

**UNIVERZITA KARLOVA**  
**FAKULTA SOCIÁLNÍCH VĚD**  
Institut komunikačních studií a žurnalistiky  
Katedra žurnalistiky

# **Etická problematika trénování velkých jazykových modelů**

Seminární práce

Akademický rok 2023/2024

Bc. Lucie Riedlová

# Obsah

Úvod .....	2
1 Pojem umělá inteligence.....	3
2 Velké jazykové modely (LLMs) .....	3
3 Konkrétní velké jazykové modely .....	4
3.1 ChatGPT .....	4
3.2 BERT .....	5
4 Zdroje trénovacích dat .....	5
4.1 Zdroje trénovacích dat pohledem ChatuGPT-3.5.....	5
4.2 Internetové zdroje .....	6
4.3 Crowdsourcing .....	8
5 Environmentální zátěž .....	9
Závěr .....	11
Zdroje .....	12

# Úvod

Od svého oficiálního vydání 30. listopadu 2022 (Marr 2023) ovlivnil ChatGPT (a jemu podobné nástroje) spoustu aspektů v našem životě v návaznosti na rychlý a obrovský rozvoj umělé inteligence jako takové. Nástroje generativní AI nám umožňují zvyšovat produktivitu, zefektivňovat práci, automatizaci některých úkonů. Jak v soukromém životě, tak i ve spoustě jednotlivých profesí. Je ale nutné neustále mít na paměti, že se s umělou inteligencí a jejím využíváním vážou určitá rizika a etické otázky.

V této práci se budu zabývat velkými jazykovými modely, pod kterými si lze představit třeba již zmiňovaný ChatGPT od společnosti OpenAI. Hlavní část se bude týkat toho, na jakých zdrojích tyto modely fungují a jaké etické problémy s tím souvisí: Jaké jsou nejpopulárnější datové sady, jaký je rozdíl mezi jedno a více jazyčnými korpusy, jakým způsobem souvisí zdrojová data s ochranou soukromí, stereotypizací, zaujatostí nebo „halucinováním“ jazykových modelů a jakým způsobem s trénováním velkých jazykových modelů souvisí crowdsourcingové agentury. V neposlední řadě bych se ráda zaměřila na vztah mezi vývojem a tréninkem modelů umělé inteligence a ochranou životního prostředí, což je další důležité etické téma, které nám rozvoj umělé inteligence otevírá.

# 1 Pojem umělé inteligence

Počátky výzkumu umělé inteligence sahají už do 50. let minulého století (Hendrychová 2024). Do centra pozornosti se ale dostává až v posledních letech, jelikož se nám začala přibližovat i v každodenním životě – ať už pomocí chytrých telefonů nebo domácích spotřebičů. Nalézt ji můžeme například ve webových kamerách a fotografických editorech, je součástí překladačů, komunikuje s námi na zákaznických linkách nebo umí hrát šachy.


Neexistuje pro ni žádná jednotně přijímaná definice. Tím, že se využívá v široké škále různých oborů v sobě jednotlivé formulace často odráží právě specifika těchto odvětví. Jejím základem jsou neuronové sítě – podobné těm, které máme v mozku. Amoroso & Tamburrini (2019) pojem charakterizují jako technologie navržené k řešení problémů, které jsou tradičně přiřazovány lidské inteligenci. Podle McKeowna a spol. (2020) jde zase o schopnost stroje učit se, jelikož učení je jedna ze základních charakteristik inteligentního chování. Obecně jde o velmi široký pojem, který by spíše než jako počítačový algoritmus mohl být definován i jako samostatný vědecký obor.

