफॉर्मर जैसी वास्तुकला में मौजूद ध्यानात्मक तंत्र मॉडल को पाठ में दीर्घकालिक संबंधों को पकड़ने की अनुमति देता है, जो इसे सुसंगत और प्रासंगिक रूप से प्रासंगिक प्रतिक्रियाएं उत्पन्न करने में सक्षम बनाता है।

जीपीटी पूर्व-प्रशिक्षण में स्टोचैस्टिक ग्रेडिएंट डिसेंट जैसे अनुकूलन एल्गोरिदम का उपयोग करके मॉडल में लाखों मापदंडों को अनुकूलित करना शामिल है। प्रमुख हाइपरपैरामीटर, जैसे सीखने की दर और ट्रांसफॉर्मर आर्किटेक्चर, इस प्रक्रिया में महत्वपूर्ण भूमिका निभाते हैं (वासवानी एट अल., 2017)। सफल प्री-ट्रेनिंग प्राप्त करने के लिए इन हाइपरपैरामीटर को उचित रूप से ट्यून करने का महत्व ध्यान देने योग्य है।

जीपीटी की फाइन-ट्यूनिंग


पूर्व-प्रशिक्षण चरण के बाद, GPT मॉडल गहन भाषा ज्ञान से समृद्ध होता है। हालाँकि, मॉडल को विशिष्ट कार्यों के लिए अनुकूलित करने के लिए, जैसे किसी विशेष डोमेन में पाठ उत्पन्न करना या विशिष्ट प्रश्नों का उत्तर देना, फाइन-ट्यूनिंग आवश्यक है। इस चरण के दौरान, मॉडल को संबोधित किए जाने वाले विशिष्ट कार्य से संबंधित लेबल किए गए डेटा के एक सेट पर प्रशिक्षित किया जाता है।

ट्यूनिंग में कार्य-विशिष्ट डेटासेट का उपयोग करके पूर्व-प्रशिक्षित मॉडल के वजन को समायोजित करना शामिल है। ट्यूनिंग में पूर्व-प्रशिक्षण की तुलना में सीखने की दर कम होती है और आमतौर पर कम पुनरावृत्तियों की आवश्यकता होती है क्योंकि मॉडल द्वारा पहले अर्जित ज्ञान अधिक विशिष्ट होता है।

ट्यूनिंग के समय, सही डेटासेट चुनना और एक प्रभावी मूल्यांकन रणनीति तैयार करना महत्वपूर्ण है। मूल्यांकन मेट्रिक्स को कार्य के उद्देश्यों के साथ संरेखित किया जाना चाहिए। उदाहरण के लिए, भावना विश्लेषण में, सटीकता, रि कॉल और स्कोर जैसे मेट्रिक्स पर विचार किया जा सकता है। ओवरफिटिंग से बचने के लिए पर्याप्त सत्यापन और परीक्षण सेट सुनिश्चित करना भी आवश्यक है (रेडफोर्ड एट अल., 2019)।

5.1.3. जीपीटी का विकास

निम्नलिखित OpenAI द्वारा विकसित GPT मॉडल के विकास की समीक्षा है, जो GPT-4 तक ले जाता है। मॉडलों की जीपीटी श्रृंखला कृत्रिम बुद्धिमत्ता के क्षेत्र में सबसे महत्वपूर्ण प्रगति में से एक का प्रतिनिधित्व करती है, विशेष रूप से प्राकृतिक भाषा प्रसंस्करण (एनएलपी) में, चित्र 3 देखें।



चित्र 3. जीपीटी श्रृंखला मॉडल (ओपनएआई, 2023) के तकनीकी विकास का एक संक्षिप्त चित्रण।

जीपीटी-1

रिलीज: ओपनएआई द्वारा जून 2018।

वास्तुकला: वासवानी एट अल द्वारा ट्रांसफार्मर। (2017)। पैरामीटर: 117 मिलियन।

तकनीकी विवरण: 12 परतों, 12 ध्यान प्रमुखों और 768 छिपी इकाइयों के साथ एक ट्रांसफार्मर आर्किटेक्चर का उपयोग करता है।

प्रमुख योगदान: प्राकृतिक भाषा प्रसंस्करण कार्यों के लिए पूर्व प्रशिक्षण के साथ एक ट्रांसफार्मर वास्तुकला का परिचय (रेडफोर्ड एट अल। 2018)।

जीपीटी-2

रिलीज: ओपनएआई द्वारा फरवरी

2019। पैरामीटर: 1.5 बिलियन।

तकनीकी विवरण: GPT-2 के पैमाने में विस्तार हुआ, जो अपने पूर्ववर्ती से दस गुना बड़ा था। मॉडल को विविध और बड़े कॉर्पस पर प्रशिक्षित किया गया था। इसके सबसे बड़े संस्करण में 48 परतें, 1600 छिपी हुई इकाइयाँ और 25.6 बिलियन पैरामीटर हैं।

प्रमुख योगदान: प्रदर्शित किया गया कि बड़े पैमाने पर भाषा मॉडल पैराग्राफ में सुसंगत, उच्च-गुणवत्ता वाला पाठ उत्पन्न कर सकते हैं, जो विभिन्न अनुप्रयोगों और मशीनी अनुवाद के लिए उपयोगी था (रेडफोर्ड एट अल। 2019)।

जीपीटी-3

रिलीज: ओपनएआई द्वारा जून 2020।

आर्किटेक्चर: GPT-2 आर्किटेक्चर एक्सटेंशन।

पैरामीटर: 175 बिलियन।

तकनीकी विवरण: GPT-3 ने पैमाने को और बढ़ाया और कई वास्तुकला और प्रशिक्षण सुधार पेश किए। विशिष्ट ट्यूनिंग की आवश्यकता के बिना विभिन्न प्रकार के कार्यों पर प्रशिक्षित किया गया।

प्रमुख योगदान: "कुछ-शॉट सीखने" की क्षमता पर प्रकाश डाला गया, जहां मॉडल केवल कुछ उदाहरणों के साथ कार्य सीख सकता है। इस मॉडल का उपयोग सामग्री लेखन और संपादन से लेकर प्रोग्रामिंग और उपयोगकर्ता इंटरफेस डिज़ाइन तक अनुप्रयोगों की एक विस्तृत श्रृंखला में किया गया है, जो क्षेत्र में अभूतपूर्व बहुमुखी प्रतिभा दिखाता है (ब्राउन एट अल। 2020)।

तालिका 2 सीखने के आकार, आर्किटेक्चर और हाइपरपैरामीटर दिखाती है।

तालिका 2. मॉडलों के आकार, आर्किटेक्चर और सीखने के हाइपरपैरामीटर (टोकन और सीखने की दर में बैच आकार)।

मॉडल नाम	एन पैरामीटर	एन परले	डी नमूना	एन सिर	डी सिर	बैच का आकार	सीखने की दर
जीपीटी-3 छोटा	125एम	12	768	12	64	0.5M	6.0×10^{-4}
जीपीटी-3 मध्यम	350 मीटर	24	1024	16	64	0.5M	3.0×10^{-4}
GPT-3 बड़ा	760एम	24	1536	16	96	0.5M	2.5×10^{-4}
जीपीटी-3 एक्सएल	1.3बी	24	2048	24	128	1M	2.0×10^{-4}
जीपीटी-3 2.7बी	2.7बी	32	2560	32	80	1M	1.6×10^{-4}
जीपीटी-3 6.7बी	6.7बी	32	4096	32	128	2M	1.2×10^{-4}
जीपीटी-3 13बी	13.0बी	40	5140	40	128	2M	1.0×10^{-4}
GPT-3 175B या "GPT-3"	175.0बी	96	12288	96	128	3.2एम	0.6×10^{-4}

कोडेक्स

रिलीज़: GPT-3 का एक संस्करण, विशेष रूप से शेड्यूलिंग कार्यों के लिए डिज़ाइन किया गया (ज़रेम्बा और ब्रॉकमैन, 2021)।

आर्किटेक्चर: ट्रांसफॉर्मर आर्किटेक्चर पर आधारित और जीपीटी-3 का एक प्रकार है जिसे विशेष रूप से शेड्यूलिंग कार्यों के लिए डिज़ाइन किया गया है।

पैरामीटर: 175 बिलियन पैरामीटर।

तकनीकी विवरण: स्रोत कोड और दस्तावेज़ीकरण के एक बड़े भंडार पर पूर्व-प्रशिक्षित। इसका उपयोग मुख्य रूप से कोड उत्पन्न करने और प्रोग्रामिंग कार्यों में सहायता के लिए किया जाता है।

प्रमुख योगदान: यह कई प्रोग्रामिंग भाषाओं में कार्यात्मक कोड उत्पन्न करने में सक्षम साबित हुआ है। इसकी रिलीज़ ने डेवलपर्स के कोड के साथ इंटरैक्ट करने के तरीके में क्रांति ला दी है, जो स्वचालित कोड जेनरेशन और प्रोग्रामिंग सहायता (ओपनएआई, 2021) के लिए एक शक्तिशाली टूल प्रदान करता है।

5.2. चैटजीपीटी, जीपीटी-4

ट्रांसफॉर्मर आर्किटेक्चर पर आधारित भाषा मॉडल का हाल के वर्षों में तेजी से विकास हुआ है, जिसका समापन ओपनएआई द्वारा विकसित जेनरेटिव प्री-ट्रैंड ट्रांसफॉर्मर (जीपीटी) मॉडल की श्रृंखला में हुआ। विशेष रूप से, GPT-4 और ChatGPT क्रमशः प्राकृतिक भाषा समझ और पीढ़ी के क्षेत्र में महत्वपूर्ण प्रगति का प्रतिनिधित्व करते हैं। ये मॉडल उपरोक्त मॉडलों के अनुवर्ती हैं और पिछले कुछ महीनों में, टेक्स्ट जेनरेटर एआई मॉडल में एक नए युग की शुरुआत हुई है। दोनों मॉडल ट्रांसफॉर्मर आर्किटेक्चर पर आधारित हैं, जो प्राकृतिक भाषा प्रसंस्करण कार्यों के लिए अत्यधिक कुशल साबित हुए हैं (वासवानी एट अल।, 2017)।

चैटजीपीटी (जीपीटी-3.5)

चैटजीपीटी ओपनएआई द्वारा विकसित एक भाषा मॉडल है और यह जीपीटी (जेनरेटिव प्री-ट्रैंड ट्रांसफॉर्मर) आर्किटेक्चर पर आधारित है। यह GPT-3 का एक ट्यून किया हुआ संस्करण है जिसे विशेष रूप से बातचीत और चैट कार्यों के लिए डिज़ाइन किया गया है। मॉडल को इंटरनेट टेक्स्ट के एक बड़े संग्रह पर प्रशिक्षित किया गया है, लेकिन यह ज्ञात नहीं है कि इसके प्रशिक्षण डेटासेट में कौन से विशिष्ट दस्तावेज़ों का उपयोग किया गया था। इसे रचनात्मक पाठ निर्माण से लेकर प्रोग्रामिंग और तकनीकी समस्या समाधान तक के कार्य करने के लिए डिज़ाइन किया गया है। यह मॉडल ChatGPT (openai.com) के माध्यम से निःशुल्क उपलब्ध है।

रिलीज: नाकानो एट अल के अनुसार चैटजीपीटी को ओपनएआई द्वारा 2021 में जारी किया गया था। (2021)।
 आर्किटेक्चर: ChatGPT भी ट्रांसफॉर्मर आर्किटेक्चर पर आधारित है और बातचीत के लिए अनुकूलित GPT-3 का एक प्रकार है।

पैरामीटर: ChatGPT में GPT-3 के समान 175 बिलियन पैरामीटर हैं।


तकनीकी विवरण: यह बातचीत और पाठ के संग्रह पर पूर्व-प्रशिक्षित है। चैटबॉट्स और इंटरैक्टिव वार्तालाप प्रणालियों के लिए डिज़ाइन किया गया।

मुख्य योगदान: चैटजीपीटी ने पिछले मॉडलों की तुलना में बातचीत में स्थिरता और प्रासंगिकता में सुधार किया है।

जीपीटी-4

GPT-4, GPT श्रृंखला का चौथा पुनरावृत्ति है और क्षमताओं, सीमाओं और संबंधित जोखिमों के संदर्भ में एक लंबी छलांग का प्रतिनिधित्व करता है। मापदंडों की अभी तक अज्ञात संख्या के साथ, GPT-4 ने पाठ निर्माण, प्रासंगिक समझ और विभिन्न कार्यों के लिए अनुकूलनशीलता में महत्वपूर्ण सुधार दिखाया है। यह मॉडल ओपनएआई के भुगतान किए गए संस्करण में उपलब्ध है जिसे चैटजीपीटी प्लस कहा जाता है, जिसमें जीपीटी -4 मॉडल के कुछ प्रतिबंध और उपलब्ध नए टूल जैसे प्लगइन्स (ओपनएआई, 2023), कोड दुभाषिया और ओपनएआई (2023) के अनुसार कस्टम निर्देश शामिल हैं, चित्र 4 विभिन्न कार्य संदर्भों को दर्शाता है।

प्लगइन्स डेवलपर्स को मॉडल में विशिष्ट कार्यक्षमता जोड़ने की अनुमति देते हैं, जैसे वेब खोज, भाषा अनुवाद और वैज्ञानिक डेटाबेस को क्वेरी करना। प्रकाशन इस बात पर जोर देता है कि ये प्लगइन्स सुरक्षित और विश्वसनीय होने के लिए डिज़ाइन किए गए हैं और अनुमोदन से पहले एक कठोर समीक्षा प्रक्रिया से गुजरते हैं।



चित्र 4. शैक्षिक और व्यावसायिक मूल्यांकन पर प्रदर्शन। प्रत्येक परीक्षण के लिए, हम वास्तविक परीक्षा वातावरण और ग्रेडिंग सिस्टम की नकल करते हैं। मूल्यांकन को GPT-3.5 के प्रदर्शन के अनुसार आरोही क्रम में व्यवस्थित किया गया है। अधिकांश मूल्यांकन परीक्षाओं में GPT-4, GPT-3.5 से आगे निकल जाता है (OpenAI, 2023)।

रिलीज: GPT-4 पर तकनीकी रिपोर्ट मार्च 2023 में OpenAI द्वारा प्रकाशित की गई थी।

आर्किटेक्चर: GPT-4 ट्रांसफॉर्मर आर्किटेक्चर पर आधारित एक मॉडल है जो छवि और टेक्स्ट इनपुट स्वीकार कर सकता है और टेक्स्ट आउटपुट उत्पन्न कर सकता है।

पैरामीटर्स: रिपोर्ट मापदंडों की सटीक संख्या निर्दिष्ट नहीं करती है लेकिन इस बात पर प्रकाश डालती है कि मॉडल बड़े पैमाने का है।

तकनीकी विवरण: GPT-4 को दस्तावेज़ में अगले टोकन की भविष्यवाणी करने के लिए पूर्व-प्रशिक्षित किया गया है। प्रशिक्षण के बाद संरक्षण प्रक्रिया के परिणामस्वरूप तथ्यात्मकता और वांछित व्यवहार के अनुपालन के उपायों पर बेहतर प्रदर्शन होता है। बुनियादी ढाँचे और अनुकूलन के तरीके विकसित किए गए जो व्यापक पैमाने पर पूर्वानुमानित व्यवहार करते हैं।

