

ParancsPULI: Az utasításkövető PULI-modell

Yang Zijian Győző, Dodé Réka, Héja Enikő, Laki László János, Ligeti-Nagy Noémi, Madarász Gábor, Váradi Tamás

HUN-REN Nyelvtudományi Kutatóközpont
1068 Budapest, Benczúr utca 33.
{vezetéknév.keresztnév}@nytud.hun-ren.hu

Kivonat Megjelenése óta a ChatGPT a szűkebb szakmai diskurzuson túl a közbeszédet is tematizálta. Sikerét több összetevőnek is köszönheti: például a különböző témájú, széles skálát lefedő, promptokkal történő finomhangolásnak, vagy az emberi visszajelzések integrálásának a finomhangolás folyamatába megerősítéses tanulás segítségével. A ChatGPT megjelenésekor azt nyilatkozták, hogy a finomhangolás során csupán angol nyelvű promptokat használtak, azonban tapasztalhattuk, hogy az alkalmazás ennek ellenére magyarul is kiválóan tudott válaszolni. Ez a tulajdonság a transfertanulásnak köszönhető, amely lehetővé teszi, hogy a modell egy adott nyelvű tanítóadaton megszerzett tudást a tanítóadatban alulreprezentált vagy egyáltalán nem szereplő nyelvek esetén is alkalmazza. A kutatásunk során a háromnyelvű PULI GPTRio modellt finomhangoltuk magyar, angol és kínai promptokkal, hogy létrehozzuk az első magyar nyelvre tanított utasításkövető GPT-3 modellt. A modell tanításához egy több mint ötezer promptból álló finomhangoló korpuszt állítottunk össze. A finomhangoló korpuszba angol és kínai nyelvű promptokat is kevertünk, hogy a transfertanulásnak köszönhetően még több különböző típusú feladatot legyen képes megoldani a modell. A promptok összeállításánál figyeltünk arra is, hogy bizonyos kérdésköröket próbáljon elkerülni a modell. Ezzel létrehoztuk – tudomásunk szerint – az első magyar nyelvű, finomhangolt, utasításkövető nagy nyelvi modellt, amely egyaránt képes kérdésekre válaszolni és nyelvtechnológiai feladatokat megoldani.

Kulcsszavak: PULI, utasításkövető nagy nyelvi modell, GPT-3

1. Bevezetés

Az utóbbi években a nagy nyelvi modellek rendkívüli figyelmet kaptak. A nagyvállalatok között verseny alakult ki, hogy nagyobbnál nagyobb modelleket hozzanak létre. Céljuk ezzel, hogy olyan modellt tanítsanak be hatalmas mennyiségű adaton, amely képes önmagában különböző nyelvi feladatok megoldására. A nagy nyelvi modellek tanítása során megmutatták, hogy ha elég nagy a modell, és elég sok adaton tanították, akkor finomhangolás nélkül, kizárólag a promptprogramozással képes magas minőségben megoldani nyelvtechnológiai feladatokat (Chowdhery és mtsai, 2022). Az igazi mérföldkövet az OpenAI¹ által

¹ <https://openai.com>

kiadott ChatGPT² jelentette, amely minden korábbinál jobban mutatta, hogy mire lehet képes egy nagy nyelvi modell.

A ChatGPT újdonsága a korábbi modellekhez képest abban rejlett, hogy többretegű finomhangolással tanították. A ChatGPT sikerének hatására elindult egy új kutatási irány, ami a nagy nyelvi modellek finomhangolására irányul, többek között a megerősítéses tanulást integráló finomhangolásra vagy a paraméter-optimalizáción alapuló finomhangolásra.

Magyar nyelvre – tudásunk szerint – csak előtanított nagy nyelvi modellek léteznek. A PULI család része az egynyelvű 6,7 milliárd paraméteres PULI GPT-3SX (Yang és mtsai, 2023a) és a háromnyelvű (magyar-angol-kínai) 7,67 milliárd paraméteres PULI GPTrío (Yang és mtsai, 2023b). Emellett létezik még a kétnyelvű (angol-magyar) 6,7 milliárd paraméteres HILANCO-GPTX³ modell.