## 2 Velké jazykové modely (LLMs)

Velké jazykové modely (tzv. LLMs – „large language models“) spadají do kategorie generativní umělé inteligence, která dokáže vytvářet různé typy obsahu – textové, obrazové, zvukové apod. Využívá se ve spoustě odvětvích – medicíně, lingvistice, ekonomii, pedagogice nebo žurnalistice (Gupta a spol. 2024). Generativní umělá inteligence funguje na principu strojového učení, které za pomoci matematických algoritmů a velkého množství dat napodobuje způsob, jakým se ze zkušeností učí lidé (Rouse 2024a). Model tedy nedostane zadání s návodem, jak ho vyřešit, ale příklady správných vstupů a výstupů, od kterých si metriku správného řešení může odvodit. Konkrétním příkladem je třeba automatický překladač, pro který neexistuje přesný návod, jak překládat, ale existuje spousta přeložených textů, které se dají pro trénování systému využít.

Název „velké“ („large“) odkazuje na číslo proměnných, které jazykový model autonomně mění, zatímco se učí. Ty největší z LLMs mají stovky miliard takovýchto parametrů (Rouse 2024b). Podle některých autorů (např. Lee a spol. 2023) jsou velké

jazykové modely, podle měřítka masovosti využití, nejúspěšnějším produktem na západní polokouli.



Zdroj: Shahab a spol. 2024

## 3 Konkrétní velké jazykové modely

V této práci se zabývám velkými jazykovými modely a jejich zdrojovými daty obecně. Nejčastěji zde ale kvůli různým příkladům mluvím o systémech GPT a BERT, proto je v rámci této kapitoly krátce představím.

### 3.1 ChatGPT

Velkým jazykovým modelem je například ChatGPT,<sup>1</sup> (Chat Generative Pre-trained Transformer), který v roce 2022 (Rillig a spol. 2023) vydala americká společnost Open AI. ChatGPT uživateli umožňuje komunikaci s chatbotem ovládaným umělou inteligencí. Model umí imitovat lidskou řeč, zvládne překládat, tvořit programovací kódy nebo odpovídat na otázky. V lednu 2023 (tři měsíce po oficiálním vydání) měl až 100 milionů aktivních uživatelů. Je tak prvním softwarem na světě, který tohoto čísla za tak krátkou dobu dosáhl (Strategic Comments 2023; Marr 2023).

ChatGPT je trénován pomocí obrovského množství internetového textu tak, aby byl schopen „odhadnout“ slovo, které má vždy ve větě následovat – učí se tak jazykové vzorce, kontexty i sémantické vztahy (Gupta a spol. 2024) a tvoří koherentní a

---

<sup>1</sup> Lépe řečeno, velkým jazykovým modelem je GPT – neuronová síť se stovkami miliardami parametrů. ChatGPT je chatbot poháněný GPT, který je na jeho parametrech zcela závislý. Jeho funkcí je dialog a obsahový filtr. (Guinness 2023)

relevantní text. Imituje tím obsah z trénovacích dat, který ale může být zaujatý, nepravdivý nebo dokonce škodlivý. (Strategic Comments 2023)

## 3.2 BERT

Model BERT (Bidirectional Encoder Representations from Transformers) od firmy Google je navržen tak, aby počítačům pomáhal s pochopením významu jazyka pomocí okolního textu k vytvoření kontextu (Hashemi-Pour & Lutkevich 2024). Při učení využívá novější koncept tzv. „obousměrného tréninku“, který umožňuje modelu vzít v potaz kontext slova nalevo i napravo od toho, na které potřebuje navázat (na rozdíl od jiných, kde je tato možnost pouze jednosměrná). Díky tomu je schopen hlouběji porozumět jazyku a kontextu a zlepšuje výkon v odpovídání na otázky nebo v analýze sentimentu. (Gupta a spol. 2023) Model je před-trénován pomocí textů z Wikipedie a lze jej dále doladit pomocí datových sad otázek a odpovědí. (Hashemi-Pour & Lutkevich 2024)

## 4 Zdroje trénovacích dat

Datová sada, kterou jednotlivé modely využívají, je pro jejich fungování zásadní. Pokud je jakýmkoliv způsobem sporná ona, jsou sporné i veškeré výsledky, které nám generativní umělá inteligence prezentuje.