प्रमुख योगदान: GPT-4 एक बड़ा मल्टीमॉडल मॉडल है (छवि और टेक्स्ट इनपुट स्वीकार करता है, टेक्स्ट आउटपुट उत्सर्जित करता है) जो वास्तविक दुनिया के कई परिदृश्यों में मनुष्यों की तुलना में कम सक्षम है, कई पेशेवर और अकादमिक बेंचमार्क पर मानव-स्तरीय प्रदर्शन प्रदर्शित करता है (ओपनएआई, 2023)।

5.3. संकेतों

संकेत निर्देश, प्रश्न या कथन हैं जिन्हें ओपनएआई के जीपीटी मॉडल जैसे प्राकृतिक भाषा प्रसंस्करण (एनएलपी) मॉडल से एक विशिष्ट प्रतिक्रिया प्राप्त करने के लिए डिज़ाइन किया गया है। चैटबॉट्स और अन्य पीएलएन अनुप्रयोगों के संदर्भ में, संकेत प्रारंभिक इनपुट के रूप में कार्य करते हैं जो सुसंगत और प्रासंगिक प्रतिक्रिया उत्पन्न करने में मॉडल का मार्गदर्शन करते हैं। मॉडल के साथ बातचीत को नियंत्रित और निर्देशित करने, उत्पन्न प्रतिक्रिया की गुणवत्ता, सटीकता और संदर्भ को प्रभावित करने में उनकी भूमिका महत्वपूर्ण है।

5.3.1. अच्छे संकेत स्थापित करने की रणनीतियाँ

- स्पष्टता और परिशुद्धता: एक अच्छा संकेत स्पष्ट और सटीक होना चाहिए, अस्पष्टता से बचना चाहिए जिससे भ्रमित करने वाले या गलत उत्तर मिल सकते हैं (रेडर एट अल., 2020)।
- प्रासंगिकता: आवश्यक संदर्भ शामिल करने से मॉडल को क्वेरी के पीछे के इरादे को समझने में मदद मिलती है, जिससे प्रतिक्रिया की प्रासंगिकता में सुधार होता है (चेन एट अल., 2019)।
- उदाहरणों का उपयोग: कुछ-शॉट सीखने में, प्रॉम्प्ट के भीतर उदाहरण प्रदान करने से मॉडल को इच्छित कार्य को समझने में मदद मिल सकती है (ब्राउन एट अल., 2020)।
- पुनरावृत्तीय प्रयोग: पुनरावृत्तीय प्रयोग और संकेत का समायोजन इंटरैक्शन को ठीक करने और इष्टतम प्रतिक्रियाएँ प्राप्त करने की अनुमति देता है (वालेस एट अल., 2019)।
- नैतिक विचार: संकेत संभावित पूर्वाग्रहों के बारे में जागरूकता के साथ तैयार किए जाने चाहिए और गोपनीयता और नैतिकता नियमों (होवी एंड स्पूट, 2016) का अनुपालन करना चाहिए।

प्रॉम्प्ट जनरेटिव भाषा मॉडल और अन्य पीएलएन अनुप्रयोगों के डिज़ाइन और उनके साथ बातचीत में केंद्रीय भूमिका निभाते हैं। उनके निर्माण और प्रबंधन में तकनीकी, भाषाई और नैतिक विचारों का संयोजन शामिल है। पीएलएन में साहित्य संकेतों के प्रभावी उपयोग से संबंधित अनुसंधान और तकनीकों का एक विस्तृत स्पेक्ट्रम प्रदान करता है, और उनका अध्ययन और अनुप्रयोग मनुष्यों और कृत्रिम बुद्धिमत्ता प्रणालियों के बीच इंटरफेस में एक महत्वपूर्ण क्षेत्र बना हुआ है।

5.3.2. संकेतों के प्रकार और उनके उपयोग

- सूचनात्मक संकेत: विशिष्ट जानकारी का अनुरोध करने के लिए डिज़ाइन किए गए, वे डेटा खोज और वर्चुअल असिस्टेंट (मैनिंग एट अल., 2008) जैसे अनुप्रयोगों में उपयोगी हैं।
- पूछताछ संबंधी संकेत: प्रश्नों के रूप में तैयार किए गए, इन्हें ग्राहक सहायता और ट्यूशन (जुराफस्की और मार्टिन, 2019) जैसे क्षेत्रों में विस्तृत प्रतिक्रिया देने के लिए नियोजित किया जाता है।

- निर्देशात्मक संकेत: किसी विशेष कार्य को करने के लिए मॉडल को निर्देशित करने के लिए उपयोग किया जाता है, जैसे अनुवाद, सारांश, या रचनात्मक सामग्री निर्माण (रेडटर और डेल, 2020)।
- प्रासंगिक संकेत: जटिल परिदृश्यों में मॉडल की प्रतिक्रिया को निर्देशित करने के लिए अतिरिक्त संदर्भ शामिल करें, जैसे चल रहे संवाद या विशेष कार्य (सर्बन एट अल।, 2017)।
- तुलनात्मक संकेत: संस्थाओं या अवधारणाओं के बीच तुलना, विश्लेषण या मूल्यांकन के लिए डिज़ाइन किया गया।
- कोड जनरेशन संकेत: प्रोग्रामिंग वातावरण में स्वचालित रूप से कोड स्निपेट उत्पन्न करने के लिए उपयोग किया जाता है, जैसे ओपनएआई कोडेक्स (ओपनएआई, 2021)।
- भाषाई सहायता संकेत: व्याकरण सुधार, अनुवाद और अन्य भाषाई सेवाओं, जैसे व्याकरण या Google अनुवाद के लिए उपकरणों में लागू।

5.3.3. उदाहरण: कोड जनरेशन

स्वचालित कोड जनरेशन एक ऐसी तकनीक है जिसका उपयोग प्रोग्रामेटिक रूप से स्रोत कोड तैयार करने के लिए किया जाता है। यह अभ्यास विशेष रूप से तब उपयोगी होता है जब बड़ी मात्रा में समान या दोहराव वाले कोड उत्पन्न करने की आवश्यकता होती है। कोड के प्रत्येक टुकड़े को मैक्युअल रूप से लिखने के बजाय, डेवलपर्स प्रक्रिया को स्वचालित करने के लिए कोड जनरेटर का उपयोग कर सकते हैं। इस लेख में, हम पता लगाएंगे कि पायथन के साथ स्वचालित रूप से कोड कैसे उत्पन्न किया जा सकता है और गणितीय फ़ंक्शन बनाने के लिए कोड पीढ़ी का एक सरल उदाहरण प्रस्तुत किया जा सकता है, चित्र 5, 6, 7 देखें।

स्वचालित रूप से कोड क्यों जनरेट करें?

दक्षता: कोड लिखने के लिए आवश्यक समय कम कर देता है।

संगति: यह सुनिश्चित करता है कि उत्पन्न कोड एक विशिष्ट पैटर्न का पालन करता है।

लचीलापन: न्यूनतम प्रयास के साथ कोड में वैश्विक परिवर्तन की अनुमति देता है।

पायथन में कोड जनरेशन का उदाहरण

स्वचालित रूप से पायथन फ़ंक्शन उत्पन्न करता है जो किसी दिए गए संख्या के वर्ग, घन और चौथी शक्ति की गणना करता है।

सबसे पहले, आइए एक पायथन फ़ंक्शन को परिभाषित करें जो एक घातांक को एक पैरामीटर के रूप में लेता है और एक फ़ंक्शन का स्रोत कोड लौटाता है जो उस घातांक के लिए एक संख्या बढ़ाता है।

```
python Copy code

def generate_power_function(exponent):
    function_name = f"power_of_{exponent}"
    code = f"""
def {function_name}(x):
    return x ** {exponent}
"""
    return code
```

चित्र 5. पायथन प्रतिपादक फ़ंक्शन।

जनरेटिंग फ़ंक्शन

अब, हम इस फ़ंक्शन का उपयोग उन फ़ंक्शंस के लिए कोड उत्पन्न करने के लिए करेंगे जो किसी संख्या के वर्ग, घन और चौथी शक्ति की गणना करते हैं।

```
python Copy code
exponents = [2, 3, 4]
for exp in exponents:
    print(generate_power_function(exp))
```

चित्र 6. पायथन सूची फ़ंक्शन।

जनरेट किया गया कोड इस तरह दिखता है:

```
python Copy code
def power_of_2(x):
    return x ** 2

def power_of_3(x):
    return x ** 3

def power_of_4(x):
    return x ** 4
```

चित्र 7. पायथन गणित फ़ंक्शन।

generate_power_function फ़ंक्शन एक घातांक लेता है और एक कोड स्निपेट लौटाता है जो एक नए पायथन फ़ंक्शन को परिभाषित करता है। यह नया फ़ंक्शन एक पैरामीटर x लेता है और x को दिए गए घातांक तक बढ़ाकर लौटाता है।

"जनरेटिंग फ़ंक्शंस" खंड में लूप घातांक की एक सूची के माध्यम से चलता है। प्रत्येक घातांक के लिए, संबंधित कोड उत्पन्न करने के लिए generate_power_function को कॉल किया जाता है।

स्वचालित कोड जनरेशन एक शक्तिशाली तकनीक है जो समय और प्रयास बचा सकती है, खासकर जब दोहराए जाने वाले या समान कोड से निपटते हैं। प्रस्तुत उदाहरण काफी सरल है, लेकिन कोड जनरेशन का उपयोग फ्रेमवर्क और सॉफ्टवेयर लाइब्रेरी सहित बहुत अधिक जटिल अनुप्रयोगों में किया जाता है।

5.4. दिशानिर्देश और दस्तावेज़ीकरण

5.4.1. नैतिकता और जिम्मेदार उपयोग

चैटजीपीटी को आम तौर पर ओपनएआई द्वारा प्रदान की गई एपीआई के माध्यम से एक्सेस किया जाता है, जिसे मॉडल के साथ इंटरैक्शन की सुरक्षा और अखंडता सुनिश्चित करने के लिए प्रमाणीकरण की आवश्यकता होती है, यह अत्यधिक बहुमुखी है और इसे ग्राहक सेवा चैटबॉट से लेकर वर्चुअल असिस्टेंट तक विभिन्न अनुप्रयोगों में लागू किया जा सकता है। और निर्णय लेने की प्रणालियाँ। एपीआई विभिन्न संदर्भों में मॉडल के व्यवहार को निर्देशित करने के लिए विशिष्ट संकेतों या निर्देशों को परिभाषित करने की क्षमता सहित अनुकूलन की एक विस्तृत श्रृंखला की अनुमति देता है। इसके अलावा, ओपनएआई प्रमाणीकरण, शीघ्र संरचना और मॉडल द्वारा उत्पन्न प्रतिक्रियाओं की व्याख्या जैसे तकनीकी पहलुओं को कवर करने वाला विस्तृत दस्तावेज प्रदान करता है (ओपनएआई, 2021)।

चैटजीपीटी तक पहुंच केवल एपीआई के माध्यम से बातचीत तक ही सीमित नहीं है, यह ओपनएआई द्वारा प्रदान किए गए वेब इंटरफ़ेस के माध्यम से भी पहुंच योग्य है। यह वेब इंटरफ़ेस उन्नत तकनीकी ज्ञान की आवश्यकता के बिना मॉडल के साथ बातचीत करने का एक सहज और उपयोग में आसान साधन प्रदान करता है। उपयोगकर्ता बस अपने संकेत या प्रश्न एक टेक्स्ट बॉक्स में दर्ज करते हैं, और मॉडल उत्तर उत्पन्न करता है जो उसी इंटरफ़ेस में प्रदर्शित होते हैं। पहुंच की यह विधि विशेष रूप से गैर-तकनीकी उपयोगकर्ताओं या उन लोगों के लिए उपयोगी है जो किसी बड़े एप्लिकेशन या सिस्टम में एकीकृत किए बिना मॉडल की क्षमताओं का परीक्षण करना चाहते हैं। इसके अलावा, वेब इंटरफ़ेस में अक्सर अतिरिक्त सुविधाएं शामिल होती हैं, जैसे तापमान और अधिकतम प्रतिक्रिया लंबाई जैसे मापदंडों को समायोजित करने की क्षमता, जो टेक्स्ट जेनरेशन पर अधिक नियंत्रण प्रदान करती है (ओपनएआई, 2021)।

चैटजीपीटी के साथ बातचीत करते समय नैतिक और जिम्मेदार उपयोग दिशानिर्देशों को ध्यान में रखना महत्वपूर्ण है, खासकर उन अनुप्रयोगों में जिनके महत्वपूर्ण सामाजिक या सांस्कृतिक प्रभाव हो सकते हैं। OpenAI इन मुद्दों के समाधान के लिए विशिष्ट दिशानिर्देश प्रदान करता है, जिसमें साहित्यिक चोरी की रोकथाम और अनुचित सामग्री का निर्माण शामिल है।

5.4.2. नैतिकता और जिम्मेदार उपयोग

दस्तावेज़ीकरण नैतिक और जिम्मेदार उपयोग के मुद्दों को भी संबोधित करता है। इसमें साहित्यिक चोरी की रोकथाम, अनुचित सामग्री की पीढ़ी, और बड़े पैमाने पर भाषा मॉडल का उपयोग करने के सामाजिक और सांस्कृतिक प्रभावों पर विचार करने पर दिशानिर्देश शामिल हैं। बड़े डेटा-सेट पर प्रशिक्षित इन मॉडलों में ऐसी सामग्री उत्पन्न करने की क्षमता होती है जो भेदभावपूर्ण, पक्षपातपूर्ण या खतरनाक भी हो सकती है (हाओ, 2020; बेंडर एट अल., 2021)। इसलिए, नैतिक मुद्दों को बहु-विषयक परिप्रेक्ष्य से संबोधित करना अनिवार्य है जिसमें तकनीकी और सामाजिक दोनों पहलू शामिल हैं।

सबसे अधिक दबाव वाली चुनौतियों में से एक प्रशिक्षण डेटा में अंतर्निहित पूर्वाग्रह है, जो मौजूदा रूढ़िवादिता और पूर्वाग्रहों को कायम रख सकता है (कैलिस्कन एट अल., 2017)। शोधकर्ता इन पूर्वाग्रहों को कम करने के तरीकों की खोज कर रहे हैं, जैसे पैरामीटर समायोजन और प्रशिक्षण डेटा का पुनः भार (झाओ एट अल., 2018)।

मॉडलों के संचालन में पारदर्शिता और उनके निर्णयों का पता लगाने की क्षमता एआई के नैतिक उपयोग के लिए मौलिक है। यह स्वास्थ्य देखभाल और न्यायिक प्रणाली जैसे महत्वपूर्ण अनुप्रयोगों में विशेष रूप से प्रासंगिक है, जहां एक गलत निर्णय के गंभीर परिणाम हो सकते हैं (दोशी-वेलेज़ एट अल., 2017)।

जिम्मेदार उपयोग में सुरक्षा उपायों को लागू करना शामिल है, जैसे सामग्री मॉडरेशन सिस्टम और अनुचित सामग्री के लिए अलर्ट। उपयोगकर्ताओं को इन मॉडलों की सीमाओं के बारे में शिक्षित करना और उनकी प्रतिक्रियाओं की आलोचनात्मक व्याख्या कैसे करें (मैकग्रेगर एट अल., 2020) भी महत्वपूर्ण है।