A kutatásunkban a ChatGPT mintáját követjük (Ouyang és mtsai, 2022), amely során első lépésként utasításokat (*instruct*) tartalmazó promptokkal finomhangoljuk a nagy nyelvi modellt. Így a jelen kutatás keretében létrehoztunk egy magyar nyelvű, finomhangoló promptgyűjteményt, majd a háromnyelvű PULI GPTrío modellt finomhangoltuk utasításkövető modellre, amelyet Parancs-PULI modellnek neveztünk el. A finomhangoló anyag folyamatosan bővül, ezért folyamatosan frissítjük a modellünket. Az aktuális utasításkövető modellünk kipróbálható a demó oldalunkon: <https://juniper.nytud.hu/demo/parancspuli>. Egy stabil változat elkészültekor a modellt feltöltjük a Hugging Face oldalunkra: <https://huggingface.co/NYTK>.

2. Kapcsolódó irodalom

A ChatGPT sikere két kiemelkedően fontos tényezőre vezethető vissza: az úgynevezett utasításkövető viselkedés elsajátítására és az emberi visszajelzéseknek az integrálására. A ChatGPT egy 'InstructGPT' variáns (Ouyang és mtsai, 2022), amely képes emberi utasításokra relevánsan reagálni. A nagy nyelvi modellekben rejlő potenciált már korábban felismerték (Brown és mtsai, 2020; Chowdhery és mtsai, 2022), és promptprogramozással próbálták kinyerni belőlük a releváns tudást. Azonban ezek a modellek még nem voltak képesek egyszerű emberi utasításokra, kérdésekre konzisztensen jól válaszolni. Ennek a képességnek az elsajátítására három lépésre volt szükség:

1. Először is, egy demonstrációs promptadatbázist kell létrehozni, amely bemutatja a modellnek a különféle utasításokra és kérdésekre adandó válaszokat. Ezt követően ezen adatok alapján felügyelt tanulási módszerekkel finomítjuk a nagy nyelvi modellt, amit *Supervised fine-tuning* – SFT-ként ismerünk.
2. Ezután a finomított modellt és más modelleket felhasználva generálunk válaszokat különböző promptokra. Ezeket a válaszokat emberek értékelik ki, és ezek az értékelések segítenek egy jutalommodell (*reward model*) kifejlesztésében.

² <https://chat.openai.com>

³ <https://hilanco.github.io>

3. Végül ezt a jutalommodellt felhasználva megerősítéses tanulási módszerekkel tovább csiszoljuk az SFT-modellt. A megerősítéses tanulás során a 'Proximal Policy Optimization' módszerét alkalmazzák (Schulman és mtsai, 2017).

A jelen kutatásunk során az 1. lépést végeztük el. A ChatGPT mögött két nagy nyelvi modell áll jelenleg: a GPT-3.5⁴ és a GPT-4 (OpenAI, 2023), ami 1,76 billió paraméteres és multi-modális, tehát így a szöveg mellett képet is képes feldolgozni. A GPT-3 nyelvi modellnek vannak még további úgynevezett utasításkövető ('instruction-following') modellvariánsai.

A ChatGPT sikerének egyik következménye, hogy nagy számban kezdtek el terjedni a különböző nagy nyelvi modellekre irányuló finomhangolások, és azok adathalmazainak előállításai. Az egyik legnépszerűbb nagy nyelvmodellcsalád lett a LLaMA (Touvron és mtsai, 2023a) és Llama 2 (Touvron és mtsai, 2023b) a Meta AI⁵ jóvoltából. LLaMA modellekből van 7 milliárd, 13 milliárd, 33 milliárd és 65 milliárd paraméteres variáns. A legkisebb modellt 1 billió tokenből álló korpuszon tanították, míg a legnagyobb modelleket 1,4 billió tokenen. A Llama 2 családban 7, 13 és 70 milliárd paraméteres variánsok vannak, és mindegyik modellt 2 billió tokenen tanították, továbbá megnövelték a bemeneti szöveg hosszát 4096-ra. A Llama 2 modelleket egyből finomhangolták is több mint 1 millió finomhangoló promptból álló korpuszon. Kétféle finomhangolt modellt tanítottak: chat és kódgeneráló. A finomhangolás folyamata megegyezik a ChatGPT által javasolt lépésekkel: először felügyelt tanuláson alapuló finomhangolást végeztek, majd megerősítéses tanuláson alapuló finomhangolást. A Llama modellek népszerűségét annak köszönhetik, hogy teljesen szabadon elérhetővé tették a modelleket.

