

大模型的多语言处理能力分析与提升

宗成庆

中国科学院自动化研究所

1. 引 言

1. 引言



2022年11月29日, OpenAI 公司发布 ChatGPT, 允许用户以自然语言的形式提问任何问题, 系统都可以给出较好的回答。

- 2023年3月14日, GPT-4.0
- 2024年2月15日, Sora
- 2024年5月1日, GPT-4o (Omni)
- 2024年9月12日, o1-preview, o1-mini
- 2024年12月20日, o3, o3-mini; 2025年1月31日 o3-mini 正式上线
- 2025年3月25日, OpenAI 宣布GPT-4o 增加图像生成功能
- 文心一言(百度), 豆包(字节), 通义千问(阿里), Kimi (月之暗面), 九天, 星火(讯飞), 腾讯混元, 百川, 华为盘古, 日日新(商汤), 紫冬太初, 智谱华章, DeepSeek

✧ **统一框架**

✧ **不同语言、不同模态信息、不同任务几乎无差别处理**

1. 引言

- 多语言处理相关问题

- 大模型对不同语言的处理能力是否一样?
- 在低资源语言上是否存在安全隐患?
- 对不同的语言模型参数是否都发挥同样的作用?

2. LLMs的多语言处理能力分析



2. LLMs的多语言处理能力分析

◆关于机器翻译

● 客观评测
(2023.5):

- (1)高资源语言： 中文， 德语
- (2)中等资源语言： 爱沙尼亚语， 立陶宛语
- (3)低资源语言： 僧伽罗语， 尼泊尔语

Flores-200
测试集

测试结果

语言对	COMET			BLEU		
	ChatGPT	Google	比值	ChatGPT	Google	比值
汉语→英语	88.7	89.4	99.3	29.6	38.6	76.7
德语→英语	90.7	91.0	99.7	43.0	47.3	90.9
爱沙尼亚语→英语	90.1	91.7	98.3	36.9	45.5	81.1
立陶宛语→英语	86.1	89.2	96.6	32.6	41.3	78.9
尼泊尔语→英语	87.4	93.2	93.8	24.5	51.3	47.7
僧伽罗语→英语	61.3	90.5	67.7	3.5	45.5	7.7



2. LLMs的多语言处理能力分析

●2024.10

➤数据集

- WMT23: 德语(de), 中文(zh), 俄语(ru), 日语(ja), 乌克兰语(uk), 希伯来语(he)
- WMT22: 冰岛语(is)

➤翻译方向: $EN \rightarrow X$, $X \rightarrow EN$

	高资源	中等资源	低资源
与英语同语言族	de, ru	uk	is
与英语不同语言族	zh	ja	he



2. LLMs的多语言处理能力分析









➤ 实验设置

✧ 模型/ 系统

- API: Google Translation, GPT-4o
- 开源指令模型: NLLB-3.3B, Aya-23-8B, Llama-3.1-8B,
Qwen-2.5-7B, Gemma-2-9B
- 基于LLM的翻译模型: X-ALMA









2. LLMs的多语言处理能力分析

B
L
E
U




2. LLMs的多语言处理能力分析

B
L
E
U



2. LLMs的多语言处理能力分析

● 平均得分



2. LLMs的多语言处理能力分析


● 分析

- GPT-4o的翻译能力已与Google Translator相当；
- 开源大模型，如Llama-3.1、Qwen-2.5等在翻译性能上已经接近Encoder-Decoder结构的SOTA多语言翻译模型(NLLB)，但仍与闭源模型有一定差距；
- 大模型在英语、中文、德语等资源丰富的语言对上表现优异；**在处理低资源语言时，通过迁移学习和知识共享，大模型可以在有限数据下实现相对合理的翻译效果，但仍逊于专门训练出来的基于Transformer架构的机器翻译模型；**
- 大模型在相同语系的语言之间，如印欧语系的英语与德语、俄语之间表现较好，但在不同语系间，如英语与汉藏语系的中文之间表现略逊；
- 大模型在处理非英语为目标语言的翻译任务时 ($EN \rightarrow X$)，通常表现稍弱，这可能与训练时英语作为中心语言的偏向有关。

2. LLMs的多语言处理能力分析

◆关于低资源语言的安全检查规避问题

相比资源丰富的语言，大语言模型使用低资源语言回复可能包含不安全的内容。例如，将带有恶意的问題翻译到低资源语言祖鲁语(isiZulu)上，就能绕过GPT-4的安全防护，让GPT-4输出带有恶意的回复。




(2024年9月 CAAI大会，南京。见 *Proc. of ACL 2024*)

2. LLMs的多语言处理能力分析

◆关于多语言诅咒问题



Conneau, Alexis, et al. Unsupervised Cross-lingual Representation Learning at Scale. *Proc. ACL* 2020.