एआई में नैतिकता एक तेजी से विकसित होने वाला क्षेत्र है जिसमें इंजीनियरों, नैतिकतावादियों, विधायकों और अन्य प्रासंगिक हितधारकों के बीच निरंतर सहयोग की आवश्यकता होती है ताकि यह सुनिश्चित किया जा सके कि प्रौद्योगिकी का उपयोग इस तरह से किया जाए जो समग्र रूप से समाज के लिए फायदेमंद हो।

5.4.3. कंप्यूटर प्रोग्रामिंग और शिक्षा में अनुप्रयोग

ओपनएआई कोडेक्स ने विशिष्ट परिचयात्मक प्रोग्रामिंग समस्याओं पर महत्वपूर्ण प्रदर्शन किया है। इसके प्रदर्शन की तुलना समान परीक्षा देने वाले छात्रों के प्रदर्शन से की गई, जिससे पता चला कि कोडेक्स अधिकांश छात्रों से बेहतर प्रदर्शन करता है। इसके अलावा, हमने पता लगाया कि कोडेक्स समस्या शब्दों में सूक्ष्म बदलावों को कैसे संभालता है, यह देखते हुए कि समान इनपुट अक्सर एल्गोरिथम दृष्टिकोण और कोड लंबाई के संदर्भ में बहुत अलग समाधान की ओर ले जाता है। यह अध्ययन उन प्रभावों पर भी चर्चा करता है जो इस तरह की तकनीक का कंप्यूटर विज्ञान शिक्षा पर पड़ रहा है क्योंकि यह लगातार विकसित हो रहा है (फिनी-एस्ले एट अल., 2022)।

एक बड़े भाषा मॉडल के रूप में ओपनएआई कोडेक्स का उपयोग करके, प्रोग्रामिंग अभ्यास (नमूना समाधान और परीक्षण मामलों सहित) और कोड स्पष्टीकरण बनाए गए थे। नतीजे बताते हैं कि स्वचालित रूप से उत्पन्न अधिकांश सामग्री नवीन और समझदार है, और कुछ मामलों में उपयोग के लिए तैयार है। यह अध्ययन परिचयात्मक प्रोग्रामिंग शिक्षा के लिए ओपनएआई कोडेक्स और इसी तरह के उपकरणों के निहितार्थों पर भी चर्चा करता है और भविष्य के शोध पर प्रकाश डालता है जिसमें शिक्षकों और छात्रों दोनों के लिए शैक्षिक अनुभव की गुणवत्ता में सुधार करने की क्षमता है (सरसा एट अल., 2022)।

OpenAI कोडेक्स द्वारा संचालित GitHub Copilot का मूल्यांकन 166 प्रोग्रामिंग समस्याओं के डेटासेट पर किया गया है। ऐसा पाया गया कि इसने अपने पहले प्रयास में इनमें से लगभग आधी समस्याओं को सफलतापूर्वक हल कर लिया और शेष समस्याओं में से 60% को समस्या विवरण में केवल प्राकृतिक भाषा परिवर्तन का उपयोग करके हल किया। इस अध्ययन का तर्क है कि इस प्रकार की त्वरित इंजीनियरिंग एक संभावित उपयोगी शिक्षण गतिविधि है जो कम्प्यूटेशनल सोच कौशल को बढ़ावा देती है और कोड लेखन कौशल विकास की प्रकृति को बदलने की संभावना है (डेनी एट अल., 2022)।

5.4.4. अकादमिक प्रकाशन में अनुप्रयोग

चैटजीपीटी को निबंधों और अन्य प्रकार की शैक्षणिक पांडुलिपियों की स्वचालित तैयारी के लिए एक संभावित मॉडल के रूप में देखा जाता है। संभावित नैतिक मुद्दे जो GPT-3 जैसे बड़े भाषा मॉडल के उद्भव के साथ उत्पन्न हो सकते हैं, ChatGPT के पीछे अंतर्निहित तकनीक और शिक्षाविदों और शोधकर्ताओं द्वारा उनके उपयोग पर चर्चा की जाती है, उन्हें कृत्रिम बुद्धिमत्ता में व्यापक प्रगति के संदर्भ में रखा जाता है, मशीन लर्निंग, और अकादमिक अनुसंधान और प्रकाशन के लिए प्राकृतिक भाषा प्रसंस्करण (लुंड एट अल., 2023)।

मॉडल की रिलीज ने कई लोगों को उन रोमांचक और समस्याग्रस्त तरीकों के बारे में सोचने के लिए प्रेरित किया है जिनसे कृत्रिम बुद्धिमत्ता (एआई) निकट भविष्य में हमारे जीवन को बदल सकती है। यह ध्यान में रखते हुए कि चैटजीपीटी को पर्यवेक्षित और सुदृढीकरण सीखने के साथ जीपीटी-3 मॉडल को ठीक करके तैयार किया गया था, उत्पन्न सामग्री की गुणवत्ता केवल अतिरिक्त प्रशिक्षण और अनुकूलन के साथ सुधारी जा सकती है। इसके उपयोग से जुड़े कई अवसर हैं, साथ ही जोखिम भी हैं, क्योंकि इस विघटनकारी तकनीक के अपरिहार्य कार्यान्वयन के चिकित्सा, विज्ञान और अकादमिक प्रकाशन के लिए दूरगामी परिणाम होंगे (होमोलक, 2023)।

यह वैज्ञानिक लेखन में भी एक उपयोगी उपकरण प्रतीत होता है, जो सामग्री को व्यवस्थित करने, प्रारंभिक मसौदा तैयार करने और/या प्रूफरीडिंग में शोधकर्ताओं और वैज्ञानिकों की सहायता करता है। इन उपकरणों के उपयोग के संबंध में कई नैतिक मुद्दे उठाए जाते हैं, जैसे साहित्यिक चोरी और अशुद्धियों का जोखिम, साथ ही उच्च आय और निम्न आय वाले देशों के बीच पहुंच में संभावित अंतर (एम. साल्वाग्नो एट अल., 2023)।

5.4.5. संवादी प्रणालियाँ

मानव-सदृश ज्ञान हस्तांतरण और संचार के लिए चिकित्सा और स्वास्थ्य सेवा सहित विभिन्न क्षेत्रों में चैटबॉट का उपयोग किया जा रहा है। विशेष रूप से, जटिल संवादों को प्रबंधित करने और बातचीत में लचीलापन प्रदान करने की क्षमता के साथ, मशीन लर्निंग को स्वास्थ्य देखभाल में लागू दिखाया गया है। यह समीक्षा कैंसर थेरेपी पर केंद्रित है, जिसमें निदान, उपचार, निगरानी, रोगी सहायता, कार्यप्रवाह दक्षता और स्वास्थ्य संवर्धन की विस्तृत चर्चा और उदाहरण शामिल हैं। इसके अलावा, नैतिक, सुरक्षा, तकनीकी और नियामक मुद्दों पर प्रकाश डालते हुए सीमाओं और चिंता के क्षेत्रों का पता लगाया जाता है (जू, एल. एट अल., 2021)।

मशीन लर्निंग (एमएल) अनुभव के माध्यम से स्वचालन के लिए कंप्यूटर एल्गोरिदम का अध्ययन है। स्वास्थ्य देखभाल संचार में एमएल का अनुप्रयोग मनुष्यों के लिए फायदेमंद साबित हुआ है। इसमें COVID-19 में स्वास्थ्य शिक्षा, कैंसर थेरेपी और मेडिकल इमेजिंग के लिए चैटबॉट शामिल हैं। समीक्षा इस बात पर प्रकाश डालती है कि स्वास्थ्य देखभाल संचार में एमएल/एआई का अनुप्रयोग जटिल संवाद प्रबंधन और संवादात्मक लचीलेपन सहित मनुष्यों को कैसे लाभान्वित करने में सक्षम है (सरकार सिद्धीकी और जेम्स सी. एल. चाउ, 2021)।

यह आलेख डेटा विज्ञान में चैटजीपीटी के उपयोग से जुड़े अवसरों और चुनौतियों का अवलोकन प्रदान करता है। इसमें चर्चा की गई है कि चैटजीपीटी डेटा वैज्ञानिकों को डेटा सफाई और प्रीप्रोसेसिंग, मॉडल प्रशिक्षण और परिणाम व्याख्या सहित उनके वर्कफ्लो के विभिन्न पहलुओं को स्वचालित करने में कैसे सहायता कर सकता है। यह इस बात पर भी प्रकाश डालता है कि कैसे चैटजीपीटी नई अंतर्दृष्टि प्रदान करने और निर्णय लेने की प्रक्रियाओं में सुधार करने की क्षमता रखता है (होसैन हसनी और ई. सिल्वा, 2023)।

5.4.6. जोखिम

इस तकनीक ने सामग्री निर्माण और लेखन पर आधारित कई उद्योगों की नींव हिला दी है, इसलिए चैटजीपीटी और अन्य कृत्रिम बुद्धिमत्ता भाषा मॉडल (ए. कैस्टेलानोस-गोमेज़, 2023) के साथ वैज्ञानिक लेख लिखने के लिए अच्छे अभ्यासों पर चर्चा करना उचित है। इस तकनीक के उपयोग और इसे कैसे किया जाना चाहिए, इस पर राय के विभिन्न स्रोत हैं।

ये भाषा मॉडल अपने पूर्ववर्तियों की तुलना में तर्क, ज्ञान प्रतिधारण और प्रोग्रामिंग में महत्वपूर्ण प्रगति दिखाते हैं। हालाँकि, ये सुधार नई सुरक्षा चुनौतियाँ भी लाते हैं, जिनमें हानिकारक सामग्री, गलत सूचना और साइबर सुरक्षा जैसे जोखिम शामिल हैं। शमन उपायों के बावजूद, मॉडल में इसके पिछले संस्करणों की तरह ही समान सीमाएँ बनी हुई हैं, जैसे पक्षपातपूर्ण और अविश्वसनीय सामग्री का निर्माण। इसके अलावा, इसकी बढ़ी हुई स्थिरता उत्पन्न सामग्री को अधिक विश्वसनीय बना सकती है और इसलिए संभावित रूप से अधिक खतरनाक हो सकती है (ओपनएआई, 2023)। इन मॉडलों के उपयोग में विचार किए जाने वाले जोखिम सूचीबद्ध हैं। हमेशा की तरह, जो व्यक्ति इन उपकरणों का उपयोग करता है वह अंततः जिम्मेदार होगा, क्योंकि, आज तक, उत्पन्न की पूरी निगरानी करता है

इसकी पुष्टि के लिए सामग्री आवश्यकता से अधिक है:

- गलत सूचना.
- हानिकारक सामग्री.
- प्रदर्शन, असाइनमेंट और सेवा की गुणवत्ता को नुकसान।
- दुष्प्रचार और प्रभाव संचालन।
- पारंपरिक और गैर-पारंपरिक हथियारों का प्रसार।
- गोपनीयता।
- साइबर सुरक्षा।

- अन्य प्रणालियों के साथ सहभागिता.
- आर्थिक प्रभाव.
- अत्यधिक निर्भरता.

गाओ एट अल के अनुसार. (2023) चैटजीपीटी द्वारा उत्पन्न वैज्ञानिक सार की तुलना एक कृत्रिम बुद्धिमत्ता आउटपुट डिटेक्टर, एक साहित्यिक चोरी डिटेक्टर और ब्लाइंड पीयर समीक्षा का उपयोग करके मूल सार के साथ की गई थी। परिणामों से पता चला कि चैटजीपीटी-जनरेटेड सार स्पष्ट रूप से लिखे गए थे, लेकिन केवल 8% ने जर्नल-विशिष्ट स्वरूपण आवश्यकताओं का पालन किया। हालाँकि उत्पन्न सार-संक्षेप मौलिक थे और साहित्यिक चोरी का कोई पता नहीं चला था, उन्हें अक्सर एआई आउटपुट डिटेक्टर का उपयोग करके और संदेहपूर्ण मानव समीक्षकों द्वारा पहचाना जाता था। निष्कर्ष यह है कि चैटजीपीटी विश्वसनीय वैज्ञानिक सार लिखता है, हालांकि, यह उत्पन्न सामग्री की सटीकता, पूर्णता और मौलिकता के संबंध में नैतिक मुद्दों और चुनौतियों को भी उठाता है।

6. कॉल 2

बड़े भाषा मॉडल (एलएलएम) उद्यम स्तर पर बहुत आशाजनक साबित हुए हैं। यह मेटा कंपनी का मामला है, जिसने कृत्रिम बुद्धिमत्ता पर अपने दृष्टिकोण के तहत इसके विकेंद्रीकरण की मांग की है, जहां संगठन अपने आभासी सहायकों को अनुकूलित कर सकते हैं और ओपन-सोर्स मॉडल को विशेषज्ञ ज्ञान के साथ प्रशिक्षित किया जा सकता है। यही कारण है कि मार्क जुकरबर्ग के नेतृत्व में नवाचार और प्रौद्योगिकी बाजार में अग्रणी मेटा ने अपने जेनरेटिव एआई टूल लामा 2 (टॉब्रॉन, एच एट अल., 2023) को पेश करने के लिए माइक्रोसॉफ्ट एज्योर के साथ साझेदारी की है, जिसे चैटजीपीटी और बार्ड को अलग करने वाला प्रतिद्वंद्वी माना जाता है। स्वयं एक खुला स्रोत है न कि बंद उत्पाद, जहां ऐसे एलएलएम को सुरक्षा और निजी जानकारी को दांव पर लगाते हुए बड़े पैमाने पर मानवीय प्राथमिकताओं के अनुसार समायोजित किया जाता है।

6.1. लामा 2 क्या है और इसकी विशेषताएं क्या हैं?

