

JAZYKOVÉ MODELY A UMĚLÁ INTELIGENCE

Jan Hendl

Abstrakt

V poslední době se v publikacích pro širokou veřejnost i v odborné literatuře objevuje často termín „jazykový model“ ve spojení s různými aplikacemi umělé inteligence. Mnohdy jde v této souvislosti o atraktivní interaktivní systém ChatGPT pro návrh odpovědí na nejrůznější dotazy. Čtenáři však obvykle nevědí, co vlastně tento termín znamená. Poskytneme určité přiblížení tohoto termínu. Osvětlíme využití jazykových modelů obecně nebo v medicíně. Popíšeme některé možnosti i omezení slibné informační technologie založené na velkých jazykových modelech.

Klíčová slova

umělá inteligence, jazykové modely, omezení aplikací, medicína

Úvod

Metody umělé inteligence (AI, Artificial Intelligence) se šíří mnoha směry. Také v medicíně se objevují rozličné aplikace AI. V tomto pojednání uvedeme několik různých a alternativních definic konceptů se vztahem k umělé inteligenci a k jazykovým modelům. Provedeme jejich určitou klasifikaci. Nepůjde nám o technické a výpočetní aspekty problematiky, spíše chceme zvýšit vědomí této oblasti u netechnicky založených zájemců [1, 2].

Definice velkého jazykového modelu (LLM, Large Language-Model) podle Wikipedie má tvar: Velký jazykový model je počítačový model založený na neuronové síti s mnoha parametry (typicky miliardami vah nebo více), trénované na velkém množství textů pomocí samoučení (self-supervised learning) nebo částečného učení s učitelem (semi-supervised learning).

K použitým pojmům v této definici se postupně vrátíme. Poznamenejme, že poznatky se v této oblasti rychle vyvíjejí. Přibývají nové pojmy a postupy. Souvisí to kromě jiného s tím, že se problematikou zabývají tisíce odborníků.

Spouštěčem velkého zájmu o LLM se stala činnost společnosti ze San Francisca, která byla v Silicon Valley dlouho známá, přestože byla poměrně malá a měla méně než 400 zaměstnanců: OpenAI. Na konci listopadu 2022 zpřístupnila svou aplikaci ChatGPT široké veřejnosti, čímž posunula chatboty na novou úroveň a pomohla generativní umělé inteligenci dosáhnout průlomu obecně.

Microsoft oznámil „mnohamiliardovou investici“ do OpenAI a integraci technologie OpenAI do svých vlastních produktů pro koncové zákazníky. Programy jako Midjourney, Stable Diffusion a Dall-E, které z krátkých textových vstupů generují nové obrázky, dělají značné pokroky. Vytvářejí obrázky, které jsou téměř k nerozeznání od autentických fotografií. Podobné aplikace existují i pro hudbu. Ke klonování hlasu pomocí umělé inteligence dnes stačí malé hlasové vzorky.

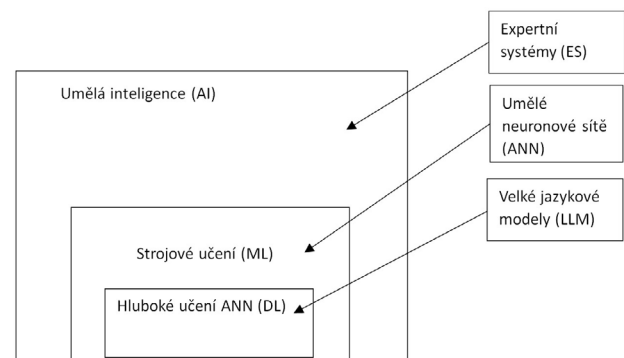
Generátory programového kódu se staly mocným nástrojem, vývojářům softwaru stačí k napsání nových programů polovina času. ChatGPT a jeho přímí konkurenti ze společností Google, Meta, Microsoft, You.com, Perplexity a mnoha dalších vytvářejí spoustu kódu v rámci dialogu s jejich uživatelem.

Umělá inteligence už není jen tématem pro několik specialistů na výzkum a vývoj. AI je nyní masovým produktem s miliardovými obraty. OpenAI a Microsoft soupeří s dalšími společnostmi, jako je Google Meta nebo Baidu v Číně o to, kdo uvede na trh nejvýkonnější, nejužitečnější a na člověka zaměřené modely. Takzvané velké jazykové modely (LLM) například vytvářejí nové, rozumně znějící texty.

Velké jazykové modely lze pomocí strojového učení (ML, Machine Learning) a hlubokého učení (DL, Deep Learning) umělých neuronových sítí (ANN, Artificial Neural Nets) trénovat k provádění atraktivních úloh (očekávané širokou veřejností) i k provádění speciálních úloh, jako je třeba porozumění struktuře proteinů nebo psaní softwarového kódu. Podobně jako lidský mozek, musí být velké jazykové modely předem natrénovány a poté jemně vyladěny, aby mohly řešit problémy klasifikace textu, zodpovídání otázek, sumarizace dokumentů nebo generování textu. Schopnost LLM nástrojů řešit problémy lze uplatnit také v oblastech, jako jsou finance a zábava. Velké jazykové modely slouží k různým aplikacím NLP (Nature Language Processing), jako jsou překlady, chatboty, atd. Popíšeme také několik aplikací a trendů LLM v medicíně.

Jazykové modely dokáží vyvinout i malé týmy. V Paříži na výstavě díla malíře van Gogha zodpovídá dotazy robot „BonjourVincent“. Zatím nejčastější otázka pro robota zněla: „Proč jste spáchal sebevraždu?“ Podle její formulace robot mění odpověď. Jedna verze vypadala takto: „Prosím Vás, zůstaňte na živu. I v nejhroších okamžicích vždy existují krása a naděje.“ Jiná vypadá takto: „Drahý návštěvníku, můj čin je velký problém, v té temné chvíli jsem si myslel, že pouze sebevraždou uniknu mučení, které trápilo moji duši.“ Tým stále pracuje na vylepšení robota, který byl trénován tisíci dopisy van Gogha a texty knih o tomto malíři.

Vzájemný vztah umělé inteligence, strojového učení, hlubokého učení a velkých jazykových modelů ukazuje pomocí hierarchického schématu obrázek 1.



Obrázek 1 – Hierarchie konceptů AI. Na pravé straně jsou aplikace.

Umělá inteligence

Umělá inteligence (AI) je schopnost zkonstruovaného stroje, například počítače, simulovat nebo duplikovat lidské kognitivní úlohy. Stroj s umělou inteligencí dokáže provádět výpočty, analyzovat data za účelem vytváření předpovědí, identifikovat různé typy znaků a symbolů, konverzovat s lidmi a pomáhat provádět úkoly bez manuálního vstupu.

Umělá inteligence má své kořeny v samotných počátcích počítačů a matematik Alan Turing (1912–1954) byl jedním z prvních, kdo popsal, jak by mohl uměle inteligentní stroj fungovat. Všechny od té doby vyrobené počítače jsou na určité úrovni umělé inteligence, protože jsou schopny provádět výpočty, které dříve mohli provádět pouze lidé. V posledních desetiletích se však schopnosti, rychlost a kapacita paměti počítačů rychle rozšířily. Dnes se pojem „umělá inteligence“ vztahuje k pokročilejším kognitivním úlohám, které počítače dokážou provádět.

Generativní umělá inteligence

Generativní umělá inteligence je typ modelu umělé inteligence, který dokáže vytvářet obsah, včetně textu, obrázků, zvuku a videa. Generativní model AI může jako vstup třeba dostat fotografii prázdné ledničky a na základě fotografií, které mu byly

v minulosti předloženy, ji naplnit pravděpodobným obsahem. I když obsah generovaný takovým modelem může být považován za „nový“, je založen na obsahu, kterým byl model dříve trénován.