3. 改进方法

3. 改进方法


● 模型与语言的独立性



Q. Wang et al., Parameter differentiation based multilingual neural machine translation. *Proc. of AAAI 2022*.


3. 改进方法

● 动态混合专家模型(Dynamic Mixture-of-Experts, DMoE)




(a) Dynamic Language Clustering

(a) 动态语言聚类



(b) Dynamic MoE Layer Extension

(b) 动态专家层扩展



(c) Dynamic Language Adaptation

(c) 动态语言适配

3. 改进方法


(a) 动态语言聚类

- Fine-tune model to obtain parameter deviation

$$\Delta\theta^x = \|\theta^0 - \theta^x\|$$

- Determine the layers to extend
- Cluster similar languages by $\Delta\theta^x$

选定最后3层的参数变化量合并成一个向量，然后这个合并向量对语言聚类。



(a) Dynamic Language Clustering


3. 改进方法

(b) 动态专家层扩展

- Extend top- ϵ layers into MoE layers
- Fine-tune with language group classification loss

$$\mathcal{L}_{RC}(\theta) = - \sum_x \sum_{i=1}^M [\log (P_i(l|x; \theta))]$$

对于不同类别的语言，将微调前后参数变化量大的网络层挑出来，转换成混合专家(MoE)结构。




(b) Dynamic MoE Layer Extension

3. 改进方法

(c) 动态语言适配

- Copy the most similar expert
- Fine-tune the added parameters

一种新的语言加入之后，对其进行类别适配。



(c) Dynamic Language Adaptation

3. 改进方法

● 实验分析

- 基座模型: Bloom, Gemma
- 基线系统:
 - + Pre-train: continue to pre-train on the same corpus
 - X-ELM: 2 languages per group
 - Branch-Train-Mix
- 语言: (1)初始在18 种语言上进行实验; (2)将实验上扩展到128 种。

Workshop, BigScience, et al., Bloom: A 176b-parameter open-access multilingual language model. arXiv preprint arXiv:2211.05100 (2022).

Team, Gemma, et al., Gemma: Open models based on gemini research and technology. arXiv preprint arXiv:2403.08295 (2024).