लामा 2 जेनरेटिव ट्रांसफार्मर मॉडल का उपयोग करके पूर्व-प्रशिक्षित और ट्यून किए गए एलएलएम का एक परिवार है, जहां सार्वजनिक रूप से उपलब्ध डेटा लिया गया है और लामा 1 संस्करण के संबंध में संदर्भ लंबाई 40% तक बढ़ा दी गई है। मॉडल के वेरिएंट, 7बी, 13बी, 34बी और 70बी के पैरामीटर वाले संस्करण, ओपन-सोर्स समुदायों के लिए उपलब्ध कराए गए हैं। लामा 2 मुफ्त लाइसेंस और अप्रतिबंधित वितरण के एक मॉडल का पालन करता है, जो विभिन्न डोमेन के लिए कई अवसर पैदा करता है (टॉब्रॉन, एच. एट अल., 2023)। तालिका 3 विभिन्न लामा 2 मॉडल दिखाती है।

तालिका 3. मॉडल लामा 2 वास्तुकला।

मॉडल पैरामीटर आकार	पूर्व प्रशिक्षित	चैट उपयोग के मामलों के लिए ठीक-ठीक ट्यून किया गया
7 बी	मॉडल आर्किटेक्चर प्रीट्रेनिंग	सहायता और सुरक्षा के लिए डेटा संग्रह, पर्यवेक्षित फाइन-ट्यूनिंग: 100,000 से अधिक हुमा प्राथमिकताएँ: 1,000,000 से अधिक
13बी	टोकन: 2 ट्रिलियन संदर्भ लंबाई:	
70बी	4096	

6.2. विशेषताएँ

प्रौद्योगिकी ढेर: लामा 2 अपने संचालन के लिए एक मजबूत प्रौद्योगिकी स्टैक का उपयोग करता है, जो प्राकृतिक भाषा प्रसंस्करण से लेकर कम्प्यूटेशनल दक्षता तक के उपकरणों और पुस्तकालयों का लाभ उठाता है। इस स्टैक में शामिल कुछ प्रमुख प्रौद्योगिकियाँ इस प्रकार हैं:

- पायथन: डेटा विज्ञान और मशीन लर्निंग समुदाय में प्रमुख प्रोग्रामिंग भाषा। इसका उपयोग लामा 2 में कोड को विकसित करने और निष्पादित करने के लिए किया जाता है, जो स्पष्ट और कुशल वाक्यविन्यास की अनुमति देता है।
- PyTorch: एक व्यापक रूप से उपयोग की जाने वाली गहन शिक्षण लाइब्रेरी। Llama 2 भाषा मॉडल बनाने और प्रशिक्षित करने के साथ-साथ तंत्रिका नेटवर्क और टेंसर पर संचालन करने के लिए PyTorch का लाभ उठाता है (Paszke, A. et al., 2019)।
- कॉन्डा: एक पैकेज और पर्यावरण प्रबंधन प्रणाली जो विशिष्ट परियोजनाओं के लिए पृथक वातावरण बनाना संभव बनाती है। लामा 2 में, कॉन्डा उपयोग किए गए पुस्तकालयों की निर्भरता और संस्करणों को प्रबंधित करना संभव बनाता है, जिससे विकास के माहौल में स्थिरता सुनिश्चित होती है (चैपलिन, जे. आर., एट अल., 2012)।
- Google/SentencePiece: SentencePiece कई भाषाओं में पाठ के टोकननाइजेशन और विभाजन के लिए एक लाइब्रेरी है। Llama 2 पाठ विभाजन कार्य के लिए Google/SentencePiece को नियोजित करता है, जो भाषा प्रसंस्करण और मॉडलिंग के लिए आवश्यक है (कुडो, टी., एट अल., 2018)।
- फेयरस्केल: एक लाइब्रेरी जो मल्टी-जीपीयू वातावरण में PyTorch की स्केलेबिलिटी और प्रदर्शन में सुधार करती है। लामा 2 हार्डवेयर संसाधन उपयोग को अनुकूलित करने के लिए फेयरस्केल का लाभ उठाता है, जो कुशल संचालन के लिए महत्वपूर्ण है (मियाओ, एक्स, एट अल., 2022)।

यह प्रौद्योगिकी स्टैक लामा 2 को प्राकृतिक भाषा प्रसंस्करण और पीढ़ी से संबंधित कार्यों की एक विस्तृत श्रृंखला को संबोधित करने में उच्च स्तर के प्रदर्शन, दक्षता और कार्यक्षमता प्राप्त करने में सक्षम बनाता है।

प्रशिक्षण हार्डवेयर: लामा 2 मॉडल मेटा के रिसर्च सुपरक्लस्टर (आरएससी) के साथ-साथ आंतरिक उत्पादन क्लस्टर पर प्री-ट्रेनिंग करता है। दोनों क्लस्टर NVIDIA A100 द्वारा संचालित हैं, जो सबसे उन्नत डेटा केंद्रों में कृत्रिम बुद्धिमत्ता, डेटा एनालिटिक्स और उच्च-प्रदर्शन कंप्यूटिंग (HPC) को शक्ति प्रदान करते हुए, बोर्ड भर में त्वरण का एक बेजोड़ स्तर प्रदान करता है। NVIDIA एम्पीयर आर्किटेक्चर द्वारा संचालित A100, NVIDIA के डेटा सेंटर प्लेटफॉर्म के दिल के रूप में खड़ा है। पिछली पीढ़ी के 20 गुना प्रदर्शन के साथ, ए100 में सात जीपीयू उदाहरणों में विभाजित होने की बहुमुखी प्रतिभा है, जो बदलती मांगों के लिए गतिशील रूप से अनुकूल है (गैल्वेज़ वैलेजो, जे.एल., एट अल. 2023)। इस तुलना में, इन दोनों समूहों के बीच दो मूलभूत अंतर सामने आते हैं। सबसे पहले, उपलब्ध इंटरकनेक्शन का प्रकार है: आरएससी एनवीआईडीआईए क्वांटम इनफिनीबैंड तकनीक का उपयोग करता है, जबकि उत्पादन क्लस्टर सामान्य प्रयोजन ईथरनेट स्विच के आधार पर आरओसीई (आरडीएमए ओवर कन्वर्ज्ड ईथरनेट) समाधान से लैस है। दोनों समाधान 200 जीबीपीएस एंडपाइंट इंटरकनेक्शन सक्षम करते हैं।

दूसरा अंतर प्रति जीपीयू बिजली खपत सीमा में है: जबकि आरएससी की सीमा 400W है, हमारा उत्पादन क्लस्टर 350W प्रति जीपीयू की सीमा के साथ काम करता है। इस दो-क्लस्टर कॉन्फिगरेशन ने बड़े पैमाने पर प्रशिक्षण के लिए इन विभिन्न इंटरकनेक्ट प्रकारों की उपयुक्तता पर सार्थक तुलना को सक्षम किया है। प्रासंगिक रूप से, आरओसीई दृष्टिकोण, एक अधिक किफायती वाणिज्यिक इंटरकनेक्ट समाधान होने के नाते, सबसे अलग है (टॉब्रॉन, एच. एट अल., 2023)।

कार्बन पदचिह्न

मेटा और लामा 2 के बीच उत्कृष्ट विभेदकों में से एक कार्बन पदचिह्न संकेतकों को प्रभावित करने की इसकी क्षमता है। कॉर्पोरेट पर्यावरणीय जिम्मेदारी ने ऊर्जा खपत के अध्ययन को प्रेरित किया है

GPU द्वारा प्रति घंटा उत्पन्न। पूर्व-प्रशिक्षण चरण के दौरान, निम्नलिखित खपत और कार्बन पदचिह्न डेटा प्राप्त किए गए थे (टौब्रान, एच. एट अल., 2023)। तालिका 4 पूर्व-प्रशिक्षण के दौरान उत्सर्जन को दर्शाती है:

तालिका 4. पूर्व-प्रशिक्षण के दौरान उत्सर्जन

नमूना	समय (जीपीयू घंटे)	बिजली की खपत (डब्ल्यू)	उत्सर्जित कार्बन (tCO ₂ eq)
7 बी	184320	400	31.22
13बी	368640	400	62.44
34बी	1038336	350	153.90
70बी	1720320	400	291.42
कुल	3311616		539.00

मॉडल मूल्यांकन

लामा 2 मॉडल निम्नलिखित विषयों पर अच्छा प्रदर्शन करता है:

- कोड जनरेशन: लामा 2 का उपयोग करके पायथन में एक कोड परीक्षण सत्यापन किया गया था।

Prompt: Calculate the factorial of a given number using Python.

Response:

```
def factorial(n):
    if n == 0 or n == 1:
        return 1
    else:
        return n * factorial(n - 1)

number = 5
result = factorial(number)
print(f"The factorial of {number} is {result}")
```

चित्र 8. कोड जनरेशन का उदाहरण.

- तर्क और सामान्य ज्ञान: लामा 2 का उपयोग करके तर्क अभ्यास का एक परीक्षण सत्यापन किया गया।

Prompt: If you have three dogs, four cats, and one duck, how many total legs do all the animals have?

Response: You can calculate the total number of legs by adding up the legs of each type of animal:

Three dogs have $3 * 4 = 12$ legs. Four cats have $4 * 4 = 16$ legs. One duck has 2 legs. Adding up all the legs: 12 (dogs) + 16 (cats) + 2 (duck) = 30 legs in total.

चित्र 9. तर्क का उदाहरण.

- वैश्विक ज्ञान: लामा 2 का उपयोग करके वैश्विक स्तर पर सामान्य संस्कृति विषयों पर एक सत्यापन परीक्षण किया गया।

Prompt: When did World War II end?

Response: World War II ended on September 2, 1945, when Japan formally surrendered to the Allied Powers, marking the official conclusion of the global conflict.

चित्र 10. विश्व संस्कृति का उदाहरण।

- समझबूझ कर पढ़ना: लामा 2 का उपयोग करके पढ़ने की समझ वाले विषयों पर एक सत्यापन परीक्षण किया गया था।

Prompt: "Create a Title from the Following Text: In the beginning, God created the heavens and the earth. 2. The earth was chaos and confusion and darkness above the abyss, and a wind of God fluttered over the waters."

Response: Creation, Chaos, and Divine Presence.

चित्र 11. पढ़ने की समझ का उदाहरण।

- अंक शास्त्र: गणना क्षमता के लिए लामा 2 का उपयोग करके एक सत्यापन परीक्षण किया गया था।

Prompt: You have a circle with a radius of length 7 units. What is the area of the circle?

Response: To calculate the area of a circle, we can use the formula for the area of a circle, which is expressed as:

$$Area = \pi \times Radius^2$$

Given that the radius is 7 units, we can substitute that value into the formula:

$$Area = \pi \times 7^2 \quad Area = \pi \times 49$$

Using an approximate value of π as 3.14159, we can calculate the area:


$$Area \approx 3.14159 \times 49 \quad Area \approx 153.93804$$

Therefore, the area of the circle with a radius of length 7 units is approximately 153.93804 square units.

चित्र 12. गणना क्षमता का उदाहरण।

6.3. लामा 2 प्रशिक्षण वास्तुकला और प्रक्रिया

लामा 2 प्रशिक्षण प्रक्रिया आर्किटेक्चर का एक नया संयोजन है, जैसे ट्रांसफॉर्मर-आधारित पूर्व-प्रशिक्षण और मानव प्रतिक्रिया (आरएलएफएच) आधारित ट्युनिंग के साथ सुदृढीकरण सीखना, जहां लामा 2 एलएलएम की सटीकता, सटीकता और सुरक्षा सर्वोपरि है। लामा 2 के निर्माण के लिए मेटा द्वारा उपयोग की जाने वाली पद्धति निम्नलिखित है (टॉब्रॉन, एच एट अल., 2023)। चित्र 13 लामा 2 मॉडल की प्रशिक्षण प्रक्रिया को दर्शाता है।



चित्र 13. प्रशिक्षण प्रक्रिया.

पूर्व प्रशिक्षण

मेटा के उत्पादों या सेवाओं से उत्पन्न होने वाले किसी भी डेटा को छोड़कर, लामा 2 सार्वजनिक रूप से उपलब्ध डेटा स्रोतों से पूर्व-प्रशिक्षण करता है। डेटा चयन प्रक्रिया के दौरान, वेब डेटा और विशेष डेटाबेस जैसे स्रोतों का उपयोग किया गया था। मॉडल को एक डेटासेट का उपयोग करके व्यापक प्रशिक्षण दिया गया जिसमें दो ट्रिलियन टोकन शामिल हैं और यह अपने पूर्ववर्ती, लामा 1 (जिओ, एफ, एट अल., 2023) की संदर्भ लंबाई से दोगुना प्रदर्शित करता है। यह डिज़ाइन विकल्प प्रदर्शन और कम्प्यूटेशनल लागत के बीच संतुलन बनाता है, जिसमें संभावित गलत सूचना और पूर्वाग्रह के मुद्दों को कम करते हुए ज्ञान में सुधार करने के लिए सबसे तथ्यात्मक स्रोतों से नमूने लेने पर जानबूझकर जोर दिया जाता है (टॉब्रॉन, एच एट अल., 2023)।

मॉडल में एक मानक ट्रांसफॉर्मर आर्किटेक्चर (वासवानी एट अल., 2017) है, जो आरएमएसनॉर्म (सेनरिच, आर एट अल., 2019) और स्विग्लू सक्रियण फंक्शन (शज़ीर, एन. एट अल., 2020) के साथ प्रीनॉर्मलाइज़ेशन का उपयोग करता है। इसके अलावा, यह रोटेशनल पोजिशनल एंबेडिंग्स (आरओपीई) को एकीकृत करता है (टॉब्रॉन, एच. एट अल., 2023)।

लामा 1 और लामा 2 के बीच मुख्य अंतर बड़ी हुई संदर्भ लंबाई और समूहीकृत क्वेरी ध्यान (जीक्यूए) को अपनाने में निहित है। ये वास्तुशिल्प संशोधन भाषा निर्माण कार्यों के दौरान लंबी प्रासंगिक जानकारी को संभालने की क्षमता बढ़ाने में योगदान करते हैं (टॉब्रॉन, एच. एट अल., 2023)। नीचे, तालिका 5 मॉडल की विशेषताओं को दर्शाती है।

तालिका 5. पूर्व-प्रशिक्षण विशेषताएँ।

	प्रशिक्षण डेटा	पैरामीटर	प्रसंग लंबाई	टोकन
कॉल 1	डेटासेट (टॉब्रॉन, एच एट अल., 2023)।	7 बी	2k	1.0टी
		13बी	2k	1.0टी
		33बी	2k	1.4टी
		65बी	2k	1.4टी
कॉल 2	ऑनलाइन डेटा	7 बी	4k	2.0टी
		13बी	4k	2.0टी
		34बी	4k	2.0टी
		70बी	4k	2.0टी

कॉल 2 फ़ाइन ट्यूनिंग:

कॉल 2 प्रारंभ में सार्वजनिक रूप से उपलब्ध ऑनलाइन डेटा का उपयोग करके प्रशिक्षित किया गया था। तब पर्यवेक्षित ट्यूनिंग का उपयोग करके लामा-2-चैट का प्रारंभिक संस्करण तैयार किया गया था। इसके बाद, लामा-2-चैट को मानव प्रतिक्रिया (आरएलएचएफ) के आधार पर प्रबलित शिक्षण को नियोजित करके पुनरावृत्त रूप से परिष्कृत किया गया, जिसमें अस्वीकृति नमूनाकरण और समीपस्थ नीति अनुकूलन (पीपीओ) (ट्वरान, एच। एट अल।, 2023) जैसी तकनीकें शामिल हैं।

हालांकि ऐसे डेटा प्रदान करने वाले कई स्रोत हैं, लेकिन उनकी सीमित विविधता और गुणवत्ता ने उच्च गुणवत्ता वाली सक्रिय और निष्क्रिय आवाज़ (ओएफवी) उदाहरणों के संग्रह को प्राथमिकता दी है, जिससे महत्वपूर्ण सुधार हुए हैं।

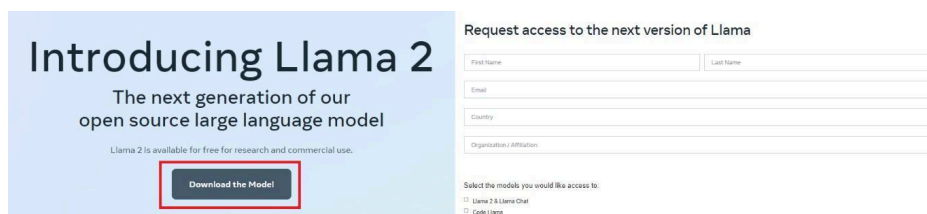
मानव प्रतिक्रिया के साथ सुदृढीकरण सीखना (आरएलएचएफ) एक मॉडल प्रशिक्षण दृष्टिकोण का प्रतिनिधित्व करता है जिसका उद्देश्य मानव प्राथमिकताओं और निर्देशों के साथ एक ट्यून किए गए भाषा मॉडल के व्यवहार को और संरेखित करना है। इसे प्राप्त करने के लिए, दो मॉडल-जनित परिणामों के बीच चयन के माध्यम से मानव वरीयता डेटा एकत्र किया जाता है, जो एक इनाम मॉडल के प्रशिक्षण में योगदान देता है जो अधिमान्य विकल्पों को स्वचालित करता है (मैरोटो-गोमेज़, एम. एट अल., 2023)।

इनाम मॉडल की आवश्यक भूमिका मानव प्रतिक्रिया (आरएलएचएफ) के साथ सुदृढीकरण सीखने के संदर्भ में प्रकट होती है। इस प्रक्रिया में, इनाम मॉडल मॉडल-जनित प्रतिक्रिया और उसके संबंधित संकेत का मूल्यांकन करता है, जिसके परिणामस्वरूप एक संख्यात्मक स्कोर प्राप्त होता है जो उपयोगिता और सुरक्षा के संदर्भ में गुणवत्ता को दर्शाता है। इन प्रतिक्रिया स्कोरों को पुरस्कार के रूप में उपयोग करके, आरएलएचएफ प्रक्रिया का लक्ष्य लामा 2 चैट को मानवीय प्राथमिकताओं के साथ अपने व्यवहार को संरेखित करने, उपयोगिता और सुरक्षा दोनों में सुधार करने के लिए अनुकूलित करना है (टौब्रॉन, एच. एट अल., 2023)।

6.4. इसे कैसे स्थापित करें?