Nástroje generativní umělé inteligence jsou stále populárnější. Především velký jazykový model (LLM) ChatGPT a generátory obrázků DALL-E a Midjourney zaujaly veřejnost a obchodní svět. Mezi další populární nástroje generativní AI patří Bard, Bing Chat a Llama.

Prediktivní umělá inteligence

Prediktivní umělá inteligence (AI) je schopnost počítačového programu využívat statistickou analýzu k identifikaci vzorců, předvídání chování a předpovídání budoucích událostí. Oblast statistiky se již dlouho používá k předpovídání budoucnosti; prediktivní umělá inteligence zrychluje a (teoreticky) zpřesňuje statistickou analýzu prostřednictvím počítačového učení a přístupu k obrovskému množství dat (Big data). Není zaručeno, že její předpovědi budou správné. Prediktivní AI je jen jednou z mnoha schopností, které nabízí umělá inteligence.

Expertní systém

Expertní systém je aplikace AI a počítačový systém, který napodobuje rozhodovací schopnosti lidského experta. Expertní systémy jsou určeny k řešení složitých problémů s využitím argumentace pomocí souborů znalostí, které jsou reprezentovány v klasickém tvaru převážně jako pravidla if-then. První expertní systémy vznikly v 70. letech 20. století a poté se rozšířily v 80. letech 20. století. Expertní systémy patřily mezi první skutečně úspěšné formy softwaru umělé inteligence. Expertní systém se dělí na dva subsystémy: inferenční komponentu a znalostní bázi. Báze znalostí představuje fakta a pravidla. Inferenční komponenta aplikuje pravidla na známá fakta a odvozuje z nich nová fakta. Expertní systémy mohou zahrnovat také vysvětlovací a ladicí komponentu.

V roce 1980 byl na základě prototypu lékařského systému MYCIN navržen prázdný expertní systém e-MYCIN. Prázdné expertní systémy jsou programy, které obsahují odvozovací komponentu a další softwarové části, ale neobsahují bázi znalostí. Jsou schopny pracovat s různými bázemi znalostí z různých expertních domén.

V současnosti se těší oblibě expertní systémy využívající trénované umělé neuronové sítě. Mají na rozdíl od klasických řešení určité potíže s vysvětlením svého řešení, mnohdy jsou přesnější a celkově výkonnější.

Embeddingy

Embeddingy jsou reprezentace souborů hodnot nebo objektů, jako je text, obrázky a zvuk, které jsou určeny pro modely strojového učení a algoritmy sémantického vyhledávání. Převádějí takové objekty do speciální digitální podoby podle faktorů nebo vlastností, které každý z nich může nebo nemusí mít, a podle kategorií, do kterých patří.

Embeddingy umožňují modelům strojového učení vyhledávat podobné objekty. Při zadání fotografie nebo dokumentu model strojového učení, který používá embeddingy, nalezne podobnou fotografii nebo dokument. Embeddingy umožňují počítačům pochopit vztahy mezi slovy a jinými objekty, jsou dnes důležitým prvkem nástrojů umělé inteligence.

Big data

Velká data (Big data) označují soubory dat, které jsou extrémně velké, složité a rychle se měnící a rostoucí – jsou tak velké, že je tradiční software pro zpracování dat nedokáže zpracovat. Tyto

soubory mohou obsahovat jak strukturovaná, tak nestrukturovaná data.

V některých ohledech jsou velká data a umělá inteligence v symbiotickém vztahu:

- Umělá inteligence vyžaduje dnes obvykle k trénování a k naučení velké soubory dat.
- A naopak, velké soubory dat lze snáze s pomocí AI lépe spravovat a analyzovat.

Strojové učení

Strojové učení je obor umělé inteligence a označuje postup, kdy se programu předávají strukturovaná nebo označená data, aby se program naučil, jak tato data identifikovat bez zásahu člověka.

Odborné vyjádření strojového učení: O počítačovém programu se říká, že se učí na základě zkušeností E s ohledem na určitou třídu úloh T a míru výkonnosti P , pokud se jeho výkonnost v úlohách T , měřená pomocí P , zlepšuje se zkušenostmi E .

Strojové učení se spoléhá na přístup k velkým souborům dat. Čím více dat model získá, tím je přesnější. Strojové učení dnes využívá celá řada softwarových a technologických řešení. Od bezpečnostních řešení, která využívají strojové učení k odhalování podvodů a identifikaci botů, až po platformy sociálních médií, které využívají strojové učení k doporučení obsahu nebo účtů ke sledování, se strojové učení ukázalo jako užitečný vývojový nástroj. V programovacím jazyku *PYTHON* (také v jazyku *R*) je připraveno mnoho volných balíčků pro řešení problémů LLM.

Fungování strojové učení

Strojové učení je založeno na vstupech a výstupech. Algoritmu strojového učení jsou předávána data (vstup), která použije k vytvoření výsledku (výstup). Model strojového učení se „učí“, jaké výstupy má produkovat, a může tak činit pěti hlavními metodami:

1 Supervised learning (učení s učitelem)

U nejzákladnějšího druhu programu strojového učení programátor připraví soubor příkladových vstupů a správných výstupů. Algoritmus strojového učení se snaží z těchto příkladů vyvinout algoritmus tak, aby po zadání vstupu sám dokázal vytvořit požadovaný výstup.

2 Unsupervised learning (učení bez učitele)

Učení bez učitele je situace, kdy jsou pokročilejšímu algoritmu strojového učení dodána nezpracovaná data. Ten pak sám identifikuje vzory.

3 Reinforcement learning (učení s posilováním)

V tomto stylu učení je algoritmus strojového učení trénován prostřednictvím zpětné vazby. Existují „dobré“ a „špatné“ výstupy a model se postupem času učí, jak se špatným výstupům vyhnout. Učení s posilováním je procesem pokusů a omylů.

4 Semi-supervised learning (učení s částečným učitelem)

Jedná se o učení s většinou nepřirazenými daty a s malým množstvím správně přirazených dat. Tato technika učení se řadí mezi učení s učitelem a učení bez učitele. Semi-supervised learning techniky používají neoznačená data k modifikaci algoritmu získaného s označenými daty.

5 Self-supervised learning (učení s vlastním dohledem)

Při učení s vlastním dohledem je model trénován pomocí neoznačených dat. Zpočátku model vytváří smysl dat (a provizorních označení) pomocí neoznačených dat technikami učení bez učitele. Spolehlivě označená data se pak použijí na neoznačená

data. Klíčovou vlastností je, že označení se s každou iterací vyvíjejí. Učení s vlastním dohledem je obzvláště užitečné při práci s rozsáhlými modely (s miliardami parametrů), které vyžadují velké množství dat pro trénování.

Neuronové sítě

Stejně jako je lidský mozek sestaven z neuronů, které jsou navzájem propojeny a vysílají si signály, je umělá neuronová síť (obvykle zkráceně „neuronová síť“) sestavena ze síťových uzlů (umělých neuronů), které navzájem komunikují. Neuronové sítě se skládají z několika „vrstev“: vstupní vrstva, výstupní vrstva a jedna nebo více vrstev (skrytých) mezi nimi. Neurony si navzájem předávají informace pouze v případě, že jejich vlastní výstupy překročí určitou mez.

