

Bottyán Sándor¹

A nagy nyelvi modellek működése és képzése, valamint alkalmazásuk stratégiai elemzése, 2. rész

The Operation and Training of Large Language Models and a Strategic Analysis of Their Application, Part 2

A nagy nyelvi modellek működése komplexitásukból adódóan nehezen érthető és magyarázható tárgykör, de ez a kétrészes tanulmány megkísérli közérthetően bemutatni annak alapvetéseit és a velük tapasztalható jelenségeket. A második részben kifejtjük a nagy nyelvi modellek képzési ciklusát, a képzés alapjául szolgáló adatkészletek típusait, az előképzés, a finomhangolás módszertanát és jellegzetességeit, valamint a modellek gyakori alkalmazási módozatait. A nagy nyelvi modellek alkalmazásának előnyeit és hátrányait egy SWOT-elemzés keretében analizáljuk, kiegészítve azon releváns belső és külső tényezőkkel, amelyek egy szervezet által folytatott információfeldolgozási folyamatban jelentkezhetnek. A tanulmányt azoknak ajánljuk, akik a nemzetbiztonsági területen folytatott információfeldolgozás iránt érdeklődnek, továbbá akik átfogó ismeretanyagot keresnek a nagy nyelvi modellekről, és azt saját kutatásaikban szeretnék felhasználni.

Kulcsszavak: nagy nyelvi modell, mesterséges intelligencia, ChatGPT, gépi tanulás

The complexity of large language models makes them a difficult subject to understand and explain, but this two-part study attempts to present their basic principles and the phenomena they reveal in a clear and accessible way. In the second part, the training cycle for large language models, the types of data sets on which the training is based, the methodology and characteristics of pre-training and fine-tuning, and common applications are explained. Furthermore, in order to provide a comprehensive understanding of the advantages and disadvantages of the large language models, a detailed SWOT analysis has been carried out to evaluate the relevant internal and

¹ Hallgató, Nemzeti Közszolgálati Egyetem Hadtudományi és Honvédtisztképző Kar Katonai Műszaki Doktori Iskola, e-mail: bottyán.sándor@gmail.com

external factors that may be involved in the information processing procedure of an organisation. The study is recommended for those interested in the field of information processing by national security, who are looking for a comprehensive knowledge on the large language models and want to use it in their own research.

Keywords: *large language model, artificial intelligence, ChatGPT, machine learning*

Bevezetés

Napjainkban a mesterséges intelligencia (MI) területén tapasztalható gyors fejlődés egyik legmeghatározóbb vívmánya a nagy nyelvi modellek (*large language models*, LLM) megjelenése. Ezek a modellek hatalmas mennyiségű szöveges adat feldolgozására, valamint összefüggések és mintázatok felfedezésére képesek – olyan hatékonysággal, amelyhez emberi erőforrással csak rendkívüli idő- és munkaráfordítással tudnánk felérni. A modern LLM-eket alkalmazó keretrendszerek lehetővé teszik a szöveges tartalmak és metaadatok közel valós idejű, együttes elemzését, mégpedig olyan volumenben, amelyet hagyományos módszerekkel csak nehezen vagy egyáltalán nem lehetne megvalósítani. A modellek leghatékonyabb működéséhez jelentős erőforrások biztosítása és a hozzájuk kapcsolódó eljárások harmonizálása szükséges, amelyet biztosítani csak kellő szakértelemmel (például adattudósok, számítástechnikai mérnökök, nyelvtudósok stb.) és jelentős tőkebevonással lehet. Bár ezek még közismert tények, a legújabb LLM-fejlesztések eredményei (például otthon, lokális környezetben futtatható modellek) lehetővé teszik új felhasználási módok megjelenését. A modellek segítségével a friss adathalmazokból kinyerhető időszerű tudás rendkívül értékes, és ez a nemzetbiztonsági tevékenységek (például hírszerzés és kockázatelemzés) területén sincs másként. A széles körű adatgyűjtés és annak gyors feldolgozása alapvető fontosságú a nemzetbiztonsági szervek számára. Az evidenciák összekapcsolásával létrejövő új tudás felismerése megelőzheti az állami működésre veszélyes kritikus eseményeket, elősegítheti a terrorizmus elleni küzdelmet, továbbá támogatást nyújthat a kiberhadviselésben és a diplomáciai tevékenységekben is. Míg a kétrészes tanulmány első részében a modellek technikai vonatkozásainak néhány aspektusát vizsgáltuk, addig ebben a második részben inkább a szervezeti követelményekre és az alkalmazás során fellépő ismert tényezőkre (erősségek, gyengeségek, lehetőségek, fenyegetések) koncentrálnunk, illetve ezek közös értékelését végezzük el. Az LLM-ek offenzív felhasználása (például kártékony kódok írása, terrorista cselekmények tudástámogatása) ma már nem példa nélküli, ugyanakkor ez az összeállított tudásanyag hozzásegít ahhoz, hogy a nagy nyelvi modellekre egy hatékony információkinyerési eszközként gondoljunk, és felismerjük a nemzetbiztonsági feladatokhoz kapcsolódó eljárásokban betöltött szerepüket, így támogatva a technológia felhasználását az állambiztonság növelése érdekében.

Nagy nyelvi modellek képzése

A nagy nyelvi modellek által biztosított képességek olyan hatékonyságnövelő lehetőségek, amelyekkel a legtöbb szervezet élni szeretne, azonban önálló modellek létrehozása

leginkább az óriásvállalatokra vagy kutatóközpontokra jellemző, de néhány esetben közösségi kezdeményezések is előfordulnak. Ennek oka, hogy a modellfejlesztés és üzemeltetés monumentális erőforrásokat igényel, emellett az eljárás hosszas és költséges. Jelentős tőkebevonás szükséges a hosszú távú projektfolyamatok (például infrastruktúra-tervezés, adatvásárlás, adatgyűjtés és előkészítési eljárások, emberi erőforrások, K+F folyamatok, termékfejlesztés stb.) pénzügyi támogatására. Nagy adatkészletek szükségesek a modellek tanítási folyamataihoz és az eredmények kiértékeléséhez egyaránt, az adatok felkészítése a modellképzéshez is jelentős erőforrásokat emészt fel. A versenyképes interdiszciplináris szakértelem (például adattudósok és adate mérnökök, géptanulás-kutatók, nyelvészek, NLP² szakértők, szoftverfejlesztők és mérnökök, etikai, adatvédelmi és jogi szakértők stb.) biztosítását nem lehet kizárólag anyagi forrásból biztosítani, az leginkább a szervezett kutatási és fejlesztési háttérrel rendelkező technológiai nagyvállalatok privilégiuma. A nagyszabású számítási képességre képes informatikai infrastruktúra rendelkezésre állása szintén nem könnyen biztosítható feltétel, bár már egyes felhőalapú rendszerek és adatközpontok gazdaságosan hozzáférhetőek.

A tőkebevonás mértékének durva becsléséhez segítségül jöhet néhány szakirodalmi információ. 2020-ban az Open AI kutatótudósai közzétettek egy tanulmányt a GPT-3 modell részletezéséről,³ az itt publikált adatok alapján független szakértők 12 millió dollárra becsülték a modell képzési költségét.⁴ A szükséges informatikai infrastruktúra becsléséhez költségpéldázat lehet az MT-NLG (Megatron-Turing Natural Language Generation)⁵ nagy nyelvi modellről kiadott információk elemzése, amely szerint a modell képzése egy *Selene* szuperszámítógépen⁶ történt, és minden modellreplika betanítása 560 db DGX A100 GPU teljesítményét igényelte, amelyeknek darabontként a piaci ára több mint 200 ezer dollár. A tömördek számítási művelet végrehajtása irreálisan hosszú betanítási időt (akár több hét vagy hónap) eredményezhet, így a tanítási folyamat tervezése és megvalósítása során kiemelt figyelmet kell fordítani az algoritmusok, a szoftverek és a hardverek együttes optimalizálására.⁷ Amennyiben az említett feltételek rendelkezésre állnak, abban az esetben megkezdhető a modell fejlesztési folyamata, a következőkben ennek bemutatására térünk rá.