A Llama modellek szabadon hozzáférhetőségének eredménye, hogy számos kutatás és projekt keletkezett a Llama modellekre építve. Az egyik népszerű projekt a Stanford Alpaca projekt (Taori és mtsai, 2023), amelyben a 'Self-Instruct' módszeréből (Wang és mtsai, 2022) inspirálódva, az OpenAI *text-davinci-003* modelljével generáltattak 52 ezer promptot. Majd a generált promptokkal felügyelt tanulással finomhangoltak egy 7 milliárd paraméteres LLaMA modellt. Annak ellenére, hogy a generált promptban sok hiba volt, a finomhangolt utasításkövető LLaMA modell hasonló teljesítményt képes nyújtani, mint a *text-davinci-003* modell.

A Vicuna projekt (Chiang és mtsai, 2023) keretében a ShareGPT adatbázist felhasználva nyílt forráskódú chatalkalmazást hoztak létre a 13 milliárd paraméteres LLaMA modellel, amely versenyképes teljesítményt képes nyújtani a ChatGPT alkalmazáshoz képest.

⁴ <https://platform.openai.com/docs/models/gpt-3-5>

⁵ <https://ai.meta.com>

Az OpenChatKit⁶ a Together AI⁷, a LAION⁸ és az Ontocord.AI⁹ együttműködésében kínál implementációt és különböző célú, finomhangolt LLaMA és GPT-NeoX modelleket.

Az utasításkövető modellek tanítására alkalmas korpusz a népszerű Dolly korpusz (Conover és mtsai, 2023), amely 15 ezer promptból áll.

A kínai Tsinghua egyetem is fejleszt saját nyelvmodelleket. Ezek a GLM modellek (Zeng és mtsai, 2022) és azok finomhangolt változatai, mint például a ChatGLM3 (Du és mtsai, 2022; Zeng és mtsai, 2022). Ez egy 6,2 milliárd paraméteres kétnyelvű társalgási modell, ami jelenleg az egyik legnépszerűbb ChatGPT helyettesítő alkalmazás Kínában. Kínai nyelven felülmúlja a ChatGPT képességeit.

3. A korpuszok

Az utasításkövető modell finomhangolásához elengedhetetlen egy utasításokat tartalmazó adathalmaz. Az adatok gyűjtése folyamatosan zajlik, a jelen fejezetben az aktuális állapotot mutatjuk be.

A magyar nyelvű utasításokat tartalmazó adathalmaz struktúrájának kialakításához a Stanford Alpaca (Taori és mtsai, 2023) mintáját vettük alapul, ami három mezőből áll: *instruct*, *input*, és *output*. Az *instruct* mezőben található a konkrét utasítás vagy kérdés, például „Ki volt Arany János?” vagy „Oldd meg a következő matematikai egyenletet!”. Az *input* mező opcionális, azoknál a feladatoknál töltjük ki, amelyek igényelnek egy konkrét tárgyat, vagy kontextust. Például a matematikai utasítás esetén ide írjuk be a kiszámolandó egyenletet. Az *output* mezőbe írjuk az utasításra megfogalmazott választ vagy eredményt.

A korpuszunk ezen kívül minden elemhez tartalmaz egy azonosítót (*id*), egy vagy több kategóriacímkét (*tags*), és különböző metaadatokat (*meta*) a szöveg származásáról (*alpaca*, vagy *translated*) és típusáról (pl. *kémia*, *érettségi*).

A finomhangoló korpusz fontosabb tulajdonságai láthatók az 1. táblázatban. A korpusz összetétele a következő:

- **Stanford Alpaca:** Lefordított Stanford Alpaca részkorpusz.
- **Lokalizáció:** 100 prompt lokalizált változata a Stanford Alpaca korpuszból. Például:
 - Eredeti: „Magyarázd el, miért jelentős a gettysburgi csata!”
 - Lokalizált: „Magyarázd el, miért jelentős a mohácsi csata!”
- **Érettségi feladatok:** magyar, matematika, történelem és kémiai érettségi feladatok.
- **HuLU:** A HuCB, HuCOLA, HuCoPA, HuRTE, HuSST és HuWNLI adatbázisból (Ligeti-Nagy és mtsai, 2022, 2023) generált promptok.

⁶ <https://github.com/togethercomputer/OpenChatKit>

⁷ <https://together.ai>

⁸ <https://laion.ai>

⁹ <https://www.ontocord.ai>

- **Rövid kérdések:** A PULI demó oldalán feltett rövid kérdések és válaszok. A válaszok nem a PULI által adott válaszok, hanem öt humán annotátortól gyűjtött válaszok. Nem mindegyik kérdésre van minden annotátortól válasz. A 1. táblázatban a zárójelben lévő szám az egyedi (*) szegmensek számát jelöli
- **Gépi fordítás:** A FLORES-101 validációs halmazából generált promptok. A fordítási nyelvek: angol-magyar, angol-kínai és magyar-kínai. Mindegyik nyelvek pár irányba, ezen kívül van még egy-több irányú fordítási prompt, például: „Fordítsd le angol, kínai, spanyol és német nyelvre!”
- **SQL:** Szabad szöveges megfogalmazásból SQL kód generálása.