### 4.1 Zdroje trénovacích dat pohledem ChatuGPT-3.5

Jednotlivé zdroje se pro různé modely liší, ale obecně jde o vzorky formálních i neformálních textů (Al Ali 2023). Zdroji datových sad pro ChatGPT je široké spektrum knih, sociálních sítí, Wikipedie, zpravodajských článků, přepisů audio a video záznamů, akademických prací, webových stránek, různých fór nebo úložišť programovacích kódů (Kinsella 2023).

Když jsem se na otázku „Jaké jsou zdroje trénovacích dat pro velké jazykové modely jako je ChatGPT-3.5?“<sup>2</sup> zeptala ChatuGPT-3.5, odpověď zahrnovala mimo právě:

1. Internet
2. Knihy a literaturu
3. Články a deníky

---

<sup>2</sup> Originál: „What are the sources of training data for language models such as ChatGPT-3.5?“

4. Encyklopedie a databáze
5. Konverzace
6. Veřejně dostupné korpusy
7. Licencované datové sady
8. Příspěvky uživatelů (Open AI 2024)

## 4.2 Internetové zdroje

Jak už bylo řečeno, před-trénování velkých jazykových modelů požaduje velké množství tréninkových dat – tzv. korpus. Problémem je, že jeho obsah nemůže být vždy regulován, kvůli čemuž často dochází ke stereotypizaci a zaujatosti, což se v modelech a jejich práci také odráží. (AI Ali 2023) Problémem může být i nedostatečná ochrana osobních dat, které ale například Evropská unie zamezila pomocí GDPR. To ale zase může způsobit nedostatečnou reprezentaci evropského obyvatelstva v trénovacích datech (Lee 2023), čímž se znovu dostáváme ke zkresleným výsledkům.

Datových sad, které LLMs primárně pro svůj trénink využívají, je celá řada. Populární jsou například Common Crawl<sup>3</sup> nebo Wikipedie<sup>4</sup>. Dále jsou to datové sady různých velkých společností, například Amazonu, Microsoftu nebo otevřená data zpřístupněná vládami jednotlivých zemí (Veli 2023).

V Česku vědci některé LLMs trénovaly pouze na datech v českém jazyce. Například model Czert (Sido a spol. 2021) využil datové sady korpusu současné psané češtiny SYN v4 (Křen a spol. 2016), Czech Wikipedia Dump a Crawled of Czech News.<sup>5</sup>

Pro efektivnější práci při učení jednotlivých modelů je datové sady nutné nejprve předzpracovat. Jinak by se mohlo stát, že se v nich budou nacházet nadbytečné údaje, kvůli kterým by se doba tréninku LLM prodloužila, což by znamenalo vyšší výpočetní zdroje, a tím pádem i vyšší náklady. Jiné datové anomálie mohou vést až

---

<sup>3</sup> V Common Crawl se nacházejí terabajty nezpracovaných dat z miliard webových stránek. Portál je aktualizován každý měsíc. Tuto datovou sadu využívají například modely ChatGPT-3, LLaMA nebo T5. (Lee 2023)

<sup>4</sup> Na rozdíl od Common Crawl jsou textová data z Wikipedie vyčištěna. Jsou také prezentována ve všech jazycích. Defaultní verze v anglickém jazyce obsahuje až 19,88 gigabajtů dat. Wikipedie je zdrojem například pro modely ChatGPT, BERT nebo LLaMA. (Lee 2023)

<sup>5</sup> Samotný SYN v4 obsahoval v roce 2021 data o objemu 28,2 GB, což se rovná počtu přibližně 3 600 000 000 slov. Dohromady tyto tři sady, které model Czert využívá, obsahují 36,9 GB dat.

k nevyzpytatelnému chování modelu. (Lee 2023) Proto se data před využitím musí vyčistit,<sup>6</sup> anebo se naopak musí ta chybějící doplnit.

Zdrojová data jsou proto často jednou z příčin etické problematiky jazykových modelů. Podle Gupty a spol. (2023) mohou být zaujatá, nereprezentují veškeré názory a myšlenky a často se soustředí hegemonický úhel pohledu na události. To může vést k udržování nerovnosti a nespravedlnosti ve společnosti (Khanam a spol. 2022), například k asociaci některých skupin lidí (např. tělesně či mentálně postižené) s negativními konotacemi.