A fejlesztési ciklus

A nagy nyelvi modellalkotás lépéseinek részletezésére a terjedelmi korlátok okán nincs lehetőségünk, így ezt a folyamatot csak általánosságban érintjük. A részfolyamatok (például adatfeldolgozás, fejlesztés, képzés, értékelés stb.) összességére mint eljárásra hivatkozhatunk képzési folyamatként, modellfejlesztési folyamatként is. De az „adattól a modellig” megközelítésre egy olyan fejlesztési ciklusként tekinthetünk, amelynek alábbi főbb pontjait minden eltérő modellalkotási folyamatban közel azonosan megtaláljuk (1. ábra).

² Natural language processing, vagyis természetes nyelvfeldolgozás.

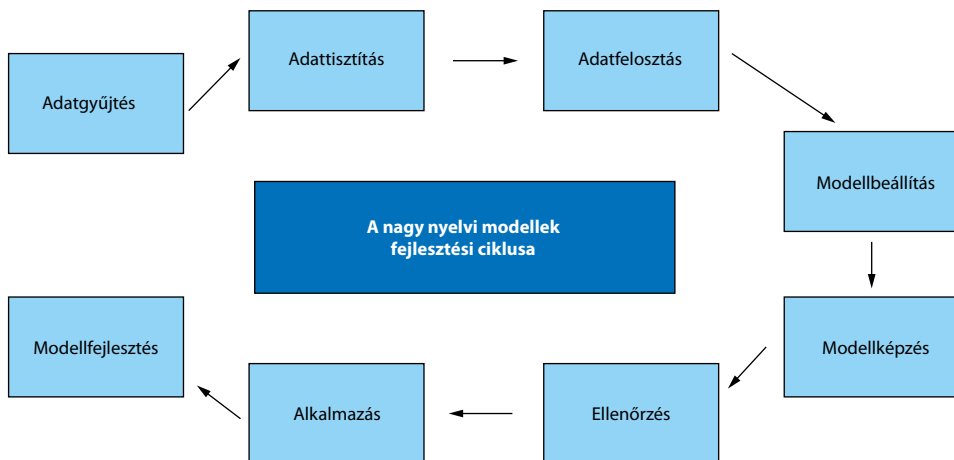
³ BROWN et al. 2020.

⁴ WIGGERS 2020.

⁵ Egy nagy nyelvi modell, amelyet a Microsoft és az Nvidia fejlesztett ki. Több száz milliárd paraméterrel rendelkezik. Az egyik legnagyobb és legfejlettebb transzformer alapú nyelvi modell.

⁶ HARANGI 2020.

⁷ KHARYA-ALVI 2021.



1. ábra: A nagy nyelvi modellek megalkotásának főbb lépései

Forrás: a szerző szerkesztése

A nagy nyelvi modellek fejlesztési ciklusának főbb lépései:

1. Az *adatgyűjtés* (*data gathering*) fázisában összegyűjtik a nyelvi modell képzéséhez szükséges adatokat. A cél az, hogy elegendő mennyiségű és változatos adat álljon rendelkezésre, továbbá amennyiben speciális felhasználásra tervezzük a modellt, abban az esetben a tartományspecifikus⁸ adatkészlet összeállítása is szükséges.
2. Az *adattisztítás* (*data cleaning*) szükséges eljárás annak okán, hogy az összegyűjtött adatok gyakran tartalmaznak hibás, irreleváns vagy torz információkat. A folyamat célja az adatkészlet felkészítése a tanítási folyamatra. Ebben a lépésben eltávolítják azokat az elemeket, amelyek zavarnák a modell tanulási folyamatát, például helyesírási hibák, duplikált adatok vagy irreleváns tartalmak.
3. Az *adatok felosztása* (*data splitting*). A tanítóanyagot általában három különböző részre osztják: tanítási adat (*training data*), validálási adat (*validation data*) és tesztadat (*test data*). A tanítási adatokra építve tanul a modell, a validálási adatokkal ellenőrzik a modell teljesítményét a képzés során, a tesztadatokkal pedig a végső értékelést végzik a modell teljesítményéről. Az adatfelosztás biztosítja, hogy a modell ne tanulja meg a tesztadatokat, ezáltal a teljesítményértékelés objektív marad.
4. A modell beállítása vagy felállítása (*model setup*) során annak konfigurációját állítják be. Ez magában foglalja a modell tanulási folyamatát befolyásoló tényezők, tehát a modell architektúrájának (például típusa és mérete stb.) és

⁸ A tartományspecifikus adatkészlet (angolul: *domain-specific dataset*) olyan különleges adatkészlet, amely nemcsak az általános nyelvi formulákat tartalmazza, hanem egy kiválasztott területről (pl. orvosi, jogi, mérnöki stb.), szakterületről használ fel szöveges tartalmat, így annak a szakterületnek a speciális nyelvi jellegzetességeit (pl. szaknyelv, terminológia stb.) is magában hordozza.

a hiperparaméterek, valamint a képzési eljárás optimális konfigurációjának meghatározását (például batch size,⁹ epochok¹⁰ száma).

5. A modell tanítása vagy képzése (*model training*) alatt a modell a tanítóadaton keresztül próbálja optimalizálni a paramétereit, felismerni a mintázatokat, és fokozatosan javítja a predikciós képességeit. A legnagyobb forrásszükségletű eljárás, hiszen tömérdek számítás igényel, ezáltal sok időt is vesz igénybe. A képzés általában egy kétciklusú (előképzési és finomhangolási) mechanizmusra bontva történik, utóbbi a modellfejlesztési ciklusban is végrehajtható.
6. A modell ellenőrzése (*model checking*) a teljes fejlesztési ciklus során gyakori szükséglet, hiszen a kiemelkedő erőforrás-felvétel megindokolja a folyamatok helyes működéséről való rendszeres meggyőződést, így a modell tanítása közben és után is ellenőrzik a modell teljesítményét, valamint igyekeznek elkerülni a túltanulás (*overfitting*)¹¹ állapotát.
7. A modell alkalmazhatósága vagy a használhatóságáról (*model usability*) való meggyőződés során megvizsgálják, hogy mennyire hatékony a gyakorlati alkalmazásokban. Ez a lépés magában foglalja annak értékelését, hogy a modell milyen jól teljesít azokon a feladatokon, amelyekre tervezték.
8. A ciklus zárásaként, a folyamatban feltárt információkra alapozva lehetőség nyílik a modell fejlesztésére (*model enhancement*). Miután a modell használhatóságát tesztelték, lehetőség van a továbbfejlesztésre, például több adat hozzáadásával további finomhangolás (*fine tune*) elvégzésére, a módosítható paraméterek utólagos módosítására, annak érdekében, hogy a modell teljesítménye tovább javuljon.

A képzési adatkészletek

Az eddigiekben több alkalommal lett érintve, hogy a képzéshez a jelentős szöveges tartalmat biztosító adatkészlet vagy korpusz (*corpus*) egyfajta fundamentum. Ebben a fejezetben rövid bemutatás következik az alkalmazható adatkészletek általános típusairól és forrásaikról.