किसी उपयोगकर्ता को पूर्व-प्रशिक्षित मॉडल तक पहुंच प्राप्त करने के लिए, उन्हें मेटा की आधिकारिक वेबसाइट के माध्यम से अनुमति का अनुरोध करना आवश्यक है (<https://ai.meta.com/llama/>) और निर्दिष्ट नियमों और शर्तों से सहमत हैं। एक बार उनका अनुरोध स्वीकृत हो जाने पर, उन्हें एक ईमेल प्राप्त होता है जिसमें एक अद्वितीय, वैयक्तिकृत लिंक शामिल होता है। यह लिंक उपयोगकर्ता को मॉडल डाउनलोड करने की अनुमति देता है।

चित्र 14 आधिकारिक मेटा लामा 2 वेबसाइट पर पंजीकरण के लिए होम स्क्रीन को दर्शाता है।



Request access to the next version of Llama

First Name Last Name

Email

Country

Organization / Affiliation

Select the models you would like access to:

Llama 2 & Llama Chat

Code Llama

[Download the Model](#)

चित्र 14. लामा 2 स्थापना प्रक्रिया।

एक पायथन प्रोजेक्ट बनाने की अनुशंसा की जाती है, ताकि उपयोगकर्ता मॉडल को होस्ट करने वाले रिपॉजिटरी को क्लोन करने के लिए GitHub पर दिए गए URL का उपयोग कर सकें। इससे प्रोजेक्ट में उपयोग के लिए मॉडलों को उनके सिस्टम पर उपलब्ध कराना आसान हो जाता है। उपरोक्त सभी चरणों का पालन करके प्राप्त किया जा सकता है:



- आधिकारिक मेटा वेबसाइट के माध्यम से पहुंच का अनुरोध करें और लागू नियमों और शर्तों से सहमत हों।
- एक बार अनुरोध स्वीकृत हो जाने पर, उपयोगकर्ता को मॉडल डाउनलोड करने के लिए एक अद्वितीय, अनुकूलित लिंक वाला एक ईमेल प्राप्त होगा।
- एक नए पायथन प्रोजेक्ट में, GitHub URL का उपयोग मॉडल वाले रिपॉजिटरी को क्लोन करने के लिए किया जा सकता है।

- "download.sh" स्क्रिप्ट चलाएँ, जहाँ उपयोगकर्ता को अद्वितीय, कस्टम URL दर्ज करना होगा और डाउनलोड करने के लिए मॉडल का चयन करना होगा। डाउनलोड के लिए उपलब्ध विकल्पों में 7बी, 13बी, 70बी, चैट 7बी, चैट 13बी और चैट 70बी शामिल हैं।

नोट: यह अनुशंसा की जाती है कि उपयोगकर्ता के पास इन मॉडलों को प्रबंधित करने में सक्षम होने के लिए पर्याप्त भंडारण, प्रसंस्करण शक्ति, एक जीपीयू और पर्याप्त रैम हो।

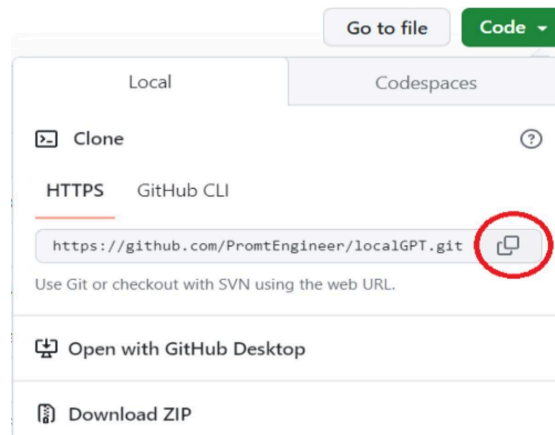
बायोइनफॉर्मेटिक्स, इंटेलिजेंट इंफॉर्मेशन सिस्टम और एजुकेशनल टेक्नोलॉजी (BISITE) अनुसंधान समूह स्थानीय स्तर पर लामा 2 मॉडल स्थापित करने में कामयाब रहा है। मॉडल को कैसे स्थापित करें और उसका अनुकूलित उपयोग कैसे करें, इस पर चरण-दर-चरण मार्गदर्शिका यहां दी गई है:

1. निःशुल्क एनाकोंडा वितरण स्थापित करें और एनाकोंडा प्रॉम्प्ट चलाएँ, चित्र 15 देखें:



चित्र 15. एनाकोंडा प्रॉम्प्ट चलाएँ।

2. भंडार तक पहुंचें <https://github.com/PromptEngineer/localGPT>, जहां क्रेडिट (प्रॉम्प्टइंजीनर, जीथब) को दिया गया है और लिंक को कॉपी करें: <https://github.com/PromptEngineer/localGPT.git>, चित्र 16 देखें।



चित्र 16. GitHub रिपॉजिटरी की प्रतिलिपि बनाएँ।

3. अपने कंप्यूटर पर अपनी पसंद के स्थान पर एक फ़ोल्डर बनाएं और GitHub क्लोन बनाएं, चित्र 17 देखें।

```
Anaconda Prompt
(base) C:\Users\juanm\Documents>cd DemoLlama
(base) C:\Users\juanm\Documents\DemoLlama>git clone https://github.com/PromptEngineer/LocalGPT.git local_llama2
git clone https://github.com/PromptEngineer/LocalGPT.git local_llama2
```

चित्र 17. स्थानीय स्तर पर GitHub क्लोन करें।

4. कॉनडा वातावरण बनाने के लिए निम्नलिखित कमांड निष्पादित करें, चित्र 18 देखें:

```
Anaconda Prompt
(base) C:\Users\juanm>cd Documents
(base) C:\Users\juanm\Documents>cd Demollama
(base) C:\Users\juanm\Documents\DemoLlama>cd local_llama2
(base) C:\Users\juanm\Documents\DemoLlama\local_llama2>conda create -n local_llama2 python= 3.11.4
```

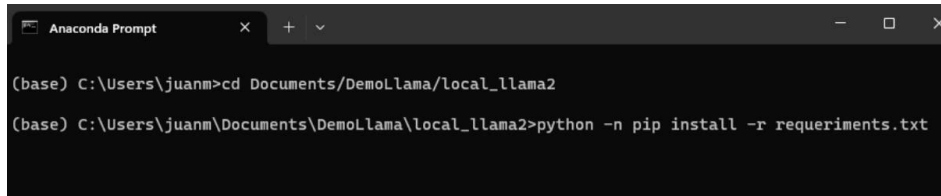
चित्र 18. आवश्यकताओं को स्थापित करने के लिए एक कॉनडा वातावरण बनाएं।

5. स्थानीय लामा 2 मॉडल को एम्बेड करने में सक्षम होने के लिए प्रशिक्षित होने के लिए फ़ाइल या दस्तावेज़ और उपरोक्त सभी दर्ज करें। इस फ़ाइल को SOURCE_DOCUMENTS फ़ोल्डर में रखा जाना चाहिए, चित्र 19 देखें।

Name	Date modified	Type	Size
.github	8/2/2023 4:55 AM	File folder	
__pycache__	8/2/2023 6:35 AM	File folder	
DB	8/29/2023 7:58 AM	File folder	
localGPTUI	8/2/2023 4:55 AM	File folder	
SOURCE_DOCUMENTS	8/3/2023 3:03 AM	File folder	
.editorconfig	8/2/2023 4:55 AM	Editor Config Source File	1 KB
.flake8	8/2/2023 4:55 AM	FLAKE8 File	1 KB
.gitignore	8/2/2023 4:55 AM	Git Ignore Source File	4 KB
.pre-commit-config.yaml	8/2/2023 4:55 AM	Yaml Source File	2 KB
.pyup.yml	8/2/2023 4:55 AM	Yaml Source File	1 KB
ACKNOWLEDGEMENT.md	8/2/2023 4:55 AM	Markdown Source File	1 KB
constants.py	8/2/2023 4:55 AM	Python File	2 KB
CONTRIBUTING.md	8/2/2023 4:55 AM	Markdown Source File	3 KB
ingest.py	8/2/2023 4:55 AM	Python File	6 KB
LICENSE	8/2/2023 4:55 AM	File	12 KB
pyproject.toml	8/2/2023 4:55 AM	Toml Source File	1 KB
README.md	8/2/2023 4:55 AM	Markdown Source File	13 KB
requirements.txt	8/2/2023 4:55 AM	Text Document	1 KB
run_localGPT.py	8/2/2023 4:55 AM	Python File	10 KB

चित्र 19. प्रशिक्षित होने के लिए फ़ाइल डालें।

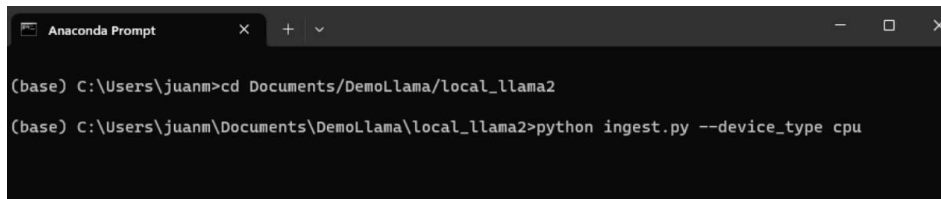
6. आवश्यकता फ़ाइल के अनुसार पैकेज स्थापित करें: कुछ पैकेज हैं: पाइटोरच, लैंगचैन, क्रोमैडब, वाक्य-ट्रांसफॉर्मर, हगिंगफैस हब (आवश्यकताएँ.txt फ़ाइल देखें), चित्र 20 देखें।



```
Anaconda Prompt
(base) C:\Users\juanm>cd Documents/DemoLlama/local_llama2
(base) C:\Users\juanm\Documents\DemoLlama\local_llama2>python -n pip install -r requirements.txt
```

चित्र 20. लामा 2 पैकेज स्थापित करना और आवश्यकताएँ।

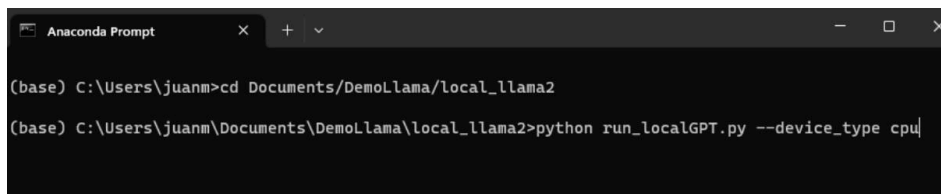
7. प्रशिक्षित की जाने वाली फ़ाइल से डेटा को मॉडल में शामिल किया जाना चाहिए और निम्नलिखित निर्देशों का पालन किया जाना चाहिए, चित्र 21 देखें:



```
Anaconda Prompt
(base) C:\Users\juanm>cd Documents/DemoLlama/local_llama2
(base) C:\Users\juanm\Documents\DemoLlama\local_llama2>python ingest.py --device_type cpu
```

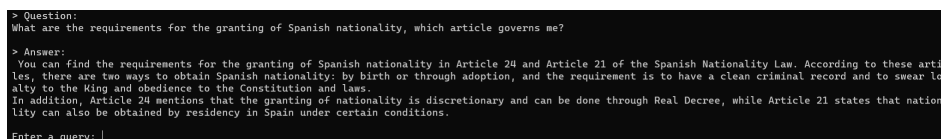
चित्र 21. लामा 2 मॉडल में डेटा अंतर्ग्रहण।

8. मॉडल को निष्पादित करने और अनुरोध या क्वेरी करने के लिए निम्नलिखित कमांड का उपयोग किया जाता है, चित्र 22, 23 देखें:



```
Anaconda Prompt
(base) C:\Users\juanm>cd Documents/DemoLlama/local_llama2
(base) C:\Users\juanm\Documents\DemoLlama\local_llama2>python run_localGPT.py --device_type cpu
```

चित्र 22. लामा 2 मॉडल में अनुरोध करना।



```
> Question:
What are the requirements for the granting of Spanish nationality, which article governs me?
> Answer:
You can find the requirements for the granting of Spanish nationality in Article 24 and Article 21 of the Spanish Nationality Law. According to these articles, there are two ways to obtain Spanish nationality: by birth or through adoption, and the requirement is to have a clean criminal record and to swear loyalty to the King and obedience to the Constitution and laws.
In addition, Article 24 mentions that the granting of nationality is discretionary and can be done through Real Decree, while Article 21 states that nationality can also be obtained by residency in Spain under certain conditions.
Enter a query: |
```

चित्र 23. सत्यापन परीक्षण।

6.5. मामलों का प्रयोग करें

जेनेरिक एआई के विकेंद्रीकरण और सामाजिक नेटवर्क पर अपमानजनक और यौन भाषा वाले लोगों की सुरक्षा और पता लगाने पर केंद्रित अनुसंधान के साथ कई अनुप्रयोग आकार लेने लगे हैं, जहां संरक्षित की जाने वाली आबादी बच्चे और किशोर हैं (गुयेन, टी. टी, आदि) अल., 2023). स्वास्थ्य क्षेत्र में, जेनेरिक एआई के माध्यम से चिकित्सा सहायकों के दृष्टिकोण से जो प्रगति प्रस्तुत की जा रही है वह स्पष्ट है। यह ली, वाई., एट अल., 2023 का मामला है, जिन्होंने एक संगठन के चिकित्सकों के निदान और अनुभव के आधार पर एक विशेष चिकित्सा चैट लागू की है। चैटडॉक्टर लामा 2 को एक ढांचे के रूप में उपयोग करता है और रोगियों की जरूरतों, प्रतिदिन जारी होने वाली चिकित्सा राय से संचालित होता है, इस प्रकार मॉडल की सटीकता में सुधार होता है, और चिकित्सा प्रतिक्रियाओं में विश्वसनीयता पैदा होती है। वित्तीय संदर्भ में, पाठ से सबसे महत्वपूर्ण संकेतक निकालने और संबंधित विश्लेषण करने के लिए वित्तीय समाचारों के विश्लेषण के लिए लामा 2 पर आधारित एलएलएम को परिष्कृत किया जाता है (पावलीशेंको, 2023)।