Specifický druh neuronových sítí používaných pro LLM se nazývá transformační modely (transformer). Transformační modely jsou schopny učit se kontextu – což je důležité zejména pro lidský jazyk a texty, které jsou na kontextu velmi závislé. Transformační modely používají matematickou techniku zvanou sebezpozorování, která umožňuje odhalit jemné způsoby, jakými prvky v síti spolu souvisejí. Díky tomu jsou schopny lépe chápat kontext než jiné typy algoritmů strojového učení. Umožňuje jim to například zjistit, jak konec věty souvisí s jejím začátkem a jak spolu souvisejí věty v odstavci. Díky tomu mohou takové modely LLM interpretovat lidský jazyk a texty, i když jsou takové jazyky a texty nejasné nebo špatně definované, uspořádané v kombinacích, se kterými se algoritmy dosud nesetkaly, nebo v nových souvislostech. Na určité úrovni „rozumějí“ sémantice v tom smyslu, že dokáží spojovat slova a pojmy podle jejich významu, když se setkali s tím, že jsou takto seskupeny v miliolech případů. Aby bylo možné vytvářet aplikace LLM, je proto potřeba přístup k velkým datovým souborům.

Jazykové modely


Velký jazykový model (LLM LargeLanguage Model) je typ programu umělé inteligence, který dokáže mimo jiné rozpoznávat a generovat text. Modely LLM se trénují na obrovských souborech dat a příslušné neuronové sítě jsou složeny z mnoha vrstev a neuronů – odtud název „velký“ („Large“). LLM jsou konstruovány jako typ neuronové sítě zvané transformační model.

Zjednodušeně řečeno, LLM je počítačový program, kterému bylo zadáno dostatečné množství příkladů, aby byl schopen rozpoznávat a interpretovat lidský jazyk nebo jiné typy složitých dat. Mnoho LLM je vyškoleny na datech, která byla shromážděna z internetu a z jiných zdrojů – jde obvykle o tisíce a miliony gigabajtů textu.

Rozdíl mezi jednoduchým jazykovým modelem (LM) a velkým jazykovým modelem (LLM) spočívá ve dvou aspektech: v složitosti a v potenciálních aplikacích. Rozmanitost a relevance u LLM je mnohem větší než u jednoduchých LM. Rozhodující roli přitom hraje rozvoj rychlosti a paměťové kapacity počítačů. Nejdříve uvedeme základní vymezení LM a LLM, následně odbornějším vymezením naznačíme jejich strukturu [1, 2].

Jazykové modely se používají v oblasti zpracování přirozeného jazyka (NLP) v úlohách rozpoznávání a generování textů. Jazykový model LM pro daný řetězec písmen nebo slov udává pravděpodobnost výskytu řetězce v daném jazyce. Při daném jazyce s určitou slovní zásobou představuje jazykový model pravděpodobnostní rozdělení výrazů ve slovní zásobě.

Jazykový model LM je pravděpodobnostní model přirozeného jazyka (bez předem teoreticky zadaného pravděpodobnostního rozložení), který dokáže generovat pravděpodobnosti řady slov (následující slova ve větě) na základě učebních textových korpůsů v jednom nebo více jazycích, na kterých byl vycvičen.



Obrázek 2 – jednoduchá a složitá (mnohem více skrytých vrstev) neuronová síť

Jazykový model pomocí různých statistických a pravděpodobnostních metod předpovídá následující sekvence textu.

Velký jazykový model LLM je pokročilou formou LM. Jde o kombinaci feedforward (vysvětleno dále) neuronové sítě (NN, Neuron Net) a transformeru. Tyto softwarové prostředky vytlačily jednodušší jazykové modely založené na jednoduchých rekurentních neuronových sítích (vysvětleno dále), které zase nahradily dřívější statistické modely, jako je například slovní n-gramový jazykový model. Použití současných LLM je mnohem širší než jednoduchých jazykových modelů (LM) staršího typu.

Rozdíl mezi jednoduchým a velkým LM spočívá při prvním přiblížením v použité neuronové síti v jednoduchém LM a LLM, což ukazují modelová schémata na obrázku 2, v kterém je jednoduchá neuronová síť v levé části a „hluboká“ v pravé části obrázku. V LLM modelech se používají neuronové sítě s mnoha miliony uzly (neurony) a s mnoha skrytými vrstvami (obrázek 2).

Velké jazykové modely (LLM) mají ohromné množství nastavitelných parametrů (definují fungování neuronů v síti), které jsou podobné elektronickým pamětem v počítači. Model parametry upravuje při učení v tréninku pomocí dodaných učebních textů. Představujeme si tyto parametry jako banku znalostí modelu. Parametry a struktura sítě určují práci vytvořené neuronové sítě.

Transformační model je nejběžnější architekturou velkého jazykového modelu. Skládá se z kodéru a dekodéru. Transformační model zpracovává data tak, že vstupní data „tokenizuje“ a současně provádí operace, aby zjistil vztahy mezi „tokeny“. To umožňuje počítači vidět vzory, které by viděl člověk, kdyby mu byl zadán stejný dotaz. „Tokenizace“ dokumentů je operace, při níž text dokumentů je převeden do termínů neboli tokenů. Termíny (tokeny) označují základ významu slova a jednotku informace. Mohou označovat celou větu nebo jednotlivá slova (unigramy), dvě následující slova (bigramy) a obecně n-gramy [3].

Transformační modely (transformery) pracují s mechanismy speciálního pozorování sebe sama (self-attention mechanismus), což umožňuje modelu učit se účinněji, než tak činí tradiční modely. Právě sebezpozorování (self-attention mechanismus) umožňuje transformačnímu modelu zohlednit různé části sekvence nebo celý kontext věty při vytváření předpovědí (predikcí).

Základní součásti velkých jazykových modelů

Velké jazykové modely se skládají z několika vrstev různých typů neuronových sítí: rekurentních vrstev (recurrent layers), napájecích vrstev (feed forward layers, FFN layers), vkládacích vrstev (embedding layers) a vrstev pozornosti (attention layers). Tyto vrstvy pracují v tandemu při zpracování vstupního textu a generování výstupního obsahu.

Vkládací vrstva vytváří ze vstupního textu vnoření (embedding). Tato část velkého jazykového modelu zachycuje sémantický a syntaktický význam vstupu, takže model dokáže porozumět kontextu.

Napájecí vrstva (FFN, Feed forward Neural Network) velkého jazykového modelu je tvořena několika plně propojenými vrstvami umělých neuronů, které transformují vstupní embeddingy. Tyto vrstvy umožňují modelu získávat abstrakce vyšší úrovně, tj. porozumět záměru uživatele při zadávání textu.

Pro vysvětlení uvádíme, že neuronová síť s **dopředným tokem** (feed forward neural network, FNN) je jedním ze dvou obecných typů umělých neuronových sítí (ANN), charakterizovaných směrem toku signálů (informací) mezi jejími vrstvami, její tok signálů je jednosměrný, což znamená, že informace v modelu proudí pouze jedním směrem – dopředu – od vstupních uzlů (neuronů), přes skryté uzly (pokud existují) a do výstupních uzlů, bez jakýchkoli cyklů nebo smyček, na rozdíl od rekurentních neuronových sítí (RNN), které mají **obousměrný tok**.

Rekurentní vrstva interpretuje postupně slova ve vstupním textu. Zachycuje vztahy mezi slovy ve větě.

Mechanismus pozornosti umožňuje jazykovému modelu zaměřit se na jednotlivé části vstupního textu, které jsou relevantní pro daný úkol. Tato vrstva umožňuje modelu generovat co nejpřesnější výstupy.