Az alapvető források közé tartoznak:

- Nyilvános adatkészletek (*public datasets*). Különbő forrásból származó, szabadon hozzáférhető adathalmazok, amelyeket leggyakrabban tudományos intézmények vagy kormányzati szervek osztanak meg nyilvánosan (például weboldalak, könyvek, cikkek). Előnyük a sokféleségükben és méretükben rejlik.¹²
- A tartomány-specifikus adatkészleteket (*domain-specific datasets*) egy adott területre vagy iparágra szabták, hiszen úgy lettek összeállítva, hogy tartalmazzák a területre

⁹ A tanítóanyag azon részalmazára, amelyet egyszerre fel tud dolgozni a modell, egy tételként (*batch*) hivatkozunk.

¹⁰ Amikor a modell képzése során az a teljes tanítóanyagon egyszer végighalad, azt egy korszaknak (*epoch*) jelöljük.

¹¹ Az *overfitting*, magyarul túltanulás vagy túllilleszkedés egy nem optimális, de gyakori jelenség a gépi tanulás során, *beleértve* a nagy nyelvi modellek képzését is. A modell túlságosan „ráilleszkedik” a tanítóadatra, beleértve annak hibáit is. Ennek eredményeképpen a modell nagyon jól teljesít a validálási és tesztadatokkal végzett értékelések során, de amikor olyan feladat végrehajtására alkalmazzuk, amelyre a tanítóadatan nem látott példát, a modell teljesítménye jelentősen romlik.

¹² CHAWRE 2023.

jellemző egyedi nyelvi mintákat és terminológiát. A finomhangolás során leginkább alkalmazott adatkészlet, hiszen ezzel javítható a nyelvi pontosság olyan egyedi tématerületeken, mint például a jog, az orvostudomány vagy a pénzügy.¹³

- Felhasználói tartalmakból összeállított adatkészlet (*user-generated contents*) a közösségi médiában megjelent bejegyzésekből, fórumbeszélgetésekből, termékismertetőkből, blogbejegyzésekből származó, változatos nyelvi stílust és kifejezést tartalmazó összeállítást jelent. Hatalmas mennyiségével biztosítja az LLM-ek számára a folyamatosan frissülő adatkészletet, valamint a naprakész információkat és nyelvi formátumokat.¹⁴
- Liszenszelt korpuszok (*licensed data corpora*). Megbízható forrásból származó, strukturált adatgyűjtemény, amelynek használatát legalább kétoldalú megállapodás szabályozza. Leginkább kiadóktól és adatszolgáltatóktól szerezhetőek be, szövegeket, képeket, hangfelvételeket tartalmaznak.¹⁵ A képzés szempontjából értékesek és minőségiek, és a szerzői jogok tekintetében garantálják a jogbiztonságot, ugyanakkor felhasználásuk költséges és korlátozott.¹⁶
- Kódtárak (*code repositories*). Programozási forráskódok gyűjteménye, valamint az ehhez fűződő dokumentumok és egyéb megjegyzések széles köre, amelyek leginkább olyan felületen érhetőek el, mint például a GitHub,¹⁷ GitLab¹⁸ és Bitbucket.¹⁹ A kódtárak elemzésével az LLM-ek megtanulják a programozással kapcsolatos szövegezés megértését és generálását, így jártasságot szerezve a szoftverfejlesztés (például *text to code*²⁰ feladatok) területén.²¹
- Szintetikus adatkészlet (*synthesized datasets*). Technikai megoldással létrehozott adathalmaz, amely során mesterséges adatokat állítanak elő olyan esetekben, amikor a természetes adatok szűkösek, érzékenyek, vagy elérésük költséges. Létrehozásukhoz olyan algoritmusokat alkalmaznak, amelyek a valós adatok jellemzőivel megegyező tartalmat állítanak elő. Előnyük van adatvédelem, méretezhetőség és sokszínűség tekintetében, azonban nem mindig valóságűiek, a generáló algoritmusok fejlesztése és finomhangolása időigényes.²²

Az LLM-ek képzési adatkészletei általában minden fentebb felsorolt csoportból tartalmaznak legalább egy típusú forrást, de a források összetételét leginkább az határozza meg, hogy milyen célú felhasználásra tervezték a modellt, mert előzetesen ennek alapján tervezik és szervezik össze a képzési adatkészletet is (1. táblázat).²³

¹³ CHAWRE 2023.

¹⁴ CHAWRE 2023.

¹⁵ Ilyenek angol nyelven a Corpus of Contemporary American English (COCA), vagy a British National Corpus (BNC), magyar nyelven a Magyar Nemzeti Szövegtár (MNSZ), továbbá egyéb digitális könyvtárak vagy könyvtári adatbázisok.

¹⁶ CHAWRE 2023.

¹⁷ GitHub. Lásd: <https://github.com/>

¹⁸ GitLab. Lásd: <https://gitlab.com/>

¹⁹ Bitbucket. Lásd: <https://bitbucket.org/>

²⁰ A *text to code* gyűjtőnévvel hivatkoznak azon feladatok körére, amikor a modellek természetes nyelven kiadott emberi utasítások alapján programozási forráskódokat állítanak elő.

²¹ CHAWRE 2023.

²² CHAWRE 2023.

²³ BOTTYÁN 2024: 43.

1. táblázat: A LLaMa modell alaptanítása (pre-training) alatt alkalmazott tanítóanyag összetétele és felhasználása

Adatkészlet	Mintavétel (%)	Korszakok	Méret (GB)
CommonCrawl	67,0	1,10	3,3
C4	15,0	1,06	783
Github	4,5	0,64	328
Wikipedia	4,5	2,45	83
Books	4,5	2,23	85
ArXiv	2,5	1,06	92
Stack Exchange	2,0	1,06	78

Forrás: TOUVRON et al. 2023: 2.

Általánosságban elmondható – de a zavarosabb adatkészletek esetében szükségszerű –, hogy a képzési adatokat felkészítésnek vetik alá: átalakítják, osztályozzák, tokenizálják, tisztítják, deduplikálják, pontozzák és priorizálják, illetve elvetik az alacsony minőségű adatkészletet. A folyamat előkészítésének részeként a modell működési célját tekintve kiválasztják a legcélszerűbb és/vagy a legminőségibb adatkészletet, és ennek megfelelően bontják fel azt a képzési folyamatban úgy, hogy az adatkészlet változatossága azért megmaradjon.²⁴

Az előképzés

Az előképzés vagy alapképzés (pre-training) során súlyozódnak be a képzetlen modell paraméterei annak érdekében, hogy a megismert minta (például az előző tokenek sorozatának szekvenciája és a kontextus jelentésének reprezentációja) alapján sikerrel jelezze elő a soron következő tokenet. A nagy nyelvi modellek képzési folyamatára általánosságban felügyelet nélküli tanulásként hivatkozunk, hiszen előzetesen nem kap definiált kimenetet, azonban a modell architektúrájának perspektívájából ez egy úgynevezett *önfelügyelt tanulás*, hiszen a predikciót követően a tanulóanyagtól megkapja a jó választ (a soron következő helyes token), majd az esetleges hibás predikciót követően újrakalibrálódnak a szükséges paraméterek.²⁵ Az előképzési folyamat végén, a modellel elért teljesítményre a validációs veszteség (*lm loss value*),²⁶ valamint a perplexitás (*lm loss ppl*)²⁷ mérőszámaival hivatkoznak.²⁸

A nyilvánosan elérhető nagy nyelvi modellek gyakorta elő vannak tanítva, hiszen a természetes nyelvek alapvető szekvenciális kapcsolatai és kontextusbeli jelentései azonosak a korpuszokban, így azt nem szükséges újra végrehajtani. Egy adott modell nulláról történő betanítása csak abban az esetben válhat szükségessé, amennyiben azt olyan

²⁴ BOTTYÁN 2024: 43.