7. निष्कर्ष

प्रसार तकनीकों का उपयोग करने वाले जनरेटिव मॉडल ने कई डोमेन में संभावनाएं खोली हैं, विशेष रूप से उच्च-निष्ठा वाले पाठ, ऑडियो और वीडियो उत्पादन में। उनके संभाव्य ढांचे डेटा के भीतर जटिल और सूक्ष्म संबंधों को पकड़ सकते हैं, जिससे अत्यधिक यथार्थवादी परिणाम उत्पन्न होते हैं (रोमबैक एट अल., 2022; हुआंग एट अल., 2023)। पाठ्य डेटा के लिए, इसमें अर्थ संबंधी सुसंगतता से लेकर वाक्यात्मक परिष्कार तक सब कुछ शामिल है। ऑडियो में, यह स्पष्ट वाक्-संश्लेषण और वाक्-से-पाठ रूपांतरण अनुप्रयोगों की ओर ले जाता है (विलियम्स, 2023)। वीडियो में, एल्गोरिदम उच्च-परिभाषा, अस्थायी रूप से सुसंगत वीडियो क्लिप उत्पन्न करते हैं (टेट, 2023)।

OpenAI द्वारा विकसित बड़े भाषा मॉडल (एलएलएम) की श्रृंखला ने प्राकृतिक भाषा प्रसंस्करण के क्षेत्र में क्रांति ला दी है। GPT-4 और ChatGPT जैसे मॉडलों ने सुसंगत पाठ उत्पन्न करने, संदर्भ को समझने और विविध कार्यों को अनुकूलित करने की प्रभावशाली क्षमता का प्रदर्शन किया है। हालांकि, जैसे-जैसे ये मॉडल आगे बढ़ते हैं, वैसे-वैसे इनके उपयोग से जुड़ी नैतिक और तकनीकी चुनौतियाँ भी बढ़ती हैं।

पूर्वाग्रह को कम करने, उपयोगकर्ता की गोपनीयता की रक्षा करने और डेटा सुरक्षा सुनिश्चित करने के लिए अनुसंधान जारी रखना और प्रभावी रणनीति विकसित करना महत्वपूर्ण है। जैसे-जैसे ये मॉडल रोजमर्रा की जिंदगी में अधिक एकीकृत होते जा रहे हैं, जिम्मेदार उपयोग के लिए स्पष्ट नियमों और दिशानिर्देशों की आवश्यकता होती है। जेनेरिक एआई के क्षेत्र में उद्यम करने से प्रोग्रामिंग से लेकर अकादमिक प्रकाशनों तक विभिन्न डोमेन में इन मॉडलों के अनुप्रयोग में महत्वपूर्ण क्षमता का पता चलता है। हालांकि, उनकी सीमाओं के प्रति आलोचनात्मक और जागरूक होना आवश्यक है। अंततः, जेनेरिक एआई अनुसंधान का लक्ष्य ऐसे उपकरण बनाना होना चाहिए जो मानवता के लिए उपयोगी, सुरक्षित और फायदेमंद हों। GPT-4 और ChatGPT जैसे मॉडलों के साथ महत्वपूर्ण प्रगति के बावजूद, इस लक्ष्य को प्राप्त करने के लिए बहुत काम किया जाना बाकी है।

मेटा एआई द्वारा विकसित लामा 2, एक ओपन-सोर्स लार्ज लैंग्वेज मॉडल (एलएलएम) है जो स्थानीय डिवाइस पर दस्तावेजों के साथ इंटरैक्शन की सुविधा प्रदान करता है। इसकी ताकत उपयोगकर्ता की गोपनीयता सुनिश्चित करते हुए स्थानीय रूप से संचालित करने की क्षमता में निहित है। अपनी परिष्कृत प्रशिक्षण प्रक्रिया के माध्यम से, लामा 2 ने तर्क, कोडिंग और पढ़ने की समझ जैसे क्षेत्रों में उत्कृष्ट प्रदर्शन करते हुए विभिन्न बेंचमार्क परीक्षणों में उच्च प्रदर्शन का प्रदर्शन किया है। इंस्टॉलेशन के लिए कुछ सिस्टम आवश्यकताओं और तकनीकी विशेषज्ञता की आवश्यकता के बावजूद, लामा 2 विभिन्न हार्डिंग फेस एलएलएम मॉडल के साथ काम करने की अनुमति देकर महान बहुमुखी प्रतिभा प्रदान करता है। सामाजिक नेटवर्क पर बाल संरक्षण से लेकर चिकित्सा सहायकों और वित्तीय विश्लेषण तक के अनुप्रयोगों के साथ, लामा 2 प्राकृतिक भाषा-आधारित बातचीत के लिए नए अवसर खोलता है और एलएलएम क्षेत्र में एक महत्वपूर्ण सफलता का प्रतिनिधित्व करता है।

8. संदर्भ

- अब्दुल्ला, एम., मदैन, ए., और जरारवेह, वाई., 2022, नवंबर। चैटजीपीटी: बुनियादी बातें, अनुप्रयोग और सामाजिक प्रभाव। में सामाजिक नेटवर्क विश्लेषण, प्रबंधन और सुरक्षा पर 2022 नौवां अंतर्राष्ट्रीय सम्मेलन (एसएनएमएस) (पृ. 1-8). आईईईई।
<https://doi.org/10.1109/SNAMS58071.2022.10062688>
- अब्राहम, ए., कोरचाडो, ई., और कोरचाडो, जे.एम., 2009. हाइब्रिड लर्निंग मशीनें। न्यूरोकंप्यूटिंग: एक अंतर्राष्ट्रीय जर्नल, 72(13-15), 2729-2730. <https://doi.org/10.1016/j.neucom.2009.02.017>
- एडम्स, एल.सी., बुश, एफ., ड्रुहन्, डी., माकोव्स्की, एम.आर., एर्ट्स, एच.जे., और ब्रेसेम, के.के., 2023। DALL-E 2 रेडियोलॉजी के बारे में क्या जानता है? जर्नल ऑफ मेडिकल इंटरनेट रिसर्च, 25, e43110. <https://doi.org/10.1109/SNAMS58071.2022.10062688>
- अलीजादेहसानी, जेड., घेमी, एच., शाहराकी, ए., गोंजालेज-ब्रियोन्स, ए., और कोर्चाडो, जे.एम., 2023. डीसीसर्वसीजी: गहन शिक्षण का उपयोग करके एक डेटा-केंद्रित सेवा कोड पीढ़ी। आर्टिफिशियल इंटेलिजेंस के इंजीनियरिंग अनुप्रयोग, 123, 106304. <https://doi.org/10.1016/j.engappai.2023.106304>
- बा, जे.एल., किरॉस, जे.आर., और हिंटन, जी.ई.। *arXiv* प्रीप्रिंट *arXiv:1607.06450*.
- बहदानौ, डी., चो, के., और बैंगियो, वाई., 2014. संयुक्त रूप से संरेखित और अनुवाद करना सीखकर तंत्रिका मशीन अनुवाद। *arXiv* प्रीप्रिंट *arXiv:1409.0473*.
- Baidoo-Anu, D., और Owusu Ansah, L., 2023, 25 जनवरी। जनरेटिव आर्टिफिशियल इंटेलिजेंस (AI) के युग में शिक्षा: शिक्षण और सीखने को बढ़ावा देने में ChatGPT के संभावित लाभों को समझना। उपलब्ध है एसएसआरएन. <https://doi.org/10.2139/ssrn.4337484>
- बेंडर, ई.एम., गेब्रु, टी., मैकमिलन-मेजर, ए., और शमिचेल, एस. (2021)। स्टोकेस्टिक तोते के खतरों पर: क्या भाषा मॉडल बहुत बड़े हो सकते हैं? में *FAccT* की कार्यवाही. <https://doi.org/10.1145/3442188.3445922>
- बेंगियो, वाई., 2009. एआई के लिए गहन आर्किटेक्चर सीखना। मशीन लर्निंग में नींव और रुझान®, 2(1), 1-127. <https://doi.org/10.1561/22000000006>
- ब्राउन, टी.बी., एट अल., 2020. भाषा मॉडल कम-शॉट सीखने वाले होते हैं। *arXiv* प्रीप्रिंट *arXiv:2005.14165*.
- बुबेक, एस., चन्द्रशेखरन, वी., एल्डन, आर., गेहरके, जे., होर्विटज़, ई., कमर, ई., ... और झांग, वाई., 2023। कृत्रिम सामान्य बुद्धि की चिंगारी: प्रारंभिक प्रयोग जीपीटी-4. *arXiv* प्रीप्रिंट *arXiv:2303.12712*.
- कैलिस्कन, ए., ब्रायसन, जे.जे., और नारायणन, ए., 2017. भाषा कॉर्पोरा से स्वचालित रूप से प्राप्त शब्दार्थ में मानव जैसे पूर्वाग्रह होते हैं। विज्ञान, 356(6334), 183-186. <https://doi.org/10.1126/science.aal4230>
- कैस्टेलानोस-गोमेज़, ए., 2023. चैटजीपीटी और अन्य कृत्रिम बुद्धिमत्ता भाषा मॉडल के साथ वैज्ञानिक लेख लेखन के लिए अच्छे अभ्यास। नैनो विनिर्माण, 3(2), 135-138 <https://doi.org/10.3390/nanomanufacturing3020009>
- चामोसो, पी., गोंजालेज-ब्रियोन्स, ए., रिवास, ए., डी ला प्रीटा, एफ., और कोरचाडो, जे.एम., 2019। मुद्रा विनिमय में सामाजिक कंप्यूटिंग। ज्ञान और सूचना प्रणाली, 61, 733-753. <https://doi.org/10.1007/s10115-018-1289-4>
- चान, डब्ल्यू.एच., मोहम्मद, एम.एस., डेरिस, एस., ज़की, एन., कासिम, एस., ओमातु, एस., कोरचाडो जे.एम. और अल अश्वल, एच., 2016। वेटिंग स्कीम के साथ एक बेहतर दंडित समर्थन वेक्टर मशीन का उपयोग करके सूचनात्मक जीन और मार्गों की पहचान। जीव विज्ञान और चिकित्सा में कंप्यूटर, 77, 102-115. <https://doi.org/10.1016/j.combiomed.2016.08.004>
- चांग, वाई., वांग, एक्स., वांग, जे., वू, वाई., झू, के., चेन, एच., ... और ज़ी, एक्स., 2023. बड़े भाषा मॉडल के मूल्यांकन पर एक सर्वेक्षण। *arXiv* प्रीप्रिंट *arXiv:2307.03109*.

- चैपलिन, जे.आर., हेल्पर, वी., फ़ार्ले, एफ.जे.एम., हर्न, जी.ई., और रेनी, आर.सी.टी., 2012. एनाकोंडा का प्रयोगशाला परीक्षण। रॉयल सोसाइटी ए के दार्शनिक लेनदेन: गणितीय, भौतिक और इंजीनियरिंग विज्ञान, 370(1959), 403-424। <https://doi.org/10.1098/rsta.2011.0256>
- चेन, डी., एट अल., 2019. बीईआरटी: भाषा समझ के लिए डीप बाईडायरेक्शनल ट्रांसफॉर्मर्स का पूर्व-प्रशिक्षण। *arXiv प्रीप्रिंट arXiv:1810.04805*.
- कोरचाडो जे.एम., 2023। वैश्विक कृत्रिम बुद्धिमत्ता का जागरण। रॉयल एकेडमी ऑफ मेडिसिन - सलामांका।
- कोर्चाडो, जे.एम., और ऐकेन, जे., 2002. समुद्र विज्ञान पूर्वानुमान मॉडल में हाइब्रिड कृत्रिम बुद्धिमत्ता विधियाँ। सिस्टम, मैम और साइबरनेटिक्स पर आईईईई लेनदेन, भाग सी (अनुप्रयोग और समीक्षा), 32(4), 307-313. <https://doi.org/10.1109/TSMCC.2002.806072>
- कोर्चाडो, जे.एम., चामोसो, पी., हर्नांडेज़, जी., गुटिरेज़, ए.एस.आर., कैमाचो, ए.आर., गोंजालेज़-ब्रियोन्स, ए., ... और ओमातु, एस., 2021. दीपिंट। नेट: स्मार्ट क्षेत्रों के लिए एक तीव्र तैनाती मंच। सेंसर, 21(1), 236. <https://doi.org/10.3390/s21010236>
- कोर्चाडो, जे.एम., डियाज़, एफ., बोरराजो, एल., और फर्नांडीज़, एफ., 2000। कृत्रिम तंत्रिका नेटवर्क. एक व्यावहारिक दृष्टिकोण. विगो विश्वविद्यालय की प्रकाशन सेवा।
- डेनी, पी., कुमार, वी., और जियाकामैन, एन., 2022। सह-पायलट के साथ बातचीत: प्राकृतिक भाषा का उपयोग करके *CSI* समस्याओं को हल करने के लिए त्वरित इंजीनियरिंग की खोज. <https://doi.org/10.1145/3545945.3569823>
- डेवलिन, जे., चांग, एम.डब्ल्यू., ली, के., और टुटानोवा, के., 2018. बर्ट: भाषा समझ के लिए गहरे द्विदिश ट्रांसफॉर्मर का पूर्व-प्रशिक्षण। *arXiv प्रीप्रिंट arXiv:1810.04805*.
- डियाज़, एफ., फर्नांडीज़-रिवेरोला, एफ., और कोरचाडो, जे.एम., 2006. जीन-सीबीआर: माइक्रोएरे डेटा सेट का उपयोग करके कैंसर निदान के लिए एक केस-आधारित रीज़निंग टूल। कम्प्यूटेशनल इंटेलिजेंस, 22(3-4), 254-268. <https://doi.org/10.1111/j.1467-8640.2006.00287.x>
- दोशी-वेल्लेज़, एफ., कॉर्टज़, एम., बुडिश, आर., बाविटज़, सी., गेर्शमैन, एस., ओ'ब्रायन, डी., ... और वाल्डो, जे., 2017. एआई की जवाबदेही के तहत कानून: स्पष्टीकरण की भूमिका. स्पष्टीकरण और कानून पर बर्कमैन क्लेन सेंटर वर्किंग ग्रुप, 21 <https://doi.org/10.2139/ssrn.3064761>
- एलॉडो, टी., मैनिंग, एस., मिशकिन, पी., और रॉक, डी., 2023. जीपीएस जीपीएस हैं: बड़े भाषा मॉडल की श्रम बाजार प्रभाव क्षमता पर एक प्रारंभिक नज़र। *arXiv प्रीप्रिंट arXiv:2303.10130*.
- फ़िनी-एंस्ले, जे., डेनी, पी., बेकर, बी.ए., लक्सटन-रेली, ए., और प्रैथर, जे., 2022। रोबोट आ रहे हैं: परिचयात्मक प्रोग्रामिंग पर ओपनएआई कोडेक्स के निहितार्थ की खोज. <https://doi.org/10.1145/3511861.3511863>
- <http://dx.doi.org/10.1037/0033-295X.101.2.211> गाला, वाई., फर्नांडीज़, ए., डियाज़, जे., और डोरोनसोरो, जे.आर. (2016)। न्यूरोकंप्यूटिंग, 176, 48-59.
- गैलवेज़ वैलेज़ो, जे.एल., स्नोडन, सी., स्टॉक्स, आर., काज़ेमियन, एफ., यान यू, एफ.सी., सीडल, सी., ... और बार्का, जी.एम., 2023. एक चरम-स्तरीय इलेक्ट्रॉनिक संरचना प्रणाली की ओर। रासायनिक भौतिकी जर्नल, 159(4). <https://doi.org/10.1063/5.0156399>
- गाओ, सी.ए., हॉवर्ड, एफ.एम., मार्कोव, एन.एस., डायर, ई., रमेश, एस., लुओ, वाई., पियर्सन, ए.टी., 2023. चैटजीपीटी द्वारा उत्पन्न वैज्ञानिक सार की तुलना डिटेक्टरों और अंधे मानव समीक्षकों के साथ वास्तविक सार से करना। एनपीजे अंक। साथ। 6, 75. <https://doi.org/10.1038/s41746-023-00819-6>
- गेरोन, ए. (2022)। स्किट-लर्न, केरास और टेन्सरफ्लो के साथ व्यावहारिक मशीन लर्निंग. ओरेली मीडिया, इंक.
- गोंजालेज़-ब्रियोन्स, ए., डी ला प्रीटा, एफ., मोहम्मद, एम.एस., ओमातु, एस., और कोरचाडो, जे.एम., 2018। ऊर्जा अनुकूलन समस्याओं में मल्टी-एजेंट सिस्टम अनुप्रयोग: एक अत्याधुनिक समीक्षा. ऊर्जा, 11(8), 1928. <https://doi.org/10.3390/en11081928>