Tři hlavní typy velkých jazykových modelů

Generické (obecné) neboli hrubé (raw) jazykové modely předpovídají další slovo na základě trénovacích dat. Tyto jazykové modely provádějí úlohy vyhledávání informací.

Instrukčně laděné (instruction-tuned) jazykové modely jsou trénovány tak, aby předpovídaly odpovědi na instrukce uvedené na vstupu. To jim umožňuje provádět analýzu sentimentu nebo generovat text či kód.

Dialogově laděné (dialog-tuned) jazykové modely jsou trénovány k vedení dialogu předpovídáním další odpovědi. Takovými jsou chatboty nebo konverzační prostředky AI.

Rozdíl mezi velkým jazykovým modelem a generativní AI

Generativní AI (Artificial Intelligence) je zastřešující pojem, který označuje modely umělé inteligence, které mají schopnost generovat obsah. Generativní AI může generovat text, kód, obrázky, video a hudbu.

Velké jazykové modely (LLM) jsou typem generativní umělé inteligence. Jsou trénovány velkou množinou textů a vytvářejí textové obsahy. ChatGPT je populárním příkladem generativní textové AI.

Fungování velkých jazykových modelů

Velký jazykový model je založen na transformačním modelu (transformeru) a funguje tak, že přijímá vstup, kóduje jej a poté dekóduje, aby vytvořil výstupní predikci. Než však může velký jazykový model přijímat textový vstup a vytvářet výstupní predikci, vyžaduje trénink a doladění, což mu umožní plnit specifické úkoly.

Trénování: Velké jazykové modely se předem trénují pomocí velkých textových datových souborů z webu jako je Wikipedie, GitHub a jiných zdrojů. Tyto datové soubory se skládají z bilionů slov a jejich kvalita určuje efektivitu jazykového modelu. V této fázi tvorby velkého jazykového modelu probíhá učení bez učitele, což znamená, že zpracovává datové soubory, které jsou mu předávány bez specifických instrukcí o správném výstupu. Během tohoto procesu se algoritmus LLM může učit významům slov a vztahům mezi slovy. Učí se také rozlišovat slova na základě kontextu. Například se naučí „chápat“, zda slovo „vpravo“ (right) znamená „správně“, nebo opak slova „vlevo“.

Doladování: Aby mohl velký jazykový model vykonávat konkrétní úkol, například překlad, musí být pro tuto činnost vyladěn. Jemné doladění optimalizuje fungování konkrétních úkolů.

Podobnou funkci jako jemné doladění plní i doladování promptů (prompt = výzva, příkaz v podobě textové vstupní řád-

ky), při němž se model trénuje k provádění konkrétního úkolu prostřednictvím několikanásobných promptů (few-shot prompting) nebo promptů s nulovým počtem podnětů (zero-shot prompting). Prompt je instrukce zadaná modelu LLM.

Několikanásobný prompt učí model předpovídat výstupy pomocí příkladů. Například při cvičení analýzy sentimentu by několikanásobný prompting vypadal takto:

Hodnocení zákazníka: Tato rostlina je tak krásná!

Sentiment zákazníka: pozitivní

Hodnocení zákazníka: Tato rostlina je tak ošklivá!

Sentiment zákazníka: negativní

Jazykový model „pochopí“ prostřednictvím sémantického významu slovo „ošklivý“ a protože byl uveden opačný příklad, že zákaznický sentiment v druhém příkladu je „negativní“.

Alternativou je nulový prompt. Nepoužívá příklady k tomu, aby naučil jazykový model, jak má reagovat na vstupy. Místo toho formulujeme otázku jako „Sentiment ve větě ‚Ta rostlina je tak ošklivá‘ je...“. Jasně se naznačuje, jakou úlohu má jazykový model provést, ale neposkytuje příklady řešení problému.

Úvahy o vytváření promptů

Prompty hrají při využívání LLM velkou roli. Prompt je instrukce (pokyn) pro program LLM. Pokud komunikujeme s programem LLM, jako je ChatGPT, používáme prompt. V ideálním případě prompt vyvolá odpověď, která je správná, má odpovídající formu i obsah a správnou délku.

Dobře strukturovaný prompt je nezbytnou součástí pro zajištění kvalitní odpovědi LLM. V podstatě jde o to, aby byl náš záměr zabalen do dotazu v přirozeném jazyce, který způsobí, že model vrátí požadovanou odpověď.

Dobré prompty se řídí dvěma základními principy: jasností a konkrétností. Jasnost popisuje použití jednoduchého, jednoznačného jazyka, který se vyhýbá žargonu a příliš složitým slovům.

Příklad nejasného promptu:

Kdo vyhrál volby?

Příklad jasného promptu:

Která strana vyhrála parlamentní volby v Česku v roce 2023?

Konkrétnost naopak odkazuje na potřebu kontextu. Sdělíme modelu tolik, kolik potřebuje vědět, aby mohl na otázku odpovědět. Někdy to může přejít téměř do oblasti vyprávění příběhů.

Příklad nekonkrétního promptu:

Vytvořte seznam titulů pro mou autobiografii.

Příklad konkrétního promptu:

Vytvoř seznam deseti titulů pro mou autobiografii. Kniha pojednává o mé cestě dobrodruha, který prožil nekonvenční život, setkal se s mnoha různými osobnostmi a nakonec našel klid v zahradničení.

Výzkumníci a uživatelé LLM identifikovali několik triků, které trvale zlepšují odpovědi modelů.

Říkáme „*dělej*“, neříkáme „*nedělej*“.

Tento aspekt se vlastně týká tématu specifčnosti, protože instrukce „*dělej*“ je ze své podstaty specifičtější než „*nedělej*“. Takže než říkat modelu, co nemá dělat, je obvykle lepší přesně specifikovat, co chceme, aby dělal – pokud víme, co to je.

Představme si, že v našem předchozím příkladu chceme zajistit, aby LLM nevytvářel příliš dlouhé názvy (jak to tyto modely mají ve zvyku).

Místo toho, abychom řekli:
Nedělej příliš dlouhé názvy

Je lepší být konkrétní:
Každý název by měl být dlouhý od dvou do pěti slov.

Více používáme několikanásobné prompty. V našem příkladu jsme požádali o konkrétní položku (název autobiografie) o určité délce (dvě až pět slov). Tento typ pokynů bez konkrétních příkladů se nazývá „zero-shot prompting“.

Většinou modelů však prospívá „několikanásobné pobídnutí“, kdy modelu podáte několik příkladů, aby se naučil požadovaný vzor. V našem promptu můžeme přidat několik existujících titulů jako příklady, které modelu pomohou získat pocit, co hledáme.

Zde je několik příkladů: *Dlouhá cesta ke svobodě, Pití na přání, Víím, proč pták v kleci zpívá.*

Jde o to, strukturovat prompt smysluplným způsobem.

Prvky jako uvozovky, odrážky, zalomení řádků atd. usnadňují lidem analýzu textu. Totéž platí i pro LLM. Aplikujme tento poznatek na náš předchozí příklad a napíšme celý prompt ještě jednou.

Vytvoř seznam deseti názvů mé autobiografie. Kniha pojednává o mé cestě dobrodruha, který prožil nekonvenční život, setkal se s mnoha různými osobnostmi a nakonec našel klid v zahradničení. Každý název by měl být dlouhý dvě až pět slov.

Správně utvořený prompt instruuje LLM, aby rozdělil své úvahy na zvládnutelné kroky a delegoval je na nástroje, které považuje za nejschopnější pro řešení úloh.