²⁵ DROST 2023.

²⁶ A nyelvi modell tanítása során mért veszteség azt méri, hogy mennyire jól teljesít a modell a következő token előrejelzésében.

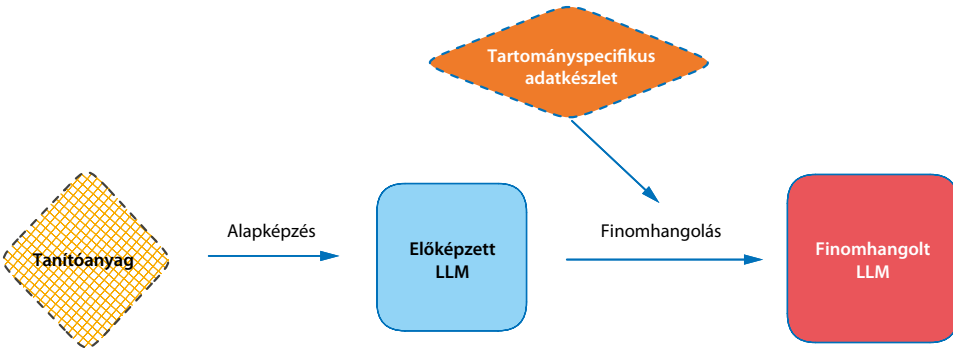
²⁷ A perplexity az „*lm loss value*” exponenciális transzformációja, és azt mutatja, hogy átlagosan hány lehetőséget vesz figyelembe a modell, amikor a következő token előrejelzésén dolgozik. Az alacsony ppl érték jobb modelteljesítményt jelez, mivel a modell kevesebb lehetőséget kezel.

²⁸ YANG ZIJIAN et al. 2023: 7.

speciális feladatra szükséges tanítani, amelynek tanítóanyaga²⁹ eltér a természetes nyelvi struktúrától és jellemzőktől.

A finomhangolás

A finomhangolás során az előképzett modell további tanítása speciális adatkészlet felhasználásával történik, amely az alapképzésnél felhasznált korpuszoktól kisebb, azonban specifikus (tartományspecifikus) adatkészlettel igyekszik a modellt a célfeladat nyelvi környezetével és jellemzőivel felvértezni. E képzési folyamat (2. ábra) során csak az architektúra utolsó rétegeiben található paraméterek újralibrálása történik meg, ezáltal a képzési erőforrások töredékét igényli és gyorsabban is végrehajtható. Itt meg kell említeni a finomhangolás egy alkalmazott speciális esetét, az emberi visszacsatolású megerősített tanulást (*reinforcement learning from human feedback*), amely során a modellt arra konfigurálják, hogy emberi csevegéshez hasonló eredményt produkáljon (például ChatGPT), és ehhez valós emberi visszajelzéseket vesznek alapul.



2. ábra: A finomhangolás folyamata

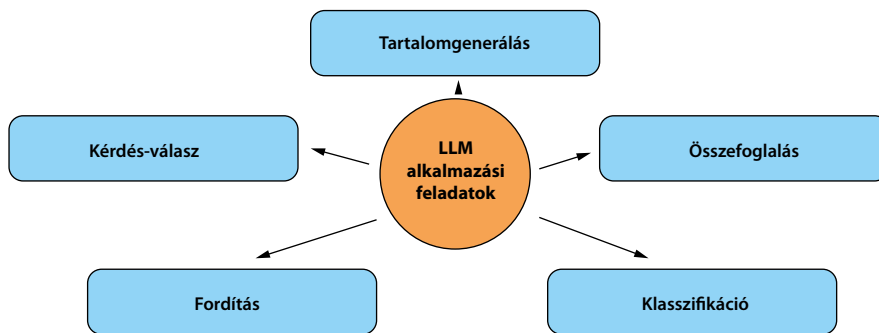
Forrás: a szerző szerkesztése

Alkalmazhatóság

A generatív mesterséges intelligenciák közül az LLM jelentős hatást gyakorol a szociális (például politika, tudományos kutatások, pszichológia stb.) és a gazdasági folyamatokra (például média, marketing, oktatás, szoftverfejlesztés, gyógyszeripar, orvosi tevékenységek, építési technológia) egyaránt.³⁰ Ezekben a területeken leginkább különböző ügynökként (*agent*) alkalmaznak LLM-képességeket, amelyek a feladatra tervezett és illesztett

²⁹ Ilyenek lehetnek például a programozási nyelvek, DNS-adatok, matematikai formulák, kémiai szerkezetek stb.

³⁰ WANG et al. 2024: 13–17; HADI et al. 2025: 4–5.



3. ábra: A nagy nyelvi modellek főbb alkalmazási területei

Forrás: a szerző szerkesztése

keretrendszerekben kapnak helyet. A szövegalapú (*text-based*) tartalmak tekintetében az alábbi főbb feladatokban (3. ábra) alkalmazzák azokat:

- *Kérdés-válasz tevékenység (question-answer, QA)*. Az alapképzést követően kifejezetten kérdéseket és válaszokat tartalmazó korpussszal finomhangolt LLM-ek eredményességüknek köszönhetően megkerülhetetlenné váltak a QA-rendszerekben. A betanított adatok mellett a figyelemmechanizmusnak és kontextusmegértésnek köszönhetően a kérdésekre nagy pontosságú válasz szintetizálható. Erre a képességre alapozva sikeresek chatbot és asszisztencia jellegű felhasználásban.³¹
- A *tartalomgenerálás* (például történetek, marketingtartalmak, blogtartalmak, bulvár- vagy kutatási cikkek, közösségimédia-tartalmak, termékleírások, programozási forráskódok, e-mailek stb.) hasznos alkalmazási módja az LLM-rendszereknek. Erre a képességre alapozva további automatizált ügynökök (például asszisztencia-alkalmazások) hozhatók létre.
- A hosszú szöveges tartalmak (például hírek, jelentések, értekezletek jegyzőkönyveinek, jogi dokumentumok stb.) koherens *összefoglalása* szintén fontos és előnyös tulajdonsága a nagy nyelvi modelleknek. A gyors és lényegi információkinyerés kulcsfontosságú lehet olyan keretrendszerek megalkotásában, ahol jelentős mértékben történik információfelvétel, továbbá ezzel összefüggésben gyors és hatékony feldolgozás válik szükségessé.
- A *szövegosztályozást* avagy *klasszifikációt* igénylő feladatokra automatizált keretrendszerekben szintén hatékony az LLM modell, hiszen előre meghatározott jellemzők szerinti tartomelemzés és kategorizálás hatékonyan képes hozzájárulni olyan speciális feladatok eredményességéhez, mint például a nyelvazonosítás, a szentimentelemzés, a spam-szűrés, a tartalommoderálás vagy az ügyfélvisszajelzések elemzése.
- A természetes nyelvek közötti *fordításban* is eredményes annak okán, hogy a beágyazás következtében a különböző nyelvek közötti fogalmak által felvett vektorértékek között hatékonyan kimutathatók a kapcsolatok. Ennek köszönhetően kivételes pontossággal képes egyik nyelvről a másikra fordítani szöveges tartalmat.³²

³¹ Lásd: <https://www.nvidia.com/en-us/glossary/large-language-models>

³² HADI et al. 2023: 19–20.