- गुडफेलो, आई., बेंगियो, वाई., और कौरविल, ए., 2016। गहन शिक्षा. प्रेस के साथ.
- गुडफेलो, आई., पॉगेट-अबादी, जे., मिर्जा, एम., जू, बी., वार्डे-फ़ार्ले, डी., ओज़ैर, एस., ... और बेंगियो, वाई., 2014। जनरेटिव प्रतिकूल जाल। तंत्रिका संबंधी जानकारी में प्रगति प्रसंस्करण प्रणाली, 27.
- गुआन, डब्ल्यू., स्मेतानिकोव, आई., और तियानक्सिंग, एम., 2020, अक्टूबर। स्वचालित पाठ सारांश और ट्रांसफार्मर मॉडल प्रयोज्यता पर सर्वेक्षण। में नियंत्रण, रोबोटिक्स और इंटेलेजेंट सिस्टम पर 2020 प्रथम अंतर्राष्ट्रीय सम्मेलन की कार्यवाही (पृ. 176-184)। <https://doi.org/10.1145/3437802.3437832> हार्नोजा, टी., झोउ, ए., एबील, पी., और लेविन, एस., 2018. सॉफ्ट अभिनेता-आलोचक: एक स्टोकेस्टिक अभिनेता के साथ ऑफ-पॉलिसी अधिकतम एन्टापी गहन सुदृढीकरण सीखना। में 35वें इंटरनेशनल की कार्यवाही मशीन लर्निंग पर सम्मेलन (खंड 80, पृ. 1861-1870)।
- हाओ, के., 2020। हमने वह पेपर पढ़ा जिसने टिमनित गेब्रू को Google से बाहर कर दिया। यह वही है जो यह कहता है। एमआईटी प्रौद्योगिकी समीक्षा।
- हसनी, एच., सिल्वा, ई.एस., 2023. डेटा साइंस में चैटजीपीटी की भूमिका: कैसे एआई-असिस्टेड कन्वर्सेशनल इंटरफेस इस क्षेत्र में क्रांति ला रहे हैं। बिग डेटा संज्ञान. संगणना., 7, 62. <https://doi.org/10.3390/bdcc7020062>
- वह, के., झांग, एक्स., रेन, एस., और सन, जे., 2016। छवि पहचान के लिए गहन अवशिष्ट शिक्षा। में कंप्यूटर विज्ञान और पैटर्न पहचान पर आईईईईई सम्मेलन की कार्यवाही (पृ. 770-778)। <https://doi.org/10.1109/CVPR.2016.90>
- हेंडलर, जे., और मुलवेहिल, ए.एम., 2016। सामाजिक मशीनें: कृत्रिम बुद्धिमत्ता, सामाजिक नेटवर्किंग और मानवता की आने वाली टक्कर. अप्रेस. <https://doi.org/10.1007/978-1-4842-1156-4>
- हर्नाडेज़, जी., रोड्रिगज़, एस., गॉजालेज़, ए., कोर्चाडो, जे.एम., और प्रीतो, जे., 2021। गहन शिक्षण एल्गोरिदम का उपयोग करके वीडियो विश्लेषण प्रणाली। में एम्बिडेंट इंटेलेजेंस-सॉफ्टवेयर और अनुप्रयोग: एम्बिडेंट इंटेलेजेंस पर 11वीं अंतर्राष्ट्रीय संगोष्ठी (पृ. 186-199)। स्प्रिंगर इंटरनेशनल पब्लिशिंग। https://doi.org/10.1007/978-3-030-58356-9_19
- हर्नाडेज़-नीवेज़, ई., हर्नाडेज़, जी., गिल-गॉजालेज़, ए.बी., रोड्रिगज़-गॉजालेज़, एस., और कोरचाडो, जे.एम., 2021. सीईबीआरए: बैंकिंग उत्पादों की सिफारिश करने के लिए एक केसई-आधारित रीज़निंग एप्लिकेशन। आर्टिफिशियल इंटेलेजेंस के इंजीनियरिंग अनुप्रयोग, 104, 104327. <https://doi.org/10.1016/j.Engappai.2021.104327>
- हो, जे., सॉन्ग, डी., और एलिज़ाल्डे, बी., 2020. डिनोइज़िंग डिफ्यूज़न प्रोबेबिलिस्टिक मॉडल्स। *ArXiv प्रीप्रिंट ArXiv*. होक्रैइटर, एस., और शिमधुबर, जे., 1997. दीर्घकालिक अल्पकालिक स्मृति। तंत्रिका गणना, 9(8), 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- होमोलक, जे. 2023. चिकित्सा, विज्ञान और अकादमिक प्रकाशन में चैटजीपीटी के अवसर और जोखिम: एक आधुनिक प्रोमेथियन दुविधा. <https://doi.org/10.3325/cmj.2023.64.1>
- होवी, डी., और स्पूट, एस.एल., 2016. प्राकृतिक भाषा प्रसंस्करण का सामाजिक प्रभाव। एसीएल 2016. <https://doi.org/10.18653/v1/P16-2096>
- वह, एल., 2022. जनरेटिव एआई और भविष्य. 23 जनवरी 2023 को यूआरएल से लिया गया <https://pub.towardsai.net/जनरेटिव-एआई-एंड-फ्यूचर-सी3बी1695876एफ2>
- हुआंग, आर., झोउ, जेड., झांग, वाई., और झाओ, जेड., 2023. मेक-एन-ऑडियो: प्रॉम्प्ट-एन्हांसड डिफ्यूज़न मॉडल के साथ टेक्स्ट-टू-ऑडियो जेनरेशन। *ArXiv प्रीप्रिंट ArXiv*:2301.12661.
- इटोह, एस., और ओकाडा, के., 2023. बड़े भाषा मॉडल की शक्ति: मौलिक डेटा का एक चैटजीपीटी-संचालित पाठ्य विश्लेषण। उपलब्ध है एसएसआरएन 4535647. <https://doi.org/10.2139/ssrn.4535647>

- जानबी, एन., महमूद, आर., कातिब, आई., अल्बेश्री, ए., कोरचैडो, जे.एम., और यिगिटकैनलर, टी., 2022. इम्तिदाद: त्वचा रोग निदान के लिए वितरित एआई सेवाओं के विकास पर एक संदर्भ वास्तुकला और एक केस स्टडी बादल, कोहरे और किनारे पर। *सेंसर*, 22(5), 1854. <https://doi.org/10.3390/s22051854>
- जियांग, एच., सन, डी., जंपानी, वी., यांग, एम.एच., लर्नड-मिलर, ई., और कौटज़, जे., 2018. सुपर स्लोमो: वीडियो इंटरपोलेशन के लिए मल्टीपल इंटरमीडिएट फ्रेम्स का उच्च गुणवत्ता अनुमान। में सीवीपीआर(पृ. 9000-9008)। <https://doi.org/10.1109/CVPR.2018.00938>
- जिओ, एफ., डिंग, बी., लुओ, टी., और मो, जेड., 2023. पांडा एलएलएम: ओपन-सोर्स चीनी इंस्ट्रक्शन-फॉलोइंग लाई लैंग्वेज मॉडल्स के लिए प्रशिक्षण डेटा और मूल्यांकन। *arXiv प्रीप्रिंट arXiv:2305.03025*.
- जोवानोविक, एम., और कैंपबेल, एम., 2022. जनरेटिव आर्टिफिशियल इंटेलिजेंस: रुझान और संभावनाएं। *कंप्यूटर*, 55(10), 107-112. <https://doi.org/10.1109/MC.2022.3192720>
- जुराफस्की, डी., और मार्टिन, जे.एच., 2019। भाषण और भाषा प्रसंस्करण. पियर्सन.
- किंगमा, डी. पी., और वेलिंग, एम., 2013. ऑटो-एन्कोडिंग वेरिफेशनल बेज़। *arXiv प्रीप्रिंट arXiv:1312.6114*.
- कोठाडिया, डी., भट्ट, सी., सपरिया, के., पटेल, के., गिल-गॉजालेज़, ए.बी., और कोर्चाडो, जे.एम., 2022. डीपसाइन: गहन शिक्षण का उपयोग करके सांकेतिक भाषा का पता लगाना और पहचानना। *इलेक्ट्रॉनिक्स*, 11(11), 1780. <https://doi.org/10.3390/इलेक्ट्रॉनिक्स11111780>
- क्रिज़ेव्स्की, ए., सुतस्केवर, आई., और हिंटन, जी.ई., 2012. गहरे दृढ़ तंत्रिका नेटवर्क के साथ इमेजनेट वर्गीकरण। तंत्रिका सूचना प्रसंस्करण प्रणालियों में प्रगति, 25.
- कुडो, टी., और रिचर्डसन, जे., 2018. सेंटेंसपीस: न्यूरल टेक्स्ट प्रोसेसिंग के लिए एक सरल और भाषा स्वतंत्र सबवर्ड टोकननाइज़र और डीटोकननाइज़र। *arXiv प्रीप्रिंट arXiv:1808.06226*. <https://doi.org/10.18653/v1/D18-2012>
- ली, वाई., ली, जेड., झांग, के., डैन, आर., जियांग, एस., और झांग, वाई., 2023. चैटडॉक्टर: एक मेडिकल चैट मॉडल एक बड़े भाषा मॉडल मेटा-एआई पर फाइन-ट्यून किया गया (एलएलएएमए) मेडिकल डोमेन ज्ञान का उपयोग करना। *क्यूरियस*, 15(6). <https://doi.org/10.7759/cureus.40895>
- लियू, एच., सेफेराज़ा, सी., और एबील, पी., 2023. भाषाएँ पुरस्कार हैं: मानव प्रतिक्रिया का उपयोग करके हिंडसाइट फ़ाइनट्यूनिंग। *arXiv प्रीप्रिंट arXiv:2302.02676*।
- लुंड, बी.डी., वांग, टी., मन्नूरु, एन.आर., नी, बी., शिमरे, एस., और वांग, जेड., 2023। चैटजीपीटी और एक नई अकादमिक वास्तविकता: आर्टिफिशियल इंटेलिजेंस-लिखित शोध पत्र और विद्वानों के प्रकाशन में बड़े भाषा मॉडल की नैतिकता। <https://doi.org/10.1002/asi.24750>
- एम. साल्वाग्नो, टैकोन, एफ., गेरली, ए., 2023। क्या कृत्रिम बुद्धिमत्ता वैज्ञानिक लेखन में मदद कर सकती है? <https://doi.org/10.1186/s13054-023-04380-2>
- मैंडोटो, ए., लिन, जेड., विनाटा, जी.आई., और फंग, पी., 2021. फ्यू-शॉट बॉट: डायलॉग सिस्टम के लिए प्रॉम्प्ट-आधारित शिक्षा। *arXiv प्रीप्रिंट arXiv:2110.08118*.
- मैनिंग, सी.डी., एट अल., 2008. सूचना पुनर्प्राप्ति का परिचय. कैम्ब्रिज यूनिवर्सिटी प्रेस.
- मारोटो-गोमेज़, एम., कास्त्रो-गॉजालेज़, ए., कैस्टिलो, जे.सी., मालफ़ाज़, एम., और सालिच्स, एम. ए., 2023। मानव-रोबोट इंटरैक्टिव संचार के लिए उपयोगकर्ता वरीयता पूर्वानुमानों पर समर्थित एक अनुकूली निर्णय लेने वाली प्रणाली . उपयोगकर्ता मॉडलिंग और उपयोगकर्ता-अनुकूलित इंटरैक्शन, 33(2), 359-403. <https://doi.org/10.1007/s11257-022-09321-2>
- मैक्कार्थी, जे., मिन्स्की, एम.एल., रोचेस्टर, एन., और शैन्नन, सी.ई., 2006। कृत्रिम बुद्धिमत्ता पर डार्टमाउथ ग्रीष्मकालीन अनुसंधान परियोजना के लिए एक प्रस्ताव, 31 अगस्त, 1955। एआई दुकानें, 27(4), 12-12.
- मैककुलोच, डब्ल्यू.एस., और पिट्स, डब्ल्यू., 1943। तंत्रिका गतिविधि में निहित विचारों का एक तार्किक कैलकुलस। *गणितीय बायोफिज़िक्स का बुलेटिन*, 5, 115-133. <https://doi.org/10.1007/BF02478259>
- मैकग्रेगर, एस., मेमन, एन., और लेवी, के., 2020. साइबर सुरक्षा और मानवाधिकार। में निष्पक्षता, जवाबदेही और पारदर्शिता पर 2020 सम्मेलन की कार्यवाही (पृ. 425-435)।