	Szegmens	Szó			Átlagos szószám		
		Utastítás	Bemenet	Kimenet	Utastítás	Bemenet	Kimenet
'Stanford Alpaca'	2000	19720	8556	174777	9,9	4,3	87,4
Lokalizáció	100	771	149	5519	7.7	1.5	55.2
Érettségi feladatok	1226	14380	124240	19968	11,7	101,3	16,3
HuLU	1200	10206	41605	7320	8,5	34,7	6,1
Rövid kérdések	485 (361*)	2455	0	6670	5,06	0	13,8
Gépi fordítás	997	5679	14356	20598	5,7	14,4	20,6
SQL	795	8424	7845	11023	10,6	9,9	13,8

1. táblázat. Az alkorpuszok főbb tulajdonságai

A modell finomhangolásához a 2. táblázatban látható promptsablonokkal dolgoztunk.

A finomhangolások során azt tapasztaltuk, hogy a transfertanulásnak köszönhetően más nyelvekből is sok tudást képes megtanulni a modell. Ezért a magyar nyelvű promptok mellé hozzátettük még az angol nyelvű 'Stanford Alpaca' 52 ezer promptját és az angol nyelvű, 15 ezer promptból álló Dolly korpuszt. Továbbá a modell kínai tudását is szeretnénk volna megőrizni, ezért vettünk egy kínai nyelvű 'Alpaca' korpuszt (Cui és mtsai, 2023), abból is egy 15 ezer promptból álló alkorpuszt (emberek által átnézett és javított), ezen kívül egy kínai nyelvű, fordított Dolly korpuszt (Ziang Leng és Li, 2023). Ezek alkotják a végleges, háromnyelvű korpuszunkat, amelyet a modell tanításához használtunk.

4. Kísérletek és kiértékelések

A ChatGPT első változatában – tudomásunk szerint – nem volt magyar nyelvű finomhangoló prompt, mégis impozáns módon tudott magyarul kommunikálni. Ezt a transfertudást teszteltük először. Kutatásunk első lépéseként, mielőtt még a magyar nyelvű korpusz elkészült volna, a PULI GPTrío modellt az angol nyelvű 'Stanford Alpaca' korpuszon finomhangoltuk. Bár csak angol nyelvű prompton finomhangoltuk, elvárásunknak megfelelően képes volt a modell magyarul értelmezni a feladatot/kérdést és válaszolni rá. Azonban egy probléma volt vele;

Bemenettel rendelkező promptsablon:

Az alábbiakban egy utasítást találsz, amely leír egy feladatot, amelyhez egy bemenetet is mellékelünk, hogy további összefüggéseket adjon. Írj egy választ, amely megfelelően teljesíti a feladatot!

Utasítás:

{A korpusz 'instruct' mezője}

Bemenet:

{A korpusz 'input' mezője}

Válasz:

{A korpusz 'output' mezője}

Bemenet nélküli promptsablon:

Az alábbiakban egy utasítást találsz, amely leír egy feladatot. Írj egy választ, amely megfelelően teljesíti a feladatot!

Utasítás:

{A korpusz 'instruct' mezője}

Válasz:

{A korpusz 'output' mezője}

2. táblázat. A PULI finomhangolásához használt promptsablonok

sok esetben angolul válaszolt. A válaszok ilyenkor is relevánsak voltak, de mégis angol nyelven generálta a szöveget. Úgy tudtuk elérni, hogy magyar nyelven válaszoljon, hogy az utasításhoz hozzáírtuk, hogy „Magyarul kérem a választ!” (lásd 3. táblázat). Promptsablonnak a Stanford Alpaca implementációban használt angol nyelvű promptot alkalmaztuk.