Az eltérő célok szerint alkotott LLM-architektúrát alkalmazó szoftvereknek természetesen differens jellemzői is vannak, azonban magában az LLM-architektúrában és a hozzá tartozó külső kapcsolatokban megfigyelhetők olyan tulajdonságok (például erősségek, gyengeségek, lehetőségek, fenyegetések), amelyek azonosíthatók heterogén alkalmazási formulákban. E jellemzők együttes feltárására kiváló eszköz a SWOT-analízis.³³

Nagy nyelvi modellek SWOT-analízise

A tanulmányban több helyen említettük a nagy nyelvi modellek komplexitását, így természetesen tulajdonságaik és jellemzőik áttekintése is összetett megközelítést igényel. A szakirodalmi bázisban az ilyen témákat feldolgozó tanulmányok gyakoriak, hiszen a technológia alkalmazásával járó kockázatok feltárása népszerűnek mondhatók. Yupeng Chang és munkatársai tanulmányukban³⁴ vizsgálták az LLM gyengeségeit és erősségeit, Muhammad Usman Hadi és munkatársai két hasonló tanulmányukban³⁵ pedig az alkalmazással járó kihívásokat és limitációkat járták körbe. Az általuk tett megállapítások felhasználásával, valamint az eddigiekben bemutatott ismeretanyag felhasználása alapján a szerző egy SWOT-analízisben összegezte azokat.

2. táblázat: Nagy nyelvi modellek SWOT-analízise

NAGY NYELVI MODELLEK SWOT-ANALÍZISE		
	Erősségek (<i>strengths</i>)	Gyengeségek (<i>weaknesses</i>)
Belső tényezők	<ul style="list-style-type: none"> • Döntéstámogatás • Folyamatos fejlődés • Folyékony, koherens szövegalkotás • Fordítási képesség • Kiváló NLP teljesítmény • Kontextuális megértés • Nyelvi megértés • Összefoglalás • Programozási nyelvek kezelése • Szövegosztályozás • Tartalomgenerálás • Többnyelvű alkalmazás 	<ul style="list-style-type: none"> • Adatszükséglet, adatfüggés és toxicitás • Aritmetikai és logikai következtetés • Információszivárgás • Gyenge NLI*-teljesítmény • Hallucináció és hiteltelenség • Jelentős erőforrás-felhasználás, költség és képzési időigény • Jelentős válaszdíó • Kiberbiztonsági sebezhetőség • Kontextuális információhiány • Korlátozott ismeretkezelés • Korlátozott tudásfrissítés • Nehéz értelmezhetőség • Nem optimális környezet • Összetett kontextusértelmezés

³³ A SWOT-analízis egy stratégiai tervezési eszköz, amely egy szervezet erősségeit (*strengths*), gyengeségeit (*weaknesses*), lehetőségeit (*opportunities*) és fenyegetéseit (*threats*) vizsgálja, hogy átfogó képet nyújtson a belső és külső tényezőkről.

³⁴ YUPENG CHANG et al. 2023.

³⁵ HADI et al. 2025.

NAGY NYELVI MODELLEK SWOT-ANALÍZISE		
	Lehetőségek (opportunities)	Fenyegetések (threats)
Külső tényezők	<ul style="list-style-type: none"> • Diszruptivitás • Energiaigények csökkentése • Felhasználók bizalmának erősítése • Forrásfelhasználás-csökkentés • Globális szerepvállalás • Komponensként alkalmazás • Multifunkcionalitás • Szabályozás • Szabványosítás 	<ul style="list-style-type: none"> • Gyors elévülés • Etikai problémák • Polgári jogi fenyegetés • Szabályozási kihívás • Társadalmi megítélés • Kibertámadási fenyegetettség • Szintetikus adatok terjedése

Megjegyzés: * NLI (natural language inference), azaz természetes nyelvi következtetés. Az NLI egy olyan folyamat vagy feladat, amely során a rendszer megpróbálja megállapítani, hogy egy adott állítás logikailag következik-e egy másik szöveges állításból, ellentmondásban áll-e vele, vagy semleges viszonyban van vele.

Forrás: a szerző szerkesztése

Erősségek (strengths)

Jelentős mennyiségű információ rendelkezésre állása esetén az LLM-ek hasznosak a döntéstámogatásban, hiszen a modellek képesek hatékonyan meghatározni, hogy egy adott kontextusban mely válasz vagy akció a legvalószínűbb. Azonban e mögött nem reális döntéshozatal rejlik, hanem egy mintafelismerés, amelyben a leggyakoribb választ fogalmazzuk meg az összefüggések figyelembevételével. Továbbá a modellek rendkívül eredményesek a folyékony, természetes nyelvű, koherens szövegalkotásban (például tartalomkészítés, párbeszédalkotása), valamint a szöveges tartalom különböző részei közötti összefüggések alapján végzett következtetésben, amely biztosítja a kontextuális megértés (például kivonatolás) képességét is. A klasszikus NLP képességeik (szemantika, szintaktika, szentimentelemzés, entitásfelismerés, kérdés-válasz stb.) erősségeként listázhatók, de egyéb nyelvi feldolgozási feladatokban (nyelvi fordítások) is kiválóak, jól teljesítenek a programozási nyelvek feldolgozásában és generálásában (*text to code*). Ide sorolható a modellek többnyelvű alkalmazásának lehetősége, hiszen a több természetesen nyelvet tartalmazó tanítóadatnak köszönhetően számos nyelven utasítható, és a megtanult kontextusbeli jelentések fordíthatók a kívánt modell által ismert nyelvre. A gépi tanulás és a nagy nyelvi modell mint technológia fejlesztése az utóbbi években rendkívüli iramot diktál, rendszeresen újabb variánsok jelennek meg, így biztosítva a folyamatos fejlődést. A megújulás folyamatosan indukálja az új felhasználási opciók megjelenését, aminek köszönhetően az alkalmazási lehetőségek köre is bővül.

Gyengeségek (weaknesses)

Az analízisben a gyengeséghez sorolható tulajdonságok egyértelműen számbeli többségben vannak a többi rendszerezett jellegzetességhez képest. Elsőként, bár a legfrissebb modellek egyre jobb eredményeket érnek el az NLI-teljesítményben, ide kell sorolnunk

az emberi ellentmondások nehézkes kezelését (például nem racionalitáson alapuló véleménykülönbségek azonosítása). Korlátozott képességként szintén ide sorolandó a szöveges tartalmakban megtalálható események közötti szemantikai hasonlóság és az absztrakt gondolkodás felismerése, valamint az összetett kontextus értelmezése.³⁶ Szintén kritikus aspektus a kontextuális információ hiánya, hiszen amennyiben a modell nem rendelkezik kellő mennyiségben feldolgozható információval (például „gondolatláncolattal” megalkotott prompt), a szemantikai elemzések teljesítménye alulmarad az elvárttól.