- मियाओ, एक्स., वांग, वाई., जियांग, वाई., शि, सी., नी, एक्स., झांग, एच., और कुई, बी., 2022. गैल्वार्टून: स्वचालित समानता का उपयोग करके एकाधिक जीपीएस पर कुशल ट्रांसफार्मर प्रशिक्षण। *arXiv प्रीप्रिंट arXiv:2211.13878*. <https://doi.org/10.14778/3570690.3570697>
- मूर, जे., 2006। डार्टमाउथ कॉलेज कृत्रिम बुद्धिमत्ता सम्मेलन: अगले पचास वर्ष। आपकी दुकानें हैं, 27(4), 87-87.
- नाडकर्णी, पी.एम., ओहनो-मचाडो, एल., और चैपमैन, डब्ल्यू डब्ल्यू., 2011. प्राकृतिक भाषा प्रसंस्करण: एक परिचय। *जर्नल ऑफ़ द अमेरिकन मेडिकल इंफॉर्मेटिक्स एसोसिएशन*, 18(5), 544-551. <https://doi.org/10.1136/amiajnl-2011-000464>
- नाकानो, आर., हिल्टन, जे., बालाजी, एस., वू, जे., औयांग, एल., किम, सी., ... और शुलमैन, जे., 2021. वेबजीपीटी: ब्राउज़र- सहायता प्राप्त प्रश्न-उत्तर मानवीय प्रतिक्रिया. *arXiv प्रीप्रिंट arXiv:2112.09332*
- गुयेन, टी.एम., और वू, क्यू.जे. (2013)। चिकित्सा छवि विभाजन के लिए मार्कोव यादृच्छिक क्षेत्र पर आधारित एक फजी लॉजिक मॉडल। *विकसित हो रही प्रणालियाँ*, 4, 171-181.
- गुयेन, टी.टी., विल्सन, सी., और डालिन्स, जे., 2023. ऑनलाइन यौन उत्पीड़नकारी चैट और अपमानजनक ग्रंथों का पता लगाने के लिए लामा 2 बड़े भाषा मॉडल को फाइन-ट्यूनिंग। *arXiv प्रीप्रिंट arXiv:2308.14683*. <https://doi.org/10.1109/TITS.2023.3297252>
- निकोल, ए., एट अल., 2021. ग्लाइड: टेक्स्ट-संचालित अनुप्रयोगों के लिए एक जेनरेटिव भाषा मॉडल। *जर्नल ऑफ़ आर्टिफिशियल इंटेलिजेंस रिसर्च*, 49(2), 315-334.
- ओपनएआई, 2021। चैटजीपीटी एपीआई दस्तावेज़ीकरण। ओपनएआई. 22 अगस्त, 2023 को पुनःप्राप्त <https://platform.openai.com/docs/guides/chat>
- ओपनएआई, 2023, 20 जुलाई। चैटजीपीटी के लिए कस्टम निर्देश। ओपनएआई ब्लॉग। <https://openai.com/blog/चैटजीपीटी-के-लिए-कस्टम-निर्देश>
- ओपनएआई, 2023. जीपीटी-4 तकनीकी रिपोर्ट। *ArXiv, abs/2303.08774*
- ओयांग, एल., वू, जे., जियांग, एक्स., अल्मेडा, डी., वेनराइट, सी., मिशिकन, पी., ... और लोव, आर., 2022. मानवीय प्रतिक्रिया के साथ निर्देशों का पालन करने के लिए भाषा मॉडल का प्रशिक्षण . त्रिका सूचना प्रसंस्करण प्रणालियों में प्रगति, 35, 27730-27744.
- पारिख, वी., शाह, जे., भट्ट, सी., कोर्चाडो, जे.एम., और ले, डी.एन., 2022, जुलाई। गहन शिक्षण आधारित स्वचालित छाती एक्स-रे असामान्यताओं का पता लगाना। में एम्बिडेंट इंटेलिजेंस पर अंतर्राष्ट्रीय संगोष्ठी (पृ. 1-12). चाम: स्प्रिंगर इंटरनेशनल पब्लिशिंग। https://doi.org/10.1007/978-3-031-22356-3_1
- पास्ज़के, ए., ग्रॉस, एस., मस्सा, एफ., लेरर, ए., ब्रैडबरी, जे., चानन, जी., ... और चिंताला, एस., 2019. पाइटरच: एक अनिवार्य शैली, उच्च प्रदर्शन गहन शिक्षण पुस्तकालय। *न्यूरल इन्फर्मेशन प्रोसेसिंग सिस्टम्स में प्रगति*, 32.
- पावलीशेंको, बी.एम. (2023)। फाइन-ट्यून्ड लामा 2 जीपीटी मॉडल का उपयोग करते हुए वित्तीय समाचार विश्लेषण। *arXiv प्रीप्रिंट arXiv:2308.13032*
- पेरेज़-पॉस, एम.ई., अलोंसो, आर.एस., गार्सिया, ओ., मारेइरोस, जी., और कोरचाडो, जे.एम., 2021। टिकाऊ कृषि बाजार के लिए गहन क्यू-लर्निंग और प्राथमिकता आधारित मल्टी-एजेंट प्रणाली। *सेंसर*, 21(16), 5276. <https://doi.org/10.3390/s21165276>
- पेरेज़-पॉस, एम.ई., पारा-डोमिंगुएज़, जे., हर्नांडेज़, जी., बिचिंडारिज़, आई., और कोरचाडो, जे.एम., 2023। ओसीआई-सीबीआर: प्राथमिकता-जागरूक निवेश परिदृश्यों में निर्णय समर्थन के लिए एक हाइब्रिड मॉडल। *अनुप्रयोगों के साथ विशेषज्ञ प्रणालियाँ*, 211, 118568. <https://doi.org/10.1016/j.eswa.2022.118568>
- रैडफोर्ड, ए., नरसिम्हन, के., सलीमंस, टी., और सुतस्केवर, आई., 2018। जेनेरिक प्री-ट्रेनिंग द्वारा भाषा की समझ में सुधार करना।
- रैडफोर्ड, ए., वू, जे., चाइल्ड, आर., लुआनु, डी., अमोदेई, डी., और सुतस्केवर, आई., 2021। भाषा मॉडल कम हैं-शांट सीखने वाले। ओपनएआई ब्लॉग, 9(2), 650-700.

- रैडफोर्ड, ए., वू, जे., चाइल्ड, आर., लुआन, डी., अमोदेई, डी., और सुतस्केवर, आई., 2019. भाषा मॉडल बिना पर्यवेक्षित मल्टीटास्क सीखने वाले होते हैं। *ओपनएआई ब्लॉग*, 1(8),9.
- रेड्टर, ई., और डेल, आर., 2020। प्राकृतिक भाषा निर्माण प्रणाली का निर्माण. कैम्ब्रिज यूनिवर्सिटी प्रेस.
- रोम्बैच, एम., एट अल., 2022. हाई डेफिनिशन वीडियो जेनरेशन के लिए जेनरेटिव लेटेंट डिफ्यूजन मॉडल। *मल्टीमीडिया पर आईईईई लेनदेन*, 24(1), 123-137.
- रोसेनब्लैट, एफ., 1958। परसेप्ट्रॉन: मस्तिष्क में सूचना भंडारण और संगठन के लिए एक संभाव्य मॉडल। *मनोवैज्ञानिक समीक्षा*, 65(6), 386. <https://doi.org/10.1037/h0042519>
- रुमेलहार्ट, डी.ई., हिंटन, जी.ई., और विलियम्स, आर.जे., 1986। बैक-प्रोपेगेटिंग त्रुटियाँ द्वारा सीखना प्रतिनिधित्व। *प्रकृति*, 323(6088), 533-536। <https://doi.org/10.1038/323533a0>
- रसेल, एस.जे., और नॉरविग, पी., 2014। कृत्रिम बुद्धिमत्ता एक आधुनिक दृष्टिकोण. हार्लो.
- सरसा, एस., डेनी, पी., हेलास, ए., और लेइनोनेन, जे., 2022। बड़े भाषा मॉडल का उपयोग करके प्रोग्रामिंग अभ्यास और कोड स्पष्टीकरण की स्वचालित पीढ़ी। <https://doi.org/10.1145/3501385.3543957> सेनरिच, आर., और झांग, बी., 2019. कम-संसाधन तंत्रिका मशीन अनुवाद पर दोबारा गौर करना: एक केस स्टडी। *arXiv प्रीप्रिंट arXiv:1905.11901*. <https://doi.org/10.18653/v1/P19-1021>
- सेर्बन, आई. वी., एट अल., 2017. एक डीप रीइन्फोर्समेंट लर्निंग चैटबॉट। *arXiv प्रीप्रिंट arXiv:1709.02349*.
- शाज़ीर, एन., 2020. ग्लू वेरिएंट ट्रांसफार्मर में सुधार करते हैं। *arXiv प्रीप्रिंट arXiv:2002.05202*.
- शेरस्टिंस्की, ए., 2020. आवर्तक तंत्रिका नेटवर्क (आरएनएन) और दीर्घकालिक अल्पकालिक मेमोरी (एलएसटीएम) नेटवर्क के बुनियादी सिद्धांत। *फिजिका डी: नॉनलाइनियर फेनोमेना*, 404, 132306। <https://doi.org/10.1016/j.PhysD.2019.132306>
- सिद्दीकी, एस.; चाउ, जे.सी.एल., 2021. हेल्थकेयर कम्युनिकेशन में मशीन लर्निंग। *विश्वकोश*, 1, 220-239. <https://doi.org/10.3390/encyclopedia1010021>
- सिमोनियन, के., और ज़िसरमैन, ए., 2014. बड़े पैमाने पर छवि पहचान के लिए बहुत गहरे दृढ़ नेटवर्क। *arXiv प्रीप्रिंट arXiv:1409.1556*.
- सु, जेड, चाउ, जे.के., टैन, पी.एस., वू, जे., हो, वाई.के., और वांग, वाई.एच., 2021। डीप कन्वोल्यूशनल न्यूरोल नेटवर्क-आधारित पिकसेल-वार भूस्खलन इन्वेंट्री मैपिंग। *भूस्खलन*, 18, 1421-1443. <https://doi.org/10.1007/s10346-020-01557-6>
- टैंग, डी., रोंग, डब्ल्यू, किन, एस., यांग, जे., और जिऑंग, जेड., 2020. उत्तर चयन के लिए समीक्षा के साथ एक एन-गेटेड आवर्ती इकाई। *न्यूरोकंप्यूटिंग*, 371, 158-165. <https://doi.org/10.1016/j.neucom.2019.09.007>
- टेट, ई., 2023। हाई डेफिनिशन वीडियो जेनरेशन: एक व्यापक समीक्षा। *मल्टीमीडिया प्रोसेसिंग जर्नल*.
- टौन्नॉन, एच., मार्टिन, एल., स्टोन, के., अल्बर्ट, पी., अलमाहैरी, ए., बाबेई, वाई., ... और स्क्रियालॉम, टी., 2023। लामा 2: खुली नींव और ठीक-ठाक चैट मॉडल. *arXiv प्रीप्रिंट arXiv:2307.09288*.
- तुल्याकोव, एस., लियू, एम. वाई., यांग, एक्स., और कौत्ज़, जे., 2018. मोकोगन: वीडियो निर्माण के लिए गति और सामग्री को विघटित करना। में कंप्यूटर विज्ञान और पैटर्न पहचान पर आईईईई सम्मेलन की कार्यवाही (पृ. 1526-1535)। <https://doi.org/10.1109/CVPR.2018.00165>
- ट्यूरिंग ए.एम., 1950। कंप्यूटिंग मशीनरी और इंटेलिजेंस। में: *दिमाग* 59.236, पृ. 433-460. <https://doi.org/10.1093/mind/LIX.236.433>
- वासवानी, ए., शज़ीर, एन., परमार, एन., उस्ज़कोरिट, जे., जोन्स, एल., गोमेज़, ए.एन., ... और पोलोसुखिन, आई., 2017। आपको बस ध्यान की आवश्यकता है। तंत्रिका सूचना प्रसंस्करण प्रणालियों में प्रगति, 30.
- वॉन ओसवालड, जे., निकलासन, ई., रैंडाजो, ई., सैक्रामेंटो, जे., मोर्डविंटसेव, ए., ज़मोगिनोव, ए., और व्लादिमिरोव, एम., 2023, जुलाई। ट्रांसफार्मर ग्रेडिएंट डिसेंट द्वारा संदर्भ में सीखते हैं। में मशीन लर्निंग पर अंतर्राष्ट्रीय सम्मेलन (पृ. 35151-35174)। पीएमएलआर.

- वॉड्रिक, सी., पिरसियावाश, एच., और टोरलबा, ए., 2016। दृश्य गतिशीलता के साथ वीडियो बनाना। में न्यूरल इन्फर्मेंशन प्रोसेसिंग सिस्टम्स में प्रगति (पृ. 613-621).
- वालेस, ई., एट अल., 2019. एनएलपी पर हमला करने और उसका विश्लेषण करने के लिए सार्वभौमिक प्रतिकूल ट्रिगर। ईएमएनएलपी 2019।<https://doi.org/10.18653/v1/D19-1221>
- वेई, आर., और महमूद, ए., 2020. बायोमेट्रिकल इन्फॉर्मेटिक्स के लिए प्रतिनिधित्व सीखने के साथ वैरिएबल ऑटोएन्कोडर्स में हालिया प्रगति: एक सर्वेक्षण। आईईईई एक्सप्रेस, 9, 4939-4956. <https://doi.org/10.1109/एक्सप्रेस.2020.3048309>
- विलियम्स, जे., 2023. एआई-जनरेटेड टेक्स्ट डिटेक्टरों की प्रभावकारिता। शैक्षिक प्रौद्योगिकी जर्नल.
- जी, जे., जू, एल., और चैन, ई., 2018. डीप न्यूरल नेटवर्क्स के साथ इमेज डीनोइजिंग और इनपेंटिंग। में न्यूरल इन्फर्मेंशन प्रोसेसिंग सिस्टम्स में प्रगति (पृ. 341-349)।
- जू, एल., सैंडर्स, एल., ली, के., चाउ, जे.सी.एल., 2021. आर्टिफिशियल इंटेलिजेंस और मशीन लर्निंग का उपयोग कर स्वास्थ्य देखभाल और ऑन्कोलॉजी अनुप्रयोगों के लिए चैटबॉट: व्यवस्थित समीक्षा। <https://doi.org/10.2196/27850>
- यालालोव, डी. 2023. चैटबॉट्स का विकास: टी9 और जीपीटी-1 के युग से चैटजीपीटी तक। डाक। यूआरएल: <https://mpost.io/es/la-evoluci%C3%B3n-de-los-chatbots-de-la-era-t9-y-gpt-1-a-chatgpt/>
- ज़ादेह, एल.ए., 2008। क्या फ़ज़ी लॉजिक की आवश्यकता है? सूचना विज्ञान, 178(13), 2751-2779. <https://doi.org/10.1016/j.ins.2008.02.012>
- ज़रेम्बा, डब्ल्यू., और ब्रॉकमैन, जी., 2021, 10 अगस्त। ओपनएआई कोडेक्स। ओपनएआई. <https://openai.com/blog/openai-कोडेक्स/>
- झाओ, जे., वांग, टी., यात्सकर, एम., कॉटरेल, आर., ऑर्डोनेज़, वी., और चांग, के.डब्ल्यू., 2018। में कम्प्यूटेशनल भाषाविज्ञान एसोसिएशन के उत्तरी अमेरिकी चैप्टर के 2018 सम्मेलन की कार्यवाही: मानव भाषा प्रौद्योगिकी, खंड 2 (लघु पत्र) (पृ. 8-14)।
- झाओ, जेड, एट अल। 2023. मेक-एन-ऑडियो: प्रॉम्प्ट-एन्हांसड डिफ़्यूजन मॉडल के साथ टेक्स्ट-टू-ऑडियो जेनरेशन। मशीन लर्निंग पर 40वें अंतर्राष्ट्रीय सम्मेलन की कार्यवाही।
- ज़ोरान, डी., काबरा, आर., लेर्चनर, ए., और रेज़ेंडे, डी. जे., 2021. भाग: स्लॉट्स, ध्यान और स्वतंत्रता अधिकतमकरण के साथ अनपर्यवेक्षित विभाजन। में कंप्यूटर विज्ञान पर आईईईई/सीवीएफ अंतर्राष्ट्रीय सम्मेलन की कार्यवाही (पृ. 10439-10447)। <https://doi.org/10.1109/ICCV48922.2021.01027>