Aplikace velkých jazykových modelů

Velké jazykové modely (LLM) lze použít k několika účelům:

Vyhledávání informací: uvažujeme vyhledávače Bing nebo Google. Kdykoli použijeme jejich vyhledávací funkci, spoléháme se na velký jazykový model, který v reakci na dotaz poskytne požadované informace. Vyhledávač je schopen vyhledat informace, poté je shrnout a sdělit odpověď v konverzačním stylu.

Analýza sentimentu: Jako aplikace zpracování přirozeného jazyka umožňují velké jazykové modely institucím a podnikům analyzovat sentiment textových dat.

Generování textů: Velké jazykové modely stojí za generativní umělou inteligencí, jako je ChatGPT, mohou generovat text na základě vstupů. Na určitý prompt mohou vytvořit víceméně relevantní text.

Například: *„Napiš mi báseň o pouličním osvětlení ve stylu Karla Jaromíra Erbena.“*

Generování kódu: Podobně jako generování textu je i generování kódu aplikací generativní umělé inteligence. LLM rozumí vzorům, což jim umožňuje generovat kód.

Chatboti a konverzační AI: Velké jazykové modely umožňují chatbotům zákaznických služeb nebo konverzační AI komunikovat se zákazníky, interpretovat význam jejich dotazů nebo odpovědí a nabízet jim odpovědi na oplátku.

Vzdělání: LLM modely lze využít k tvorbě vzdělávacího obsahu, ke zlepšení zapojení a interakce studentů a k personalizaci výuky. Velké jazykové modely ve vzdělávání vyžadují, aby si učitelé a žáci vytvořili soubory kompetencí a gramotností, které jsou nezbytné jak pro pochopení těchto technologií, tak i jejich omezení a chybování. Kromě toho je k začlenění a plnému využití velkých jazykových modelů do vzdělávacích prostředí a výukových programů zapotřebí jasná strategie v rámci vzdělávacích systémů a jasný pedagogický přístup se silným důrazem na kritické myšlení a strategie ověřování faktů.

Kromě těchto případů použití mohou velké jazykové modely doplňovat věty, odpovídat na otázky a shrnovat text.

ChatGPT

Velké jazykové modely, jako je Generative Pre-trained Transformer (GPT) v posledních letech významně pokročily ve zpracování přirozeného jazyka (NLP). Tyto modely jsou trénovány na obrovském množství textových dat a jsou schopny generovat text podobný lidskému, odpovídat na otázky a plnit další jazykové úlohy s vysokou přesností.

Mezi nejnovější aplikaci GPT patří také **ChatGPT**, který byl natrénován na velké sadě dat, tj. textech z velmi rozsáhlého webového korpusu, a prokázal špičkový výkon v široké škále úloh z přirozeného jazyka, od překladu po odpovědi na otázky, psaní souvislých esejí a počítačových programů. Kromě toho byl proveden rozsáhlý výzkum zaměřený na doladování těchto modelů na menších souborech dat a na aplikaci transferového učení na nové problémy. To umožňuje zlepšit výkonost v konkrétních úlohách s menším množstvím dat.

Integrace různých chatbotů do webových stránek je dobrým způsobem, jak návštěvníkům webu poskytnout určitou pomoc. Zvyšuje se tak spokojenost návštěvníků zejména z webových stránek, které poskytují služby a produkty.

Je nesporné, že mít online robota přináší výhody. Pomáhá v mnoha ohledech, například přivítá nové zákazníky, poskytne jim odpovědi během několika sekund a umožní jim zanechat kontaktní údaje pro následnou komunikaci nebo sledování.

V současné době existuje mnoho nástrojů pro chat s umělou inteligencí. Uvedme některé z nich: ChatGPT, BotStar, Flow XO, Customers.ai, Pandorabots, atd. ChatGPT společnosti OpenAI je nejpoužívanější dosud vyvinutou aplikací AI a LLM. Odhaduje se, že během pouhých dvou měsíců po svém spuštění aplikace přitáhla více než 100 milionů uživatelů, což z této aplikace činí „nejrychleji rostoucí spotřebitelskou aplikaci v historii.“

Základní verze ChatGPT je v současné době k dispozici zdarma a k použití prostřednictvím prohlížečů. Schopnosti ChatGPT jsou poměrně pokročilé, přičemž neustále přicházejí nová vylepšení, která jsou ztělesněna v ChatGPT Plus. Bezplatný online chatovací ChatGPT s umělou inteligencí je výkonný v komunikaci s uživateli, sběru dat a vícejazyčných funkcích. V současné době můžeme k jeho volnému používání online použít verze s API.

Společnost OpenAI představila GPT-4, který je považován za spolehlivější, kreativnější a všestrannější než jeho předchůdci GPT-3 a GPT-3.5-turbo. Kromě toho se GPT-4 neomezuje pouze na zadávání textu; kromě textu dokáže zpracovávat i obrázky, což mu umožňuje popisovat humor na neobvyklých obrázcích, shrnovat text ze snímků obrazovky a dokonce odpovídat na otázky ke zkouškám obsahujícím diagramy.

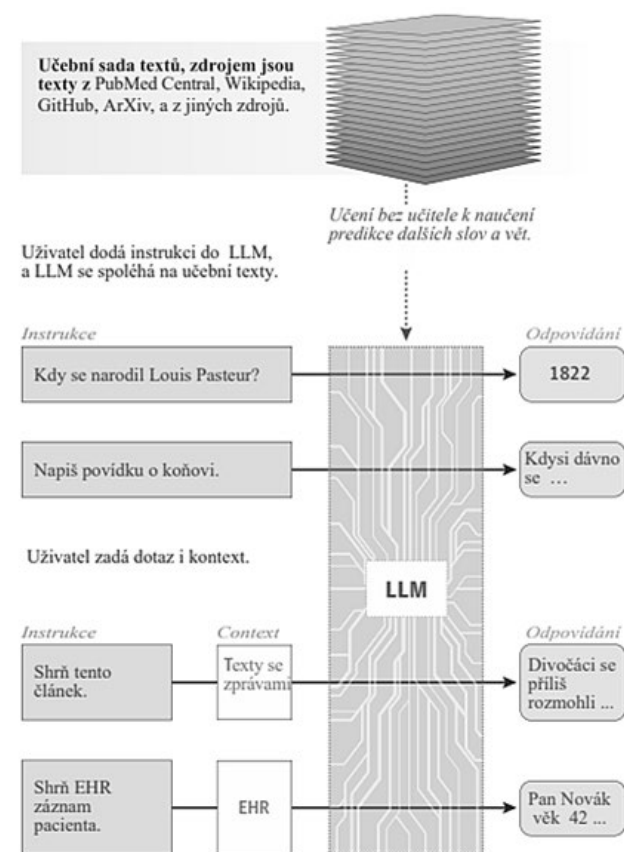
Pro lepší ovládnutí GPT-4 zavedla společnost OpenAI koncept „systémové zprávy“, což je pokyn zadaný v přirozeném jazyce, který specifikuje tón hlasu a úkol modelu. Uživatelé tak mohou modelu nařídit, aby reagoval určitým způsobem, například aby přijal podobu shakespearovského piráta nebo formátoval svůj výstup ve formě JSON.

Aplikace v medicíně

Velké jazykové modely (LLM), jako je ChatGPT, si získaly značnou pozornost díky svým působivým schopnostem porozumění lidskému jazyku a generování odpovědí. Proto se použití LLM v medicíně jako pomoc lékařům a při péči o pacienty jeví jako slibný směr výzkumu jak v oblasti umělé inteligence, tak v oblasti klinické medicíny.

Článek [4] uvádí schematicky postup tvorby LLM a některé medicínské aplikace (viz obrázek 3).