Közismert tény a nagy nyelvi modellek „hallucinálása”, vagyis, hogy valótlan vagy pontatlan információkat szolgáltatnak leggyakrabban annak okán, hogy megpróbálják áthidalni az ismerethiányból eredő korlátokat. A modellek nem rendelkeznek tényleges és teljes körű „tudással” a világról, hanem statisztikai minták alapján hoznak létre válaszokat, így amennyiben olyan kérdéssel találkoznak, amelyhez nincs a tanítóadaton nyugvó, releváns és megalapozott ismeret, a valószínűségszámításon alapuló válaszadás nem feltétlenül lesz minden esetben igaz. A hallucináció oka összetett probléma, amely az architektúrátípussal, a tanítóadattal és a tanítási folyamattal egyaránt összefügg.³⁷

Az LLM egyik alapköve a tanítóanyag, ezáltal a képzés sikeressége függ a felhasznált adatok mennyiségétől és minőségétől. Tekintve, hogy a modellképzés során hatalmas mennyiségű tanítóanyag összeállítása, áttekintése, értékelése és előkészítése szükséges, ez komoly kihívást jelent. Hasonlóan a tanítóadattól ered a hiteltelenség problémája is. A téves vagy ellentmondásos információkat tartalmazó képzési adat nem befolyásolja a működést, azonban a modell nem képes különbséget tenni az igaz és hamis információk között, így előfordulhat, hogy valótlan információt használ fel a válaszadás során. Továbbá, amennyiben a tanítóadatban káros tartalom (például elfogultság, gyűlöletbeszéd, előítélek vagy más káros információ) jelenik meg, annak feldolgozása esetében sajnos a modell képes ugyanilyen jellemzőkkel bíró generatív eredményt produkálni (toxikus működés). Ezek alapján az LLM által szolgáltatott információ nem tekinthető teljes mértékben megbízható, hiteles forrásnak. E mellett egyértelmű, hogy a tanítóanyagként összeállított óriási adathalmazt manuálisan ellenőrizni lehetetlen, így a tisztításokat követően is tartalmazhatnak bizalmas információkat (például személyes adatokat). Ez a modellműködés során adatvédelmi szivárgásokhoz vezethet, véletlenszerűen vagy a rosszindulatú prompttevékenységeknek köszönhetően egyaránt.

Valós tapasztalás az is, hogy a nagy nyelvi modellek aritmetikai és logikai következtetési képességei erősen korlátozottak. A szöveges korpuszokon végzett tanítási folyamat és a modellek működése nem matematikai műveletek végrehajtására lett tervezve és optimalizálva. A modellek a szöveg alapján próbálnak mintákat felismerni, de nem rendelkeznek olyan explicit matematikai képességekkel, mint egy erre tervezett algoritmus.

A nagy nyelvi modellek képzése és működtetése jelentős és optimalizált számítási kapacitást biztosító infrastruktúrát igényel, ami nehezen biztosítható követelmény, és amelynek hiányában az alapjaiban is időigényes folyamatok az eredménytelenség mellett jelentős pénz- és energiapazarlással járhatnak.³⁸ Ugyanakkor, a modellek újratanítása szintén költséges folyamat, és rendszeres gyakorisággal nem fenntartható. Bár bizonyos architektúrák

³⁶ BOTTYÁN 2024: 60.

³⁷ GREENE 2022.

³⁸ A jelenséggel járó kockázatok elkerülésére már számos technikai megoldás létezik, például a *Parameter-Efficient Fine-Tuning*, *Low-Rank Adaptation (LoRA)*, *LongLora* avagy a *QLora*.

esetében léteznek technikák a modellműködés módosítására, azonban ezeknek csak korlátozott lehetőségei vannak, így ebből a szempontból a működés limitálnak tekinthető. Illetve a megfelelő konfigurációs beállítások meghatározása leginkább csak tapasztalati úton, próbálkozásokkal határozható meg, ami szintén jelentős erőforrás-felhasználással jár. További hátrány a nagy memóriafelhasználásból és számításikapacitás-igényből adódó hosszú válaszidő is.³⁹

A nagy nyelvi modellekkel kapcsolatosan elmondható, hogy azok működése nehezen magyarázható és értelmezhető, nem szakértő személyek számára kihívást jelent az ezzel kapcsolatos ismeretek elsajátítása. Működése a társadalom jelentős részének egyfajta misztikum, ez nehezíti a technológia térnyerését és az azzal kapcsolatos felelősségvállalást és etikus alkalmazást. Korlátozott ismeretkezelés: az alaptanítással képzett modellek szakmai tudást igénylő tartományi (például jog, egészségügy stb.) felhasználás esetében finomhangolás nélkül nem eredményesek, ennek okán nehéz generális feladatokra hatékony modellt létrehozni. Emellett a promptok kétértelműsége és a logikai műveletek megértésével kapcsolatos belső korlátok miatt fellépő következtetési hibák okán komplex tervekészítési feladatokban nem kellően eredményesek a modellek.

Lehetőségek (opportunities)

A nagy nyelvi modellek lehetőségei nem csupán a technológia önálló fejlődéséből erednek, hanem olyan külső tényezőkből is származtathatók, amelyek hatással vannak annak alkalmazására. Amennyiben sikerül azon területeken fejlődést elérni, amelyek kedvezően befolyásolják a gépi tanulási környezeteket, az hozzájárulhat az LLM felhasználási gyakoriságának növeléséhez. A nagy nyelvi modellek gyengeségei közé sorolt energiaigények valóban hátráltatják a technológia térnyerését, azonban manapság számos kutatás igyekszik az adatközpontok energiaellátását csökkenteni. A környezetbarát megoldásokra való törekvés mellett az adatfeldolgozás, a mesterséges intelligencia és a fenntartható technológiák összekapcsolása jelentős előrelépést hozhat az LLM-ek széles körű alkalmazásában. Az újgenerációs mobilhálózatok (például 5G) és egyéb jövőbeni hálózati technológiák terjedése lehetővé teszi az LLM-ek valós idejű alkalmazását olyan területeken is, ahol korábban a sávszélesség vagy a késleltetés problémát jelentett.

A multifunkcionalitásnak köszönhetően felhasználása egyre népszerűbb, napjainkban az LLM-képességeket komponensként gyakorta integrálják különböző szoftverekbe, amely megoldások köre folyamatosan bővül. Továbbá eredményei okán diszruptív, hiszen új perspektívákat nyit meg az eddigi alkalmazott eljárásokban (például adatok kezelése, ügyfélszolgálati chatbot, automatikus fordítások), valamint forradalmasíthatja, felválthatja azokat. Modularitásának köszönhetően különböző technológiákkal bővíthető, ami tovább növeli a felhasználási lehetőségek körét. A nagy nyelvi modellek nem csupán a természetes nyelv feldolgozásának hatékonyságát javítják, hanem az automatizálás és az intelligens rendszerek fejlődését is támogatják. Ezen túlmenően az LLM-ek különösen

³⁹ Ehhez kapcsolódóan meg kell említeni, hogy bizonyos feladatügnökök több ciklusban hajtanak végre LLM-lekérdezéseket, az így felhalmozódó reakcióidő már számottevő. A jelenséget már speciális technikai megoldások (pl. kvantálás, *efficient attention*, *multi-attention query* stb.) alkalmazásával próbálják csökkenteni.

hasznosnak bizonyulhatnak a globális együttműködések terén. A nemzetközi szereplők közötti kommunikáció megkönnyítésével, a különböző nyelveken végzett automatizált fordításoknak köszönhetően segíthetik a globális szintű kapcsolatok (kereskedelem, gazdasági együttműködések) hatékonyságának növelését.

Nemzetközi szabványok (pl. ISO/IEC 42000 szabványcsalád) és a kapcsolódó jogi szabályozók (például AI Act) alkalmazásának elterjedése szintén pozitív hatással lehet az LLM-ek fejlődésére, az adatbiztonság és a magánélet védelmének e téren való érvényesítésére. Az egységes szabályozás elősegíti a technológia biztonságos és etikus alkalmazását, ami közvetetten hozzájárul ahhoz, hogy a felhasználók bizalommal forduljanak ezekhez a technológiákhoz.