Důvodem může být nerovnoměrný přístup k internetu, kdy jím disponují hlavně mladí lidé a také lidé žijící ve vysokopříjmových zemích. Stránkám sbírající tréninková data také údajně dominují muži a moderování obsahu má tendence zaujímat diskriminační stanovisko vůči marginalizovaným skupinám. Různá sociální hnutí sice přicházejí s novými normami, formami jazyka a způsoby komunikace, které jdou proti dominantním narativům, velké jazykové modely jsou ale trénovány pouze jednou a nestíhají se dynamicky vyvíjet společně s jazykem (Bender a spol. 2021).

Zdrojem zaujatosti a zavádějících informací nemusí být ale pouze zdrojová data. Vliv na to může mít i nastavený algoritmus (který nastavuje člověk a říká, jakým způsobem jsou zdrojová data využita) a forma konečného výsledku (například co se týče míry ne/jistoty v prohlášení). (Rillig a spol. 2023)

Stereotypizace a zaujatost se také odvíjí různě v závislosti na jazyku. Práce Martinkové a spol. (2023) pracuje s modely BERT, které se učí čistě z českých, slovenských nebo polských korpusů, přičemž pracují se čtyřmi genderovými kategoriemi: muž, žena, (neutrální) osoba, nebinární osoba. Výzkum se mimo jiné zaměřil na to, kolik bolestivého obsahu – například témata násilí, nemocí či smrti – bude vygenerováno v souvislosti s jednotlivými gendery. Podle výsledků vyprodukoval český a slovenský BERT nejvíc bolestivého obsahu v souvislosti s muži, polský naopak s ženami. Nebinární subjekt byl s bolestivým obsahem asociován nejméně – výzkumníci to ale vysvětlují tím, že modely pravděpodobně neznají slovo nebinární. Je důležité si v tomto případě uvědomit, že LLMs jsou ale nejčastěji vícejazyčné a kulturní

---

<sup>6</sup> Nevyčištěná datová sada například vedla k tomu, že AI modely vědců z Massachusettského technologického institutu (MIT) používaly v komunikaci s uživateli rasistické a misogynní nadávky. (Quach 2020)



normy se často v rámci jednotlivých řečí nemusí projevit vůbec. (Hämmerl a spol. 2022)

Výzkumníci napříč spektrem přiznávají, že modely také často tzv. „halucinují“ a uvádějí očividné výmysly jako fakta. To podle některých může být výhodou v produkci dezinformací, které fungují na principu textů vyvolávající silné (a obvykle negativní) reakce, i přestože nejsou faktograficky správné. Někteří se proto obávají, aby je dezinformátoři nezačali využívat pro automatickou tvorbu dezinformačního obsahu, což by následně mohlo zefektivnit i jeho šíření. (Strategic Comments 2023)

### 4.3 Crowdsourcing

Kromě internetového obsahu můžou zdrojem dat pro učení velkých jazykových modelů být i tzv. crowdsourcingové firmy. Ty fungují na principech tzv. „gig economies“, což jsou ekonomické systémy, ve kterých místo zaměstnanců na plný úvazek pracují nezávislí outsourceri, pracující na dočasných a flexibilních projektech. (Allon 2024)

AI modely fungují na principu sbírání velkého množství informací od velkého množství lidí a jejich zdrojů. Díky počtu zapojených osob by systémy měly být diverzifikované, nezaujaté a reprezentativní. (Reffel 2023) Výhodou je také jejich rychlost a levnost. Nabízí se ale otázka, zdali lidé poskytující svá data nejsou vykořisťováni.