Az első sikeres kísérlet után az volt a feltevésünk, hogy a modell elég robusztus ahhoz, hogy ha gépi fordított szövegen tanítjuk, akkor is képes megfelelően válaszolni. Ehhez a feladathoz vettük Laki és Yang (2022) legjobban teljesítő Marian modelljét, és lefordítottuk a 'Stanford Alpaca' korpuszt, majd a lefordított korpuszsal finomhangoltuk a PULI GPTrío modellt. A második modell már kevesebb angol választ generált, de sajnos még mindig volt rá példa (lásd 4. táblázat), ezen kívül elsajátította a gépi fordító modell által generált hibákat is. A válasz sok esetben jól indult, de a végére mondattanilag helytelen mondatokat generált (lásd 4. táblázat). Ezért indokoltnak láttuk a magyar nyelvű, tiszta prompt finomhangoló adathalmaz létrehozását. Az angol nyelvű generálás lehetséges okai az angol promptsablon és az olyan szegmensek a korpuszban, amelyeket a gépi fordító modell nem tudott lefordítani, ezért maradtak benne angol nyelvű részek. Mivel azokban az esetekben is gyakran rosszul generált a modell, ahol csak magyar nyelvű kimeneteket generált, ezért elvetettük ezt a modellt, és

Példa angol nyelvű válaszra:

Instruction:

Ki a legerősebb szuperhős?

Response:

The strongest superhero is none other than Tony Stark, the genius behind Stark Industries. He is a genius in the fields of science, technology, engineering, and construction, and has the capability to create and control powerful energy blasts and force.

Példa magyar nyelvű válaszra:

Instruction:

Ki a legerősebb szuperhős? Magyarul kérem a választ!

Response:

A legerősebb szuperhős egyértelműen Thor.

3. táblázat. Példa az angol nyelvű 'Stanford Alpaca' korpuszon finomhangolt modell generálására

nem végeztünk több kísérletet az angol nyelvű szövegenerálás problémájának javítására.

Instruction:

Ki a legerősebb szuperhős? Miért?

Response:

A legerősebb szuperhős egyértelműen Thor. Thor egy hatalmas istenség, akinek ereje a bátorság, a sebesség, a sebesség és a hihetetlen regenerációs képességgel társul. Thor is a mentor to many of his fellow Avengers, and his compassion and strength inspire others to follow in his own path.

Instruction:

Ki a legerősebb szuperhős? Miért?

Response:

A legerősebb szuperhős valószínűleg Superman, hihetetlen képességekkel és elszánt-sággal. Ő egy igazi hős, aki képes volt, hogy hatalmas bátorságot és erőt.

4. táblázat. Példa a gépi fordított 'Stanford Alpaca' korpuszon finomhangolt modell generálására

A magyar nyelvű korpusz összeállítása után betanítottuk a PULI GPTRio modellt a háromnyelvű korpuszunkkal (lásd 3. fejezet utolsó bekezdése). Mind-egyik finomhangoláshoz (előző kettő kísérlet esetén is), a 'Stanford Alpaca' (Taori és mtsai, 2023) implementációját használtuk, amelyben nem módosítottuk a hiperparamétereket: 4 batch/GPU (összesen 8 darab NVIDIA A100 GPU (80GB)); tanulási ráta=2e-5; warmup=0.03; epoch=3; deepspeed optimalizáció¹⁰. A finomhangolás körülbelül 16 órát vett igénybe.

¹⁰ <https://huggingface.co/docs/accelerate/v0.11.0/en/deepspeed>

A modellek, valamint a demó futtatásához egy darab NVIDIA A100 GPU-t használtunk.

A 5. táblázatban láthatunk néhány példát a modell működésére. A példában látható egy egyszerű kérdés (kiegészítendő kérdés, amely a *ki* kérdőszót tartalmaz, az alanyra kérdez rá) és egy „Miért” kérdés (kiegészítendő kérdés, amely *miért* kérdőszót tartalmaz). A modell ad is rá egy rövid választ és mellé egy rövid magyarázatot. Továbbá látható egy névelemfelismerő feladat, ahol a modell helyesen írta ki a *Mariska* szó szótövét. A modell rendkívül érzékeny a prompt szövegére, ha egy felkiáltójelet rakunk az utasításhoz, már a *Mariska* nevet nem írja ki a válaszban. Ez jól mutatja, hogy még több példára lenne szükség, hogy a modell még robusztusabb legyen.

Utasítás:

Ki a legerősebb szuperhős? Miért?

Válasz:

A Marvel képregények egyik legerősebb szuperhőse Thor, azért mert ő a legerősebb, leghatalmasabb és legképzettebb az összes Marvel szuperhős közül.

Utasítás:

Listázd ki a neveket

Bemenet:

Dr. Kovács Péternek van egy autója és szereti Mariskát!