Fenyegetések (threats)

Az LLM-re ható fenyegetések köre sokrétűnek mondható, azonban a legpotenciálisabb külső fenyegetés a rosszindulatú, a modell működését manipuláló vagy megakadályozó kibertámadások megvalósítása. Evidens, hogy a sebezhetőségek számának mennyisége a nyilvános kapcsolattal ellátott keretrendszerekbe foglalt LLM-ek esetében számottevőbb, mint lokálisan futatott modellek esetében. A kiberfenyegetések közül a prompt injection⁴⁰ típusú támadást jegyzik a leginkább, hiszen a modellek érzékenyek a promptokra, különösen a rosszindulatú promptokra. Ilyen műveletekkel nagymértékben manipulálható a modellek működése és kimenetkezelése egyaránt, azonban olyan további támadástípusokat is meg lehet említeni, mint a szolgáltatásmegtagadás-támadás,⁴¹ a modellettulajdonítás,⁴² a tanítóadat-mérgezés,⁴³ az ellátási láncot célzó támadások⁴⁴ köre, és más egyéb ide sorolható módszerek. A nagy nyelvi modellek elektronikus információbiztonsági sebezhetősége valóban számottevő gyengeségi jellemző, így az azok kihasználására megjelenő rosszindulatú tevékenységek köre is számottevő és változatos. A téma górcső alá vétele jó eséllyel egy önálló tanulmány terjedelmét is felölelné, így ennek okán a további kibertámadási fenyegetések részletezésétől el kell tekintenünk.

Emellett az LLM-ek esetében a felhasznált tanítóanyaggal kapcsolatos szerzői és tulajdonjogi tárgyban indított polgári peres keresetek kimenetele eléggé bizonytalan. Amennyiben a képzési és működési eljárások alatt alkalmazott gyakorlatok nem kerülnek jogi szabályozás alá, számítani kell ilyen jellegű nehézségekre. Általánosságban elmondható, hogy a jelenleg alkalmazott tanítóanyagok jelentős részre webes tartalmakból összegyűjtött nyílt forrású adat. Az ilyen adathalmazzal végzett tanítások a későbbiekben

⁴⁰ A prompt injection során a felhasználó vagy másik program úgy manipulálja a bemeneti parancsot vagy utasítást (a promptot), hogy a rendszer nem várt vagy nem kívánt műveleteket hajtson végre. Ez különösen releváns az LLM modellek esetében.

⁴¹ Angolul denial-of-service attack (DoS). A támadók nagy mennyiségű hálózati forgalommal árasztják el az LLM infrastruktúráját, ami a rendelkezésre állás megszűnéséhez vezet.

⁴² Angolul: model theft. Egy modell kifejlesztése rendkívül költséges, így valós fenyegetés irányul annak lemásolására.

⁴³ A tanítóadatok rosszindulatú módosítása jelentősen befolyásolja a modell működését. Dezinformációs célok érvényesíthetők, akár hátsó kapuk (backdoor) hozhatók létre a modell manipulálására.

⁴⁴ A fejlesztési ciklus során megjelenő, vagy az üzemeltetési fenyegetések érvényesítése során végrehajtott modellkompromittálás.

fellépő adatszivárgás esetén az adatgyűjtési eljárással és az adatok védelmével kapcsolatos olyan etikai problémákat hozhatnak a felszínre, amelyek akár könnyen jogi aktusokká fejlődhetnek. Az LLM-ek vonatkozásában is tény, hogy a fejlődésük okozta társadalmi hatásokkal a jog ereje nem bír lépést tartani, így a szabályozatlanságból eredő problémák fenyegetésként jelentkeznek. A webes tartalmakra visszatérve említendő az is, hogy a generatív mesterséges intelligenciák megjelenése óta a tanítóanyagként felhasználható, nyíltan elérhető szöveges tartalmak egyre nagyobb része szintetikus adat. A mesterségesen előállított szöveges tartalom nem tartalmazza azon természetes nyelvi sajátosságokat, amelyek a nagy nyelvi modellek további eredményes fejlesztéséhez szükségesek, ennek eredményeképp az így létrehozott szövegek gyarapodására fenyegetésként tekinthetünk.

Említeni kell még az MI-k társadalmi megítélésével kapcsolatos nehézségeket. A technológia nehezen értelmezhető, és társadalmi elfogadása még kialakulóban van, ebből kifolyólag a társadalom tagjai úgy ítélik meg megjelenését, mint ami veszélyezteti az emberek munkahelyeit. Számolni kell a technológia rosszindulatú felhasználásának kockázatával is, hiszen a nyílt forráskódú modellek esetében bárhogy, hostolt modellek esetén a biztonsági védelem megkerülésével rosszindulatú célokra (például információgyűjtésre, dezinformációs tartalmak generálására, kibertámadásokra) is alkalmazható. Mindemellett a már említett rendkívül gyors ütemű fejlődésnek köszönhetően a legújabb modellek folyamatos fejlesztés és frissítés nélkül, bár képességeik tekintetében állandók, eredményeik tekintetében elavultnak számíthatnak rövid időn belül.⁴⁵

Összefoglalás

Az összeállított ismeretanyag tekintetében megállapíthatjuk, hogy amennyiben valamely szervezet saját nagy nyelvi modellt képzése, vagy bármely egyéb modellvariáns alkalmazó informatikai keretrendszer bevezetése mellett dönt, mindenféleképpen a szervezeti adatvagyon felmérése, valamint az azzal összefüggő adatgazdálkodási rendszer kialakítása az elsődleges feladata. Azonban emellett a modellek fenntarthatósága nagyban függ a fejlesztési ciklus rendszeres ismétlődésétől is. Egyrészt az erősségeket felhasználó és a lehetőségeket kihasználó fejlesztési szemlélet biztosítja a rendszeresen megújuló eredményességet, másrészt a modellt külsőleg fenyegető veszélyeket, valamint annak belső tulajdonságai között megjelenő gyengeségeket ciklusonként értékelve és kockázatokként kezelve biztosítható a nagy fokú rendelkezésre állás mellett az etikus és felelős használat.

A szervezeti adatvagyonról a generált szervezeti adat létrejöttéig számos feltételnek és folyamatnak kell teljesülnie, azonban a tanulmányban feltárt alapelvek és megállapítások figyelembevételével a modellek hatékonyan alkalmazhatók a szervezeti tevékenységekben. Amennyiben a nagy nyelvi modellek generatív képességét egy szervezet képes felelősen a saját szolgálatába állítani, az a hozzáadott érték mellett velejároként alakítja a szervezet mesterségesintelligencia-kultúráját is.

A LLM-fejlesztésben jelenleg tapasztalt legfőbb irányok (például erőforrás-felhasználás szempontú architektúraoptimalizálás, kompakt modellek, multimodalitás stb.) egyértelműen annak hátrányainak és hibáinak felszámolására is törekednek amellet,

⁴⁵ BOTTYÁN 2024: 62.

hogy a legkívánatosabb cél továbbra is a legeredményesebb modellek létrehozása. Ezt a jövőt vetíti elénk az a közelmúltban megjelent hír is, amely során az OpenAI vállalat bejelentése alapján o3 modelljük bizonyos teszteken egy átlagos ember eredmény szintjét érte el. Amennyiben hitelesnek tekinthetjük a vállalat által közölt információkat, ez az elért eredmény azt sugallja, hogy sikerült létrehozniuk egy rendkívül alkalmazkodóképes modellt.⁴⁶ Erre a tapasztalásra alapozva, valamint arra, hogy egyre több technikai megoldás (például RAG⁴⁷, RIG⁴⁸ stb.) igyekszik az LLM hatékonyságát még tovább növelni, kijelenthető az a megállapítás, hogy napjainkban a nagy nyelvi modellek jelenlegi teljesítményértékei és felhasználási területei nincsenek kőbe vésve, és a következő időszakokban magasabb szintű eredményekre, az ezzel együtt járó hatásokra számíthatunk.