Vývojáři mohou své tazatele požádat i o zpětnou vazbu. Lidský faktor je důležitý zároveň jako beta trénink na pokládání otázek a zadávání instrukcí poté, co model už veškeré datové korpuse zpracoval a musí se je naučit používat. V porovnání s množstvím zpracovaných dat je lidský zásah minimální, zato je ovšem finančně velmi náročný. Aby měl LLM dostatečnou zpětnou vazbu a mohl se proměnit ve funkčního chatbota, jsou zapotřebí až stovky tisíc hodin práce. (Hern 2024) Pro lidi v crowdsourcingových firmách, kteří svá data poskytují, jde ale často o úkol nad rámec jejich pracovních činností. (Reffel 2023)

Příkladem takovéto společnosti je Amazon Mechanical Turk, crowdsourcingový trh, do jehož pracovního portfolia spadají úkoly na vyžádání, které nemohou dělat počítače, jako psaní popisů produktů, ověřování dat, účasti v průzkumech, moderování obsahu, identifikace obsahu na obrázků apod. (Amazon Mechanical Turk 2024)

Společnosti zabývající se umělou inteligencí často outsourcují ale i v zemích globálního jihu, kde mohou pracovníky s anglofonními znalostmi najímat za málo

peněž. Hern (2024) uvádí příklad pracovníků v africké Keni: „*Okinyi, bývalý moderátor obsahu pro ChatGPT od OpenAI v keňském Nairobi, je jeden ze čtyř lidí v této pozici, kteří keňské vládě podali petici, ve které ji vyzývají k vyšetření toho, co sami nazývají jako ‚vykořisťující podmínky pro dodavatele‘.*“<sup>7</sup>

Důsledkem vlivu „africké angličtiny“ na jazyk ChatuGPT je například nadužívání slova „*delve*“ (ponořit se) v porovnání s jeho ne tak hojným výskytem na internetu. Toto slovo je ale naopak velmi běžným na africkém webu, jelikož i jeho zastoupení v business angličtině je mnohem častější než v psané formě ve Velké Británii nebo Spojených státech amerických. Autor si na závěr pokládá otázku: Pokud AI zní jako africká angličtina a africká angličtina tím pádem zní jako AI, co se stane, až jako systémy umělé inteligence bude znít většina lidstva, která se na jejich tréninku podílela? (Hern 2024)

## 5 Environmentální zátěž

Dalším etickým problémem, který se datových sad pro velké jazykové modely týká, je jejich environmentální zátěž. Veškeré parametry, které modely zpracovávají, mají dopad na životní prostředí, a tím i na udržitelnost výzkumu a vývoje. (Gupta a spol. 2023) Současné LLMs vyžadují obrovské množství výpočetního výkonu, aby mohly zpracovávat veškeré datové sady uvedené výše. Podle odhadů spotřebuje nejnovější<sup>8</sup> velký jazykový model od společnosti OpenAI, ChatGPT-4, během tří měsíců při zpracovávání bilionů slov až 25 tisíc nejmodernějších grafických procesorových jednotek. (Smith a spol. 2023)

Vliv na životní prostředí můžeme měřit různými způsoby, jedním z nejčastějších je měření emisí oxidu uhličitého, jelikož je CO<sub>2</sub> hlavním skleníkovým plynem, který způsobuje globální oteplování (Smith a spol. 2023). Uhlíkové emise LLM produkuje ve dvou fázích: během počátečních nákladů na sestavení a trénování modelu a poté během nákladů na jeho provoz (Vartziotis a spol. 2024). Kromě emisí uhlíku mají výpočetní zařízení vliv i na spotřebu vody a znečištění půdy. (Rillig 2023)

---

<sup>7</sup> Originál: „Okinyi, a former content moderator for OpenAI’s ChatGPT in Nairobi, Kenya, is one of four people in that role who have filed a petition to the Kenyan government calling for an investigation into what they describe as exploitative conditions for contractors.“ (Hern 2024)

<sup>8</sup> Ke dni 12. 5. 2024

Odhadované emise CO<sub>2</sub> pro trénink velkého jazykového modelu mohou být až 10x vyšší než životní cyklus osobního automobilu (Strubell a spol. 2019). Smith a spol. (2023) například uvádí, že náklady základní verze ChatuGPT-3 se pohybují okolo 1 287 000 kilowatthodin nebo 552 tun emisí oxidu uhličitého (Vartziotis a spol. 2024). Údajně je to podobný počet tun jako když 2-3 plné Boeingsy 767 letí z New Yorku do San Franciska a zase zpátky (Smith a spol. 2023). Nemluvě o tom, že další energetickou nálož stojí zpracování jednotlivých dotazů a pokynů – podle odhadů model pro odpověď na jednu otázku, kterých může denně být až 100 milionů, musí vynaložit energii ve výši 0,002 kWh. (Vartziotis a spol. 2024)