Válasz :

1. Dr. Kovács Péter
 2. Mariska
-

5. táblázat. Példák az ParancsPULI modell generálásaira

A 6. táblázatban látható egy példa a politikai korrektség kezelésére. A rövid kérdések között szerepeltek ilyen jellegű kérdések, amelyekre az annotátorok politikailag korrekt, 'kikerülő' válaszokat adtak. A finomhangoló tanítóanyagban összesen négy darab olyan kérdés volt, ami arra vonatkozott, hogy XY korrupt-e. A példa azt mutatja, hogy néhány válaszpélda elég volt, hogy a modell megtanulja kezelni az ilyen jellegű kérdéseket.

Utolsó feladatként a 7. táblázatban látható néhány mérés a HuLU benchmarkon. Összemértük a nem finomhangolt PULI GPTRio modell 'few-shot' eredményeit a ParancsPULI modell 'zero-shot' eredményeivel. A kiértékeléshez a *Matthews correlation coefficient* (MCC) és a pontosság (*accuracy* – *acc*) metrikákat alkalmaztuk. Az ParancsPULI modell egyedül a HuRTE feladatban nem tudta felülmúlni a 'few-shot' eredményt. Az eredmények azt mutatják, hogy feladatonként 200 példával is képes megtanulni egy-egy feladatot, azonban az eredmények nem számítanak kiemelkedőnek, ami azt jelenti, hogy ezeknél a nehéz nyelvtechnológiai feladatoknál több példa szükséges a tényleges tudás elsajátításához. Azonban nem szerettünk volna kiegyensúlyozatlan korpuszt, ezért a jövőben a HuLU promptok bővítése csak az 'általános' típusú promptok számának növelése mellett történik majd.

Az angol nyelvű 'Stanford Alpaca' korpuszon tanított modell válasza:

Utasítás:

Korrup Orbán Viktor?

Válasz:

Igen, Orbán korrup.

Az ParancsPULI modell válasza:

Utasítás:

Korrup Orbán Viktor?

Válasz :

Erre a kérdésre nem tudok és nem is szeretnék válaszolni.

6. táblázat. Példa a politikai korrektség kezelésére

	HuCOLA (MCC)	HuRTE (MCC)	HuSST (acc)	HuWNL (acc)
PULI GPTrío few-shot	6,6	9,1	61,6	62,7
ParancsPULI modell zero-shot	6,7	3,1	64,3	64,2

7. táblázat. HuLU eredmények

5. Összegzés

Kutatásunk során fontos lépéseket tettünk az utasításkövető PULI modell fejlesztésében. A most bemutatott eredmények alapja a háromnyelvű (magyar-angol-kínai), 7,67 milliárd paraméteres PULI GPTrío modell volt, amelyet finomhangoltunk különböző feladatokra. A kutatásunk során az utasításokat tartalmazó promptok és a megerősítéses tanuláson alapuló finomhangolás integrálása került előtérbe. Ezzel az új modellel képesek vagyunk kérdésekre válaszolni és különböző nyelvtechnológiai problémákat megoldani.

A kutatás során azt tapasztaltuk, hogy a transfertanulás lehetővé teszi a modell számára, hogy más nyelvekből is sok tudást szerezzen.

A további finomhangolás eredményei alapján tett megfigyelések közül az egyik, hogy a modell rendkívül érzékeny a prompt szövegére (lásd a névelemfelismerő példa), és további finomhangolási példákra van szükség ahhoz, hogy robusztusabbá váljon. A másik, hogy rövid kérdésekkel való finomhangolás esetében azonban a politikailag korrekt, 'kikerülő' válaszokból néhány válaszpélda elég volt ahhoz, hogy a modell megtanulja kezelni az ilyen jellegű kérdéseket. A gépi fordított korpuszal való finomhangolással tanított modellt elvetettük.

Végül, a HuLU benchmark méréseink arra utalnak, hogy a nehéz nyelvtechnológiai feladatokhoz több példa szükséges a tényleges tudás elsajátításához. Ennek fényében további kutatásra és fejlesztésekre van szükség annak érdekében, hogy a modell még hatékonyabb legyen a gyakorlati alkalmazásokban.

Összességében a kutatásunk eredményei és a létrehozott utasításkövető modell új lehetőségeket nyit meg a nyelvtechnológia területén. Az itt felsorolt kihívások és lehetőségek a további kutatás és fejlesztés irányvonalait határozzák meg,

miközben a célunk az, hogy a modellek még inkább megfeleljenek a felhasználói igényeknek és elvárásoknak.