Dále popíšeme některé zvláště důležité aplikace LLM v medicíně a uvedeme vybranou literaturu [5].



Obrázek 3 – trénink a interakce s LLM (bez vyladění)

Lékařská diagnóza: Je důležité stanovit diagnózu pacienta přesně a včas, protože účinnost léčby většiny nemocí je velmi závislá na okamžiku provedení. U jakéhokoli onemocnění má chybná nebo nesprávná diagnóza často negativní důsledky, a to v rozsahu od drobných nepříjemností až po smrt. Začlenění LLM do systému lékařské diagnostiky může zvýšit dostupnost odborné zdravotní péče.

Nedávno byla nevržena metoda využití LLM pro lékařskou diagnostiku prostřednictvím grafového modelu, který poskytuje diagnostický rozhodovací strom týkající se patologie nemoci. Dr. Knows – grafový model vybírá relevantní diagnostické případy s vysvětlením vycvičený na reálném souboru nemocničních dat [6].

Jedním z výrazných omezení použití LLM jako jediného nástroje pro lékařskou diagnostiku je to, že je zcela závislý na subjektivních vstupech od pacienta. Vzhledem k tomu, že LLM jsou primárně založeny na textu, postrádají přirozenou schopnost analyzovat lékařské diagnostické snímky. Vzhledem k tomu, že objektivní lékařské diagnózy často závisejí na vizuálních obrazech, LLM často nejsou schopny přímo provádět diagnostické hodnocení, protože jim chybí konkrétní vizuální důkazy, které by diagnózu nemoci podpořily. Mohou však pomoci při diagnostice jako nástroj logického uvažování, který pomáhá zlepšit přesnost jiných modelů založených na vidění. Například ChatCAD využívá výše uvedenou logiku při tvorbě diagnózy. Snímky jsou filtrovány do stávajícího modelu počítačem podporované diagnostiky (CAD, Computer Assisted Diagnosis).

Formátování a kódování ICD: Mezinárodní klasifikace nemocí ICD (International Classification of Diseases) je metoda standardizace diagnostických a procedurálních informací klinického rozhodování. Operace jsou zaznamenány v kódu ICD při každé návštěvě pacienta u lékaře v elektronických zdravotních záznamech (EHR, Electronic Health Record) jednotlivce, aby na ně bylo možné v budoucnu odkazovat. Tyto kódy slouží také ke sledování zdravotních ukazatelů, výsledků léčby a také k fak-

turaci. Existuje potřeba automatizovat proces označování ICD, protože je časově náročný a často jej provádějí sami lékaři. LLM mohou pomoci automatizovat kódování ICD tím, že izolují lékařské termíny z klinických poznámek a přiřazují jim odpovídající kódy ICD. PLM-ICD je LLM systém vyladěný pro automatické kódování ICD [7].

Vytváření klinických zpráv: Klinické zprávy se týkají standardizované dokumentace, kterou musí zdravotničtí pracovníci vyplnit po každé návštěvě pacienta. Úzce souvisí s lékařskou diagnózou, protože velkou část zprávy často tvoří výsledky diagnózy. Pro klinické pracovníky je to často zdlouhavá a časově náročná aktivita, a proto hrozí, že bude neúplná nebo náchylná k chybám pro přepracované klinické pracovníky. Přijetí LLM pro tvorbu klinických zpráv proto může poskytnout objektivní prostředek, jak se vyhnout neúplnosti a zároveň snížit pracovní zátěž kliniků.

Intuitivním způsobem, jak mohou LLM pomoci při tvorbě klinických zpráv, je příklad nástroje sumarizace [8]. Pokud je jako vstup zadána diagnóza, může využít své schopnosti shrnutí textu a poskytnout jasný a stručný finální závěr. V tomto případě použití se LLM přímo nepodílí na zlepšení přesnosti závěru. Spíše fungují jen jako nástroj usnadňující zdlouhavou práci, kterou by jinak vykonávali lékaři.

Další populární využití LLM k vytváření klinických zpráv často spoléhá na nějaký jiný typ modelu založeného na vidění nebo na manuálním vstupu lékaře [9]. LLM použije tuto informaci spolu s nějakým dalším textovým promptem, například formátem zprávy zadaným lékařským personálem, aby vygeneroval přesnou zprávu, která dodržuje požadovaný formát. To výrazně snižuje pracovní zátěž lékařů.

Vzdělávání lékařů: Příprava lidí pro specifické role v terénu je klíčová. Zdravotnické vzdělávání může zahrnovat jak vzdělávání odborníků, tak i vzdělávání široké veřejnosti, které je pravděpodobně stejně důležité. Do systému lékařského vzdělávání lze LLM začlenit mnoha způsoby, včetně pomoci studentům při přípravě na lékařské zkoušky, působení v roli sokratovského tutora a zodpovídání otázek [10].

Karabacak et al. navrhli [11] několik procedur začlenění LLM do systému lékařského vzdělávání, konkrétně pro přípravu studentů medicíny na lékařské zkoušky a následně na scénáře v reálném světě. Navrhují, že lékařské vzdělávání lze rozšířit generováním scénářů, problémů a odpovídajících odpovědí pomocí LLM. Prostřednictvím tohoto systému se studenti setkájí s větší škálou problémů, než jaké najdou v učebnici. LLM může také generovat zpětnou vazbu k odpovědím studentů na cvičné úlohy. Tím se zajišťuje přístup k hodnocení, což studentům umožní poznat své slabé stránky v reálném čase.

Dalším využitím LLM v medicíně je poskytování informací veřejnosti. Výrazy lékařů jsou často složité a pro běžného pacienta obtížně srozumitelné. Díky zohlednění laického publika mohou LLM systémy vyladit textový výstup promptů tak, aby používaly přizpůsobenou lékařskou terminologii. Pro laika tak bude mnohem méně svízelný přístup k lékařským informacím a jejich pochopení a pro zdravotnického pracovníka to může zajistit, že bude mít větší přístup k relevantním informacím.

Lékařská robotika: Lékařské roboty lze využít v mnoha oblastech medicíny, při operacích, transportu pacientů, asistenci zdravotním sestřím, lékařské rehabilitaci a v mnoha dalších případech. Lékařské roboty se používají v boji proti nedostatku zdravotnického personálu a vykonávají úkoly přesahující fyzické možnosti člověka.

Roboti ke svému fungování potřebují informace o prostředí. V případě lékařských robotů jsou zapotřebí senzory, které získávají vstupní data, analyzují tato data, provádějí plánování postupu a také vykonávají naplánovaný postup k provedení požadované činnosti. Plánování postupu je proto klíčovou fází robotického výkonu.

Využití LLM v lékařské robotice může také zlepšit interakci člověka s počítačem. Zlepšením interaktivity mohou roboti rozpoznávat lidské emoce a požadavky prostřednictvím vstupů v přirozeném jazyce. To umožňuje, aby komunikace pacientů s roboty byla méně nezvyklá a uživatelsky přívětivější [12].

Příklad lékařského jazyka: Existují dvě hlavní oblasti překladu lékařského jazyka. Jednou z nich je překlad lékařské terminologie z jednoho jazyka do druhého. Druhou je překlad odborného lékařského dialogu do výrazů srozumitelných neobornému personálu [11]. Oba případy jsou důležité, protože umožňují pohodlnější komunikaci, ať už prostřednictvím různých jazyků, nebo mezi různými skupinami lidí.

Překlad lékařských termínů z jednoho jazyka do druhého může usnadnit globální spolupráci jak ve výzkumu, tak při aplikaci lékařských technik. Jazyk je často jednou z velkých překážek globální spolupráce a s pomocí LLM lze tuto bariéru do značné míry snížit.