S tématem životního prostředí souvisí i obsah jazykových modelů. Autoři upozorňují nejen na možnosti externího ovlivnění, ať už vstupních dat, algoritmů nebo výstupů, ale i zastoupení současných názorů společnosti na environmentální témata projevující se na internetu. Podle Rilliga a spol. (2023) by mohly nepřímo vést k potlačení hlasů volajících k zastavení klimatické změny a upozorňujících na její rizika. Na druhou stranu ale uznávají, že díky velkým jazykovým modelům by vzdělávání o životním prostředí mohlo být efektivnější – například díky personalizaci obsahu podle věku či úrovně vzdělání.

## Závěr

Tato práce měla za cíl přiblížit tzv. velké jazykové modely, které představují zásadní pokrok v oblasti umělé inteligence a strojového učení. Jejich využití má široké možnosti aplikace, od komunikace s chatboty po překlad textů. Tento pokrok je ale provázen řadou etických problémů a rizik.

Jedním z hlavních etických dilemat v souvislosti s LLMs je kvalita a charakter zdrojových dat, na kterých tyto modely trénují. Jsou to nejrůznější formální i neformální internetové obsahy včetně sociálních sítí, akademických prací nebo Wikipedie. Tyto zdroje ale často mohou být zaujaté, zkreslené a nereprezentativní, což může vést například ke stereotypizaci nebo šíření dezinformací. Důležitou otázkou je v tomto kontextu i ochrana osobních dat a dodržování zásad soukromí. Součástí sběru trénovacích dat je i tzv. crowdsourcing, který přináší další etická rizika spojená například s nespravedlivými pracovními podmínkami a vykořisťováním pracovníků, zejména v zemích globálního jihu.

Významným aspektem je i environmentální zátěž spojená s tréninkem a provozem těchto modelů, které vyžadují velké množství výpočetního výkonu, čímž přispívá k emisím oxidu uhličitého a dalším formám znečištění životního prostředí.

Není mým úkolem rozhodovat o tom, zdali výhody, které LLMs přinášejí, převažují nad jejich riziky. Myslím, že je důležité, aby se výzkumníci, vědci, vývojáři i regulační orgány nebáli využívat jejich předností a přínosu pro společnost, ale zároveň spolupracovali na minimalizaci negativních dopadů technologií, včetně řádného etického ukotvení. To se týká zejména transparentnosti při sběru dat, ochrany soukromí, spravedlivých pracovních podmínek nebo snížení uhlíkové stopy modelů.

# Zdroje

AL ALI, Adnan. (2023) Gender stereotypes in neural sentence representations. Bakalářská práce, vedoucí Libovický, Jindřich. Praha: Univerzita Karlova, Matematicko-fyzikální fakulta, Ústav formální a aplikované lingvistiky.

ALLON, Gad. Gig Economy, AI, and LLM: Friends or Foes? Online. Gad's Newsletter. 2024. Dostupné z: <https://gadallon.substack.com/p/gig-economy-ai-and-llm-friends-or>. [cit. 2024-05-12].

Amazon Mechanical Turk. Online. Amazon Mechanical Turk. 2024. Dostupné z: <https://www.mturk.com/>. [cit. 2024-05-12].

AMOROSO, D., & TAMBURRINI, G. (2019). What makes human control over weapon systems “meaningful”? ICRA Working Paper Series #4.

BENDER, E. M., GEBRU, T., MCMILLAN-MAJOR, A. & S. SHMITCHELL. On the dangers of stochastic parrots: Can language models be too big? In Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency, FAccT '21, page 610–623, New York, NY, USA, 2021. Association for Computing Machinery. ISBN 9781450383097. doi: 10.1145/ 3442188.3445922. URL <https://doi.org/10.1145/3442188.3445922>.