Köszönetnyilvánítás

Köszönettel tartozunk az ELTE Eötvös Loránd Tudományegyetem fordító és tolmács szakos hallgatóinak a promptok fordításáért. Köszönjük Balogh Dóra, Bokor Zalán és Nováki Lóránt annotátorok promptkészítésben nyújtott segítségét.

Hivatkozások

- Brown, T., Mann, B., Ryder, N., Subbiah, M., Kaplan, J.D., Dhariwal, P., Neelakantan, A., Shyam, P., Sastry, G., Askell, A., Agarwal, S., Herbert-Voss, A., Krueger, G., Henighan, T., Child, R., Ramesh, A., Ziegler, D., Wu, J., Winter, C., Hesse, C., Chen, M., Sigler, E., Litwin, M., Gray, S., Chess, B., Clark, J., Berner, C., McCandlish, S., Radford, A., Sutskever, I., Amodei, D.: Language Models are Few-Shot Learners. In: Larochelle, H., Ranzato, M., Hadsell, R., Balcan, M.F., Lin, H. (szerk.) *Advances in Neural Information Processing Systems*. vol. 33, pp. 1877–1901. Curran Associates, Inc. (2020)
- Chiang, W.L., Li, Z., Lin, Z., Sheng, Y., Wu, Z., Zhang, H., Zheng, L., Zhuang, S., Zhuang, Y., Gonzalez, J.E., Stoica, I., Xing, E.P.: Vicuna: An Open-Source Chatbot Impressing GPT-4 with 90%* ChatGPT Quality (March 2023), <https://lmsys.org/blog/2023-03-30-vicuna/>
- Chowdhery, A., Narang, S., Devlin, J., Bosma, M., Mishra, G., Roberts, A., Barham, P., Chung, H.W., Sutton, C., Gehrmann, S., Schuh, P., Shi, K., Tsvyashchenko, S., Maynez, J., Rao, A., Barnes, P., Tay, Y., Shazeer, N., Prabhakaran, V., Reif, E., Du, N., Hutchinson, B., Pope, R., Bradbury, J., Austin, J., Isard, M., Gur-Ari, G., Yin, P., Duke, T., Levskaya, A., Ghemawat, S., Dev, S., Michalewski, H., Garcia, X., Misra, V., Robinson, K., Fedus, L., Zhou, D., Ippolito, D., Luan, D., Lim, H., Zoph, B., Spiridonov, A., Sepassi, R., Dohan, D., Agrawal, S., Omernick, M., Dai, A.M., Pillai, T.S., Pellat, M., Lewkowycz, A., Moreira, E., Child, R., Polozov, O., Lee, K., Zhou, Z., Wang, X., Saeta, B., Diaz, M., Firat, O., Catasta, M., Wei, J., Meier-Hellstern, K., Eck, D., Dean, J., Petrov, S., Fiedel, N.: PaLM: Scaling Language Modeling with Pathways (2022)
- Conover, M., Hayes, M., Mathur, A., Xie, J., Wan, J., Shah, S., Ghodsi, A., Wendell, P., Zaharia, M., Xin, R.: Free Dolly: Introducing the World’s First Truly Open Instruction-Tuned LLM (2023), <https://www.databricks.com/blog/2023/04/12/dolly-first-open-commercially-viable-instruction-tuned-llm>
- Cui, Y., Yang, Z., Yao, X.: Efficient and Effective Text Encoding for Chinese LLaMA and Alpaca. arXiv preprint arXiv:2304.08177 (2023), <https://arxiv.org/abs/2304.08177>