Felhasznált irodalom

- BENNETT, Michael T. – PERRIER, Elija (2024): OpenAI Claims Its New Model Reached Human Level on a Test for ‘General Intelligence.’ What Does That Mean? *Gizmodo*, 2024. december 29. Online: https://gizmodo.com/openai-claims-its-new-model-reached-human-level-on-a-test-for-general-intelligence-what-does-that-mean-2000543834?utm_source=fark&utm_medium=website&utm_content=link&ICID=ref_fark
- BOTTYÁN Sándor (2024): *Nagy nyelvi modellel támogatott nyílt forrású információgyűjtés a kibertérben*. Tudományos diákköri dolgozat. Budapest: Nemzeti Közzolgálati Egyetem Államtudományi és Nemzetközi Tanulmányok Kar.
- BROWN, Tom B. – MANN, Benjamin – RYDER, Nick – SUBBIAH, Melanie – KAPLAN, Jared – DHARIWAL, Prafulla – NEELAKANTAN, Arvind – SHYAM, Pranav – SASTRY, Girish – ASKELL, Amanda – AGARWAL, Sandhini – HERBERT-VOSS, Ariel et al. (2020): *Language Models are Few-Shot Learners*. Online: <https://doi.org/10.48550/arXiv.2005.14165>
- CHAWRE, Huzefa (2023): Prominent Data Collection Methods and Tools for LLMs. *Turing*, 2023. november 21. Online: <https://www.turing.com/resources/data-collection-methods-and-tools-for-llms>
- DROST, Dorian (2023): Different Ways of Training LLMs. *Towards Data Science*, 2023. július 21. Online: <https://towardsdatascience.com/different-ways-of-training-llms-c57885f388ed>
- GREENE, Jenna (2022): Will ChatGPT Make Lawyers Obsolete? *Reuters*, 2022. december 9. Online: <https://www.reuters.com/legal/transactional/will-chatgpt-make-lawyers-obsolete-hint-be-afraid-2022-12-09/>
- HADI, Muhammad Usman – AL-TASHI, Qasem – QURESHI, Rizwan – SHAH, Abbas – MUNEEB, Amgad – IRFAN, Muhammad – ZAFAR, Anas – SHAIKH, Muhammad Bilal – AKHTAR, Naveed – AL-GARADI, Mohammed Ali – HASSAN, Syed Zohaib –

⁴⁶ BENNETT-PERRIER 2024.

⁴⁷ A Retrieval-Augmented Generation megoldás egy kimenetoptimalizálási folyamat, amely során a generatív folyamatokba szándékos beavatkozás történik. A válaszgenerálás előtt a képzési adatokon kívül egy hiteles tudásbázist (pl. adatbázisok és dokumentumok) is felhasznál a modell, ezáltal kiterjesztve a modell ismereteit, és csökkentve a hamis információfelhasználást, a hallucinációt és a pontatlanságot.

⁴⁸ A Retrieval-Integrated Generation technika a lekérdezési és generációs folyamatokat jobban összekapcsolja. Célja, hogy a modell jobban kihasználja a visszakeresett információkat és pontosabb, célzottabb választ adjon.

- SHOMAN, Maged – WU, Jia – MIRJALILI, Seyedali – SHAH, Mubarak (2023): *A Survey on Large Language Models: Applications, Challenges, Limitations, and Practical Usage*. TechRxiv. Online: <https://doi.org/10.36227/techrxiv.23589741.v1>
- HADI, Muhammad Usman – AL-TASHI, Qasem – QURESHI, Rizwan – SHAH, Abbas – MUNEER, Amgad – IRFAN, Muhammad – ZAFAR, Anas – SHAIKH, Muhammad Bilal – AKHTAR, Naveed – HASSAN, Syed Zohaib – SHOMAN, Maged – WU, Jia – MIRJALILI, Seyedali – SHAH, Mubarak (2025): *LLMs: A Comprehensive Survey of Applications, Challenges, Datasets, Limitations, and Future Prospects*. TechRxiv. Online: <https://doi.org/10.36227/techrxiv.23589741.v8>
- HARANGI László (2020): Egy hónap alatt összeszerelte az NVIDIA a világ hetedik leggyorsabb szuperszámítógépét. *PCW*, 2020. augusztus 17. Online: <https://www.pcwplus.hu/pcwpro/egy-honap-alatt-osszeszerelte-az-nvidia-a-vilag-hetedik-leggyorsabb-szuperszamitogepet-283131.html>
- KHARYA, Paresh – ALVI, Ali (2021): Using DeepSpeed and Megatron to Train Megatron-Turing NLG 530B, the World’s Largest and Most Powerful Generative Language Model. *Nvidia Developer*, 2021. október 11. Online: <https://developer.nvidia.com/blog/using-deepspeed-and-megatron-to-train-megatron-turing-nlg-530b-the-worlds-largest-and-most-powerful-generative-language-model/>
- TOUVRON, Hugo – LAVRIL, Thibaut – IZACARD, Gautier – MARTINET, Xavier – LACHAUX, Marie-Anne – LACROIX, Timothée – ROZIÈRE, Baptiste – GOYAL, Naman – HAMBRO, Eric – AZHAR, Faisal – RODRIGUEZ, Aurelien – JOULIN, Armand et al. (2023): *LLaMA: Open and Efficient Foundation Language Models*. Online: <https://doi.org/10.48550/arXiv.2302.13971>
- WANG, Lei – MA, Chen – FENG, Xueyang – ZHANG, Zeyu – YANG, Hao – ZHANG, Jingsen – CHEN, Zhiyuan – TANG, Jiakai – CHEN, Xu – LIN, Yankai – ZHAO, Wayne Xin – WEI, Zhewei – WEN, Jirong (2024): A Survey on Large Language Model Based Autonomous Agents. *Frontiers of Computer Science*, 18. Online: <https://doi.org/10.1007/s11704-024-40231-1>
- WIGGERS, Kyle (2020): OpenAI’s Massive GPT-3 Model is Impressive, But Size Isn’t Everything. *VentureBeat*, 2020. június 1. Online: <https://venturebeat.com/ai/ai-machine-learning-openai-gpt-3-size-isnt-everything>
- YANG ZIJIAN Győző – DODÉ Réka – FERENCZI Gergő – HÉJA Enikő – JELENCSEK MÁTYUS Kinga – KÖRÖS Ádám – LAKI László János – LIGETI-NAGY Noémi – VADÁSZ Noémi – VÁRADY Tamás (2023): *Jönnek a nagyok! BERT-Large, GPT-2 és GPT-3 nyelvmodellek magyar nyelvre*. XIX. Magyar Számítógépes Nyelvészeti Konferencia, Szeged, 2023. január 26–27. Online: <https://acta.bibl.u-szeged.hu/78417/>
- YUPENG, Chang et al. (2023): A Survey on Evaluation of Large Language Models. *Arxiv*. Online: <https://doi.org/10.48550/arXiv.2307.03109>