GUINNESS, Harry. What is GPT? Everything you need to know about GPT-3 and GPT-4. Online. Zapier. 2023. Dostupné z: <https://zapier.com/blog/what-is-gpt/>. [cit. 2024-05-12].

GUPTA, B. B., GAURAV, A., & V. ARYA (2024). Navigating the security landscape of large language models in enterprise information systems. Enterprise Information Systems, 18(4).

GUPTA, B. B., GAURAV, A., KUMAR PANIGRAHI, P. & V. ARYA. (2023). “Analysis of Artificial Intelligence-Based Technologies and Approaches on Sustainable Entrepreneurship.” Technological Forecasting & Social Change 186:122152.

HÄMMERL, K., DEISEROTH, B., SCHRAMOWSKI, P., LIBOVICKÝ, J., FRASER, A. & KERSTING, K. (2022), Do Multilingual Language Models Capture Differing Moral Norms?, Ithaca.

HASHEMI-POUR, Cameron a LUTKEVICH, Ben. BERT language model. Online. TechTarget. 2024. Dostupné z: <https://www.techtarget.com/searchenterpriseai/definition/BERT-language-model#:~:text=BERT%2C%20which%20stands%20for%20Bidirectional,calculated%20based%20upon%20their%20connection>. [cit. 2024-05-12].

HENDRYCHOVÁ, Lucie. (2024) Technologie založená na umělé inteligenci: Právní aspekty ochrany dat a soukromí. Rigorózní práce, vedoucí Svobodová, Magdaléna. Praha: Univerzita Karlova, Právnická fakulta, Katedra evropského práva.

HERN, Alex. TechScape: How cheap, outsourced labour in Africa is shaping AI English. Online. The Guardian. 2024. Dostupné z: <https://www.theguardian.com/technology/2024/apr/16/techscape-ai-gadgest-humane-ai-pin-chatgpt>. [cit. 2024-05-13].

KHANAM, S., TANWEER, S. & S. SIBTAIN KHALID. (2022). “Future of Internet of Things: Enhancing Cloud-Based IoT Using Artificial Intelligence.” International Journal of Cloud Applications and Computing (IJCAC) 12 (1): 1–23. <https://doi.org/10.4018/IJCAC.297094>

KINSELLA, Bret. GPT-4 is Better Than GPT-3.5 - Here Are Some Key Differences. Online. Synthedia. 2023. Dostupné z: <https://synthedia.substack.com/p/gpt-4-is-better-than-gpt-35-here>. [cit. 2024-05-12].

KŘEN, M., V. CVRČEK, T. ČAPKA, A. ČERMÁKOVÁ, M. HNÁTKOVÁ, L. CHLUMSKÁ, T. JELÍNEK, D. KOVÁŘÍKOVÁ, V. PETKEVIČ, P. PROCHÁZKA, H. SKOUMALOVÁ, M. ŠKRABAL, P. TRUNEČEK, P. VONDŘIČKA & A. ZASINA. (2016). SYN v4: large corpus of written czech. URL <http://hdl.handle.net/11234/1-1846>. LINDAT/CLARIAH-CZ digital library at the Institute of Formal and Applied Linguistics (ÚFAL), Faculty of Mathematics and Physics, Charles University.

Large language models: fast proliferation and budding international competition. (2023). Strategic Comments, 29(2), iv–vi. <https://doi.org/10.1080/13567888.2023.2198430>

LEE, Kenny. Open-Sourced Training Datasets for Large Language Models (LLMs). Online. Kili Technology. 2023. Dostupné z: <https://kili-technology.com/large-language-models-llms/9-open-sourced-datasets-for-training-large-language-models>. [cit. 2024-05-12].

LEE, P., GOLDBERG, C. & I. KOHANE. (2023). The AI revolution in medicine: GPT-4 and beyond. 1st ed. Harlow: Pearson.