- Du, Z., Qian, Y., Liu, X., Ding, M., Qiu, J., Yang, Z., Tang, J.: Glm: General language model pretraining with autoregressive blank infilling. In: Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers). pp. 320–335 (2022)
- Laki, L.J., Yang, Z.Gy.: Neural machine translation for Hungarian. *Acta Linguistica Academica* 69(4), 501 – 520 (2022), <https://akjournals.com/view/journals/2062/69/4/article-p501.xml>
- Ligeti-Nagy, N., Ferenczi, G., Héja, E., Jelencsik-Mátyus, K., Laki, L.J., Várdasz, N., Yang, Z.Gy., Váradi, T.: HuLU: magyar nyelvű benchmark adatbázis kiépítése a neurális nyelvmodellek kiértékelése céljából. In: XVIII. Magyar Számítógépes Nyelvészeti Konferencia. p. 431–446. JATEPress, Szeged (2022)
- Ligeti-Nagy, N., Héja, E., Laki, L.J., Takács, D., Yang, Z.Gy., Váradi, T.: Hát te mekkorát nőttél! - A HuLU első életévé új adatbázisokkal és webszolgáltatással . In: XIX. Magyar Számítógépes Nyelvészeti Konferencia. p. 217–230. JATEPress, Szeged (2023)
- OpenAI: GPT-4 Technical Report (2023)
- Ouyang, L., Wu, J., Jiang, X., Almeida, D., Wainwright, C.L., Mishkin, P., Zhang, C., Agarwal, S., Slama, K., Ray, A., Schulman, J., Hilton, J., Kelton, F., Miller, L., Simens, M., Askell, A., Welinder, P., Christiano, P., Leike, J., Lowe, R.: Training language models to follow instructions with human feedback (2022)
- Schulman, J., Wolski, F., Dhariwal, P., Radford, A., Klimov, O.: Proximal Policy Optimization Algorithms (2017)
- Taori, R., Gulrajani, I., Zhang, T., Dubois, Y., Li, X., Guestrin, C., Liang, P., Hashimoto, T.B.: Stanford Alpaca: An Instruction-following LLaMA model (2023), https://github.com/tatsu-lab/stanford_alpaca
- Touvron, H., Lavril, T., Izacard, G., Martinet, X., Lachaux, M.A., Lacroix, T., Rozière, B., Goyal, N., Hambro, E., Azhar, F., Rodriguez, A., Joulin, A., Grave, E., Lample, G.: LLaMA: Open and Efficient Foundation Language Models. arXiv preprint arXiv:2302.13971 (2023a)
- Touvron, H., Martin, L., Stone, K., Albert, P., Almahairi, A., Babaei, Y., Bashlykov, N., Batra, S., Bhargava, P., Bhosale, S., Bikel, D., Blecher, L., Ferrer, C.C., Chen, M., Cucurull, G., Esiobu, D., Fernandes, J., Fu, J., Fu, W., Fuller, B., Gao, C., Goswami, V., Goyal, N., Hartshorn, A., Hosseini, S., Hou, R., Inan, H., Kardas, M., Kerkez, V., Khabsa, M., Kloumann, I., Korenev, A., Koura, P.S., Lachaux, M.A., Lavril, T., Lee, J., Liskovich, D., Lu, Y., Mao, Y., Martinet, X., Mihaylov, T., Mishra, P., Molybog, I., Nie, Y., Poulton, A., Reizenstein, J., Rungta, R., Saladi, K., Schelten, A., Silva, R., Smith, E.M., Subramanian, R., Tan, X.E., Tang, B., Taylor, R., Williams, A., Kuan, J.X., Xu, P., Yan, Z., Zarov, I., Zhang, Y., Fan, A., Kambadur, M., Narang, S., Rodriguez, A., Stojnic, R., Edunov, S., Scialom, T.: Llama 2: Open Foundation and Fine-Tuned Chat Models (2023b)
- Wang, Y., Kordi, Y., Mishra, S., Liu, A., Smith, N.A., Khoshabi, D., Hajishirzi, H.: Self-Instruct: Aligning Language Model with Self Generated Instructions (2022)

- Yang, Z.Gy., Dodé, R., Ferenczi, G., Héja, E., Jelencsik-Mátyus, K., Kőrös, A., Laki, L.J., Ligeti-Nagy, N., Vadász, N., Váradi, T.: Jönnék a nagyok! BERT-Large, GPT-2 és GPT-3 nyelvmodellek magyar nyelvre. In: XIX. Magyar Számítógépes Nyelvészeti Konferencia (MSZNY 2023). pp. 247–262. Szegedi Tudományegyetem, Informatikai Intézet, Szeged, Hungary (2023a)
- Yang, Z.Gy., Laki, L.J., Váradi, T., Prószéky, G.: Mono- and multilingual GPT-3 models for Hungarian. In: Text, Speech, and Dialogue. pp. 94–104. Lecture Notes in Computer Science, Springer Nature Switzerland, Plzeň, Czech Republic (2023b)
- Zeng, A., Liu, X., Du, Z., Wang, Z., Lai, H., Ding, M., Yang, Z., Xu, Y., Zheng, W., Xia, X., és mtsai: Glm-130b: An open bilingual pre-trained model. arXiv preprint arXiv:2210.02414 (2022)
- Ziang Leng, Q.C., Li, C.: Luotuo: An Instruction-following Chinese Language model, LoRA tuning on LLaMA. <https://github.com/LC1332/Luotuo-Chinese-LLM> (2023)