Specifická aplikace AI a LLM v medicíně

Ischemická choroba srdeční (ICHS) je celosvětově rozšířené a etiologicky složité onemocnění. Současné pokyny pro primární prevenci zahrnují poměrně jednoduché hodnocení rizika a ponechávají značný prostor pro zlepšení jak pro stanovení rizika, tak pro výběr preventivních strategií. V práci [13] se popisují možnosti AI a LLM informačních technologií ke zjištění rizika ischemické choroby srdeční.

Novější poznatky v oblasti umělé inteligence (AI) mají potenciál pro využitelnost mnohorozměrných dat a poskytnout příležitost lépe porozumět vzájemnému působení mnoha rizikových faktorů. V článku [13] autoři (vesměs korejského původu) zkoumají pokrok v oblasti strojového učení a umělé inteligence v primární prevenci, zdůrazňují současné silné stránky i omezení potenciálních aplikací. V závěru si všímají možností LLM technologií. Obrázek 4 ukazuje schematicky oblasti, které autoři uvažují.

Kromě využití umělé inteligence v oblasti zobrazování srdce, což je jistě pokročilá aplikace umělé inteligence ve zdravotnictví, odhaluje například transplantační výzkum také slibnou

cestu pro AI v oblasti multimodální predikce rizika pomocí standardních biomarkerů, genetických a jiných omických technologií, různých biosenzorů a nestrukturovaných dat z elektronických zdravotních záznamů (EHR).

V klinické validaci modelů AI však stále přetrvávají mezery, především ve využitelnosti komplexní predikce rizik pro přesnější terapeutické zásahy. Nedávná dostupnost velkých souborů dat z databank poskytuje příležitost k podchycení longitudinálních trajektorií zdravotního vývoje pomocí medicínských údajů shromážděných doma, v laboratořích a při návštěvách klinik.

Stále rostoucí dostupnost genotyp-fenotypových dat a výsledků jejich analýz asi umožní přechod od jednoduchých algoritmů pro predikci rizika ke komplexním, „datově intenzivním“ modelům umělé inteligence v klinickém rozhodování.

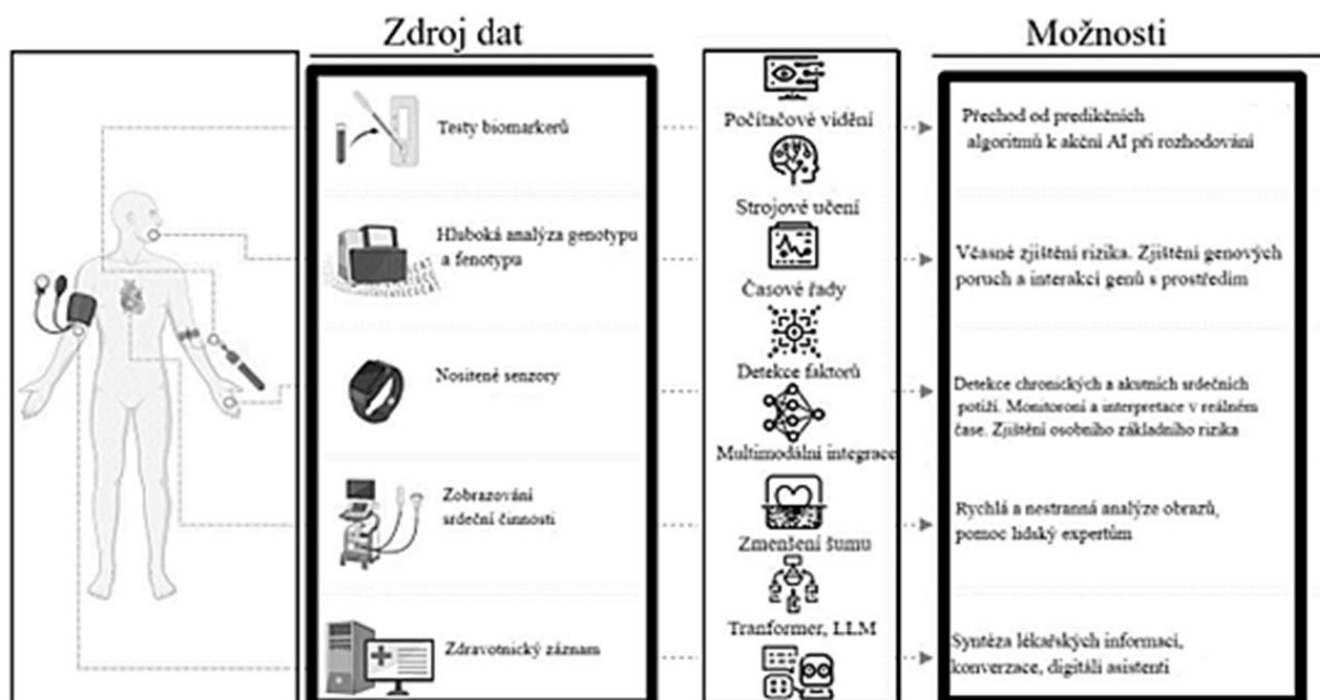
Výsledky LLM při integraci mnoha poznatků jsou působivé také v oblasti prevence ICHS. Zatím se však navržené přístupy nevyrovňají lidskému výkonu. Přístupy založené na řetězci myšlenek zprostředkované LLM sice naznačují vzorce uvažování, které se poměrně dobře shodují s reálnými přístupy k řešení lékařských problémů, ale stále odhalují značné mezery ve znalostech a uvažování.

Pouze největší modely GPT byly v pokusech schopny odpovídat na lékařské otázky. Menší modely asi nedokážou podchytit složité uvažování potřebné k řešení specializovaných úloh. Trénování LLM nástrojů je nákladné a před nasazením do reálných systémů se vyžaduje vývoj zabezpečujících opatření. Je dobře známo, že LLM mají sklon zvětšovat společenské předsudky obsažené v trénovacích datech, mohou si také vymýšlet informace na základě dat zakódovaných v jejich parametrech.

Výhody velkých jazykových modelů pro medicínu

Velké jazykové modely s širokou škálou aplikací jsou pro řešení problémů mimořádně přínosné, protože poskytují informace jasným, konverzačním stylem, který je pro uživatele snadno srozumitelný [1, 5].

Velký soubor aplikací: Lze je použít pro překlad jazyka, doplňování vět, analýzu sentimentu, zodpovídání otázek, matematické rovnice a další.



Obrázek 4 – oblasti AI a LLM v prevenci ICHS

Stále se zlepšují: Výkonnost velkých jazykových modelů se neustále zlepšuje, protože roste s přibývajícím daty a parametry. Čím více se učí, tím se stávají efektivnější. Velké jazykové modely navíc mohou vykazovat takzvané „učení v kontextu“. Jakmile je LLM předtrénován, několikanásobný prompting umožňuje modelu učit se z nulového promptu. Tímto způsobem se také učí nepřetržitě při dalším používání.

Učí se rychle: Při učení v kontextu se velké jazykové modely učí rychle, protože k trénování nepotřebují další parametry.

Omezení velkých jazykových modelů pro medicínu

Velké jazykové modely (LLM) v nás mohou vzbudit dojem, že rozumí významu a dokáží na něj přesně reagovat. Zůstávají však technologickým nástrojem a potýkají se s řadou nedostatků a výzev [1, 5].