MARR, Bernard. A Short History Of ChatGPT: How We Got To Where We Are Today. Online. Forbes. Dostupné z: <https://www.forbes.com/sites/bernardmarr/2023/05/19/a-short-history-of-chatgpt-how-we-got-to-where-we-are-today/>. [cit. 2024-05-13].

MARTINKOVÁ, S., STAŃCZAK, K. & I. AUGENSTEIN. (2023) Measuring gender bias in west slavic language models.

MCKEOWN, T., MUSTAFINA, J., MAGIZOV R. & C. GATAULLINA. (2020) "AI in Law Practices," 13th International Conference on Developments in eSystems Engineering (DeSE), Liverpool, United Kingdom, 2020, pp. 27-32, <https://doi:10.1109/DeSE51703.2020.9450780>

OpenAI. (2024). ChatGPT-3.5 [Large language model]. <https://chat.openai.com>

QUACH, Katyanna. MIT apologizes, permanently pulls offline huge dataset that taught AI systems to use racist, misogynistic slurs. Online. The Register. 2020. Dostupné z: [https://www.theregister.com/2020/07/01/mit\\_dataset\\_removed](https://www.theregister.com/2020/07/01/mit_dataset_removed). [cit. 2024-05-12].

REFFELL, Clive. Why is Crowdsourcing Vital to Make AI Smarter? Online. Crowdsourcing Week. 2023. Dostupné z: <https://crowdsourcingweek.com/blog/crowdsourcing-makes-ai-smarter/#:~:text=Crowdsourcing%20is%20a%20powerful%20technique,who%20will%20be%20using%20them>. [cit. 2024-05-12].

RILLIG, M. C., ÅGERSTRAND, M., BI, M., GOULD, K. A. & U. SAUERLAND, (2023), Risks and Benefits of Large Language Models for the Environment, Environmental Science & Technology 57 (9), 3464-3466 DOI: <https://10.1021/acs.est.3c01106>

ROUSE, Margaret. Large Language Model (LLM). Online. Techopedia. 2024b. Dostupné z: <https://www.techopedia.com/definition/34948/large-language-model-llm>. [cit. 2024-05-12].

ROUSE, Margaret. Machine Learning (ML). Online. Techopedia. 2024a. Dostupné z: <https://www.techopedia.com/definition/8181/machine-learning-ml>. [cit. 2024-05-12].

SHAHAB, Omer; EL KURDI, Bara; SHAUKAT, Aasma; NADKARNI, Girish a SOROUSH, Ali. Large language models: a primer and gastroenterology applications: a primer and gastroenterology applications. Therapeutic Advances in Gastroenterology. 2024/02/22, roč. 17. Dostupné z: <https://doi.org/10.1177/17562848241227031>.

SIDO, J., PRAŽÁK, O., PŘIBÁŇ, P., PAŠEK, J., SEJÁK, M. & M. KONOPÍK. (2021). Czett – czech bert-like model for language representation.

SMITH, Greg; BATEMAN, Michael; GILLET, Remy a THANISCH, Eystein. Environmental Impact of Large Language Models. Online. Cutter. 2023. Dostupné z: <https://www.cutter.com/article/environmental-impact-large-language-models>. [cit. 2024-05-12].

STRUBELL, E., GANESH, A. & A. MCCALLUM, (2019). “Energy and policy considerations for deep learning in NLP,” in Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics, Florence, Italy: Association for Computational Linguistics, Jul. 2019, pp. 3645–3650. DOI: 10. 18653 / v1 / P19 - 1355. [Online]. Available: <https://aclanthology.org/P19-1355>

VARTZIOTIS, T., DELLATOLAS, I., DASOULAS, G., SCHMIDT, M., SCHNEIDER, F., HOFFMANN, T., KOTSOPOULOS, S., & KECKEISEN, M. (2024). Learn to Code Sustainably: An Empirical Study on LLM-based Green Code Generation. ArXiv. /abs/2403.03344

VELI, Nesin. What Are the Best Sources of Training Data for Language Models? Online. Irdentrics. 2023. Dostupné z: <https://identrics.ai/what-are-the-best-sources-of-training-data-for-language-models/>. [cit. 2024-05-12].