Halucinace: O halucinaci se jedná tehdy, když model LLM produkuje výstup, který je nepravdivý nebo který neodpovídá záměru uživatele. Například tvrzení, že je člověk, že má emoce nebo že je do uživatele zamilovaný. Protože velké jazykové modely předpovídají další syntakticky správné slovo nebo frázi, nemohou zcela interpretovat lidský význam. Výsledkem může být někdy to, co se označuje jako „halucinace“.

Bezpečnost: Velké jazykové modely představují významné bezpečnostní riziko, pokud nejsou řádně spravovány nebo kontrolovány. Mohou vést k úniku soukromých informací, podílet se na podvodech typu phishing a produkovat spam. Uživatelé se zlými úmysly mohou umělou inteligenci přeprogramovat podle svých ideologií nebo předsudků a přispívat k šíření dezinformací. Důsledky mohou být v globálním měřítku ničivé.

Předpojatost: Data použitá k trénování jazykových modelů ovlivní výstupy, které daný model produkuje. Pokud tedy data reprezentují jednu demografickou skupinu nebo postrádají rozmanitost, budou výstupy vytvořené velkým jazykovým modelem rovněž postrádat rozmanitost.

Souhlas: Velké jazykové modely jsou trénovány na bilionech datových sad – některé z nich nemusely být získány se souhlasem. Je známo, že velké jazykové modely při získávání dat z internetu ignorují licence na autorská práva, plagiují psaný obsah a předpracovávají proprietární obsah, aniž by získaly povolení od původních vlastníků nebo umělců. Když vytvoří výsledky, neexistuje způsob, jak sledovat původ dat, a často nejsou uvedeny žádné údaje o tvůrcích, což může uživatele vystavit problémům s porušením autorských práv.

Mohou také získat osobní údaje, jako jsou jména subjektů nebo fotografií z popisů fotografií, což může ohrozit soukromí.

Škálování: Škálování a údržba velkých jazykových modelů mohou být obtížné a náročné na čas a zdroje.

Nasazení: Nasazení velkých jazykových modelů vyžaduje hluboké učení, transformační model, distribuovaný software a hardware a celkové technické znalosti.

Hodnotící metriky: Vzhledem k nově vznikajícím schopnostem univerzálních LLM nedokážou současné benchmarky a metriky zhodnotit celkové schopnosti LLM, zejména v lékařské oblasti.

Zdůrazněme, že současné datové soubory v lékařské oblasti, jsou stále relativně malé ve srovnání s datovými soubory používanými k tréninku univerzálních LLM. Lékařská znalostní doména je rozsáhlá; stávající datové sady jsou omezené a nepokrývají celý tento prostor. To má za následek, že LLM vykazují v prvních pokusech zdánlivě mimořádný výkon, při podrobnějším přezkoušení, však nedosahují dostatečného výkonu v reálných úlohách, jako je diferenciální diagnostika a personalizované plánování léčby.

Závěr

Vývoj interaktivních systémů podobných lidem je již několik desetiletí cílem výzkumu umělé inteligence (AI). Příchod snadno dostupných velkých jazykových modelů (LLM) byl přivítán s nadšením, které bylo doprovázeno úsilím o implementaci této nové technologie do mnoha aspektů každodenního života, včetně medicíny. LLM se mohou uplatnit v široké škále klinických a lékařských aplikací, mimo jiné při odpovídání na otázky pacientů, generování poznámek z klinických setkání, vytváření a zodpovídání testových otázek, pomoci při diagnostice a vedení nebo zapojení do terapeutických interakcí. Stejně jako v případě jiných aplikací umělé inteligence v medicíně, jako je zpracování obrazu a předpovídání klinických rizik, existuje možnost velkého přínosu, stejně jako oprávněné obavy z chybného výkonu a dokonce z možného poškození pacienta. Výzkum v této oblasti je proto nezbytný [15]. Stejně jako u každé nové technologie lze předpokládat, že se standardy používání v oblasti lékařské péče budou vyvíjet s tím, jak budou lépe pochopeny silné stránky a omezení umělé inteligence a LLM. Je důležité připomínat myšlenku AI odborníka Fangzheng (Frank) Xu: „Uvažujme střízlivě: umělá inteligence nemůže vyřešit všechny problémy světa.“ Nasazení LLM do citlivých odvětví, jako je zdravotnictví, je potřeba provádět s velkou opatrností. LLM jsou mocnými nástroji, a mají proto potenciál změnit oblast umělé inteligence aplikované ve zdravotnictví a primární prevenci (ICHS a další). Přístupně v češtině pojednávají problematiku LLM knihy [3, 14, 16].

LANGUAGE MODELS AND ARTIFICIAL INTELLIGENCE

Abstract

Recently, the term "language model" has appeared frequently in publications for the general public or in the medicine literature. However, readers usually do not know what this term actually means. We are going to give some background on this term. Often, in this context, it refers to the attractive interactive system ChatGPT for suggesting answers to various questions. We are interested in the use of language models in general or in medicine. We describe some possibilities and limitations of a promising information technology based on large language models.

Keywords

artificial intelligence, language models, application limitations, medicine

Literatura

- [1.] Large language model definition (Elastic). (staženo 28.11.2023) <https://www.elastic.co/what-is/large-language-models>
- [2.] A Beginner's Guide to Large Language Models (NVIDIA). (staženo 28.11.2023) <https://resources.nvidia.com/en-us-large-language-model-ebooks>
- [3.] Hendl J. Big data. Věda o datech – základy a aplikace. Praha: Grada 2021.
- [4.] Shah N et al. Creation and Adoption of Large Language Models in Medicine. *AMA*. 330(9):866-869. doi:10.1001/jama.2023.14217 2023.
- [5.] Zhou H et al. A Survey of Large Language Models in Medicine: Progress, Application, and Challenge. *arxiv.org/abs/2311.05112v1* 2023.
- [6.] Gao Y et al. Leveraging A Medical Knowledge Graphin to Large Language Models for Diagnosis Prediction. *arXiv:2308.14321v1 [cs.CL]* 28 Aug 2023.

- [7.] Ong J et al. Applying large language model artificial intelligence for retina international classification of diseases (icd) coding. *Journal of Medical Artificial Intelligence*, 6, 2023.
- [8.] ShengWang S. et al. Chatcad: Interactive computer-aided diagnosis on medical image using large language models. *arXiv preprint arXiv:2302.07257*, 2023.
- [9.] BangYang B et al. Customizing general-purpose foundation models for medical report generation. *arXiv e-prints, pagesarXiv-2306*, 2023.
- [10.] Qiu J et al. Large ai models in health informatics: Applications, challenges and the future. *IEEE Journal of Biomedical and Health Informatics*, arXiv:2303.11568v1 [cs.AI] 21 Mar 2023.
- [11.] Karabacak M et al. The advent of generative language models in medical education. *JMIR Medical Education*, 9(1):e48163, 2023.
- [12.] Ni Z et al. Grid: Scene-graph-based instruction-driven robotic taskplanning. *arXiv, preprint, arXiv:2309.07726*, 2023.
- [13.] Chen S-F et al. Artificial Intelligence for Risk Assessment on Primary Prevention of Coronary Artery Disease. *Current Cardiovascular Risk Reports* <https://doi.org/10.1007/s12170-023-00731-4> 2023.
- [14.] Kolektiv: Jednoduše. Umělá inteligence. Praha: DK Universum 2023.
- [15.] Chollet F *Deep learning v jazyku Python. 2.edition*, Praha: Grada 2023.
- [16.] Zandl P *Mýty a naděje digitálního světa. Jan Melvil publ.* 2023.

Kontakt**Prof. Jan Hendl****1. LF UK*****jhendl1111@gmail.com***