3. 改进方法

➤ 18种语言的相似度对比

ar	1.00	0.08	0.02	0.08	0.12	0.09	0.02	0.01	0.02	0.01	0.02	0.08	0.05	0.01	0.02	0.11	0.09	0.07
bn	0.08	1.00	0.01	0.05	0.14	0.07	0.01	0.01	0.02	0.01	0.02	0.10	0.08	0.01	0.02	0.09	0.06	0.05
de	0.02	0.01	1.00	0.09	0.03	0.05	0.05	0.02	0.01	0.10	0.02	0.01	0.01	0.01	0.02	0.01	0.04	0.03
fr	0.08	0.05	0.09	1.00	0.08	0.14	0.08	0.03	0.02	0.06	0.04	0.04	0.02	0.01	0.02	0.03	0.15	0.09
hi	0.12	0.14	0.03	0.08	1.00	0.14	0.02	0.02	0.02	0.02	0.02	0.16	0.12	0.02	0.02	0.13	0.09	0.07
id	0.09	0.07	0.05	0.14	0.14	1.00	0.05	0.02	0.02	0.04	0.03	0.07	0.05	0.01	0.02	0.07	0.15	0.07
it	0.02	0.01	0.05	0.08	0.02	0.05	1.00	0.01	0.01	0.05	0.02	0.02	0.01	0.01	0.02	0.01	0.04	0.02
ja	0.01	0.01	0.02	0.03	0.02	0.02	0.01	1.00	0.03	0.01	0.01	0.01	0.00	0.02	0.01	0.01	0.03	0.07
ko	0.02	0.02	0.01	0.02	0.02	0.02	0.01	0.03	1.00	0.01	0.02	0.02	0.02	0.03	0.02	0.02	0.03	0.04
nl	0.01	0.01	0.10	0.06	0.02	0.04	0.05	0.01	0.01	1.00	0.02	0.01	0.01	0.01	0.01	0.01	0.03	0.03
ru	0.02	0.02	0.02	0.04	0.02	0.03	0.02	0.01	0.02	0.02	1.00	0.02	0.01	0.02	0.30	0.01	0.03	0.02
ta	0.08	0.10	0.01	0.04	0.16	0.07	0.02	0.01	0.02	0.01	0.02	1.00	0.19	0.01	0.02	0.08	0.05	0.05
te	0.05	0.08	0.01	0.02	0.12	0.05	0.01	0.00	0.02	0.01	0.01	0.19	1.00	0.01	0.01	0.06	0.04	0.03
th	0.01	0.01	0.01	0.01	0.02	0.01	0.01	0.02	0.03	0.01	0.02	0.01	0.01	1.00	0.01	0.01	0.01	0.02
uk	0.02	0.02	0.02	0.02	0.02	0.02	0.02	0.01	0.02	0.01	0.30	0.02	0.01	0.01	1.00	0.01	0.02	0.01
ur	0.11	0.09	0.01	0.03	0.13	0.07	0.01	0.01	0.02	0.01	0.01	0.08	0.06	0.01	0.01	1.00	0.05	0.04
vi	0.09	0.06	0.04	0.15	0.09	0.15	0.04	0.03	0.03	0.03	0.03	0.05	0.04	0.01	0.02	0.05	1.00	0.12
zh	0.07	0.05	0.03	0.09	0.07	0.07	0.02	0.07	0.04	0.03	0.02	0.05	0.03	0.02	0.01	0.04	0.12	1.00
	ar	bn	de	fr	hi	id	it	ja	ko	nl	ru	ta	te	th	uk	ur	vi	zh

Bloom_{560M}

ar	1.00	0.09	0.03	0.12	0.10	0.10	0.03	0.03	0.03	0.02	0.04	0.06	0.05	0.01	0.02	0.09	0.12	0.10
bn	0.09	1.00	0.02	0.06	0.13	0.06	0.02	0.02	0.02	0.01	0.02	0.10	0.07	0.01	0.02	0.08	0.06	0.06
de	0.03	0.02	1.00	0.08	0.04	0.06	0.07	0.02	0.01	0.10	0.03	0.01	0.01	0.01	0.02	0.02	0.04	0.03
fr	0.12	0.06	0.08	1.00	0.10	0.14	0.08	0.04	0.03	0.06	0.04	0.05	0.04	0.02	0.02	0.05	0.16	0.09
hi	0.10	0.13	0.04	0.10	1.00	0.11	0.04	0.03	0.03	0.03	0.03	0.13	0.11	0.02	0.02	0.11	0.10	0.09
id	0.10	0.06	0.06	0.14	0.11	1.00	0.06	0.03	0.02	0.04	0.05	0.04	0.03	0.01	0.03	0.06	0.14	0.07
it	0.03	0.02	0.07	0.08	0.04	0.06	1.00	0.02	0.01	0.06	0.02	0.01	0.01	0.01	0.01	0.02	0.05	0.04
ja	0.03	0.02	0.02	0.04	0.03	0.03	0.02	1.00	0.04	0.01	0.02	0.02	0.02	0.02	0.01	0.03	0.05	0.06
ko	0.03	0.02	0.01	0.03	0.03	0.02	0.01	0.04	1.00	0.01	0.02	0.02	0.02	0.03	0.02	0.03	0.03	0.03
nl	0.02	0.01	0.10	0.06	0.03	0.04	0.06	0.01	0.01	1.00	0.02	0.01	0.01	0.01	0.01	0.01	0.03	0.03
ru	0.04	0.02	0.03	0.04	0.03	0.05	0.02	0.02	0.02	0.02	1.00	0.02	0.02	0.02	0.21	0.02	0.05	0.03
ta	0.06	0.10	0.01	0.05	0.13	0.04	0.01	0.02	0.02	0.01	0.02	1.00	0.14	0.01	0.01	0.07	0.06	0.05
te	0.05	0.07	0.01	0.04	0.11	0.03	0.01	0.02	0.02	0.01	0.02	0.14	1.00	0.01	0.01	0.06	0.04	0.03
th	0.01	0.01	0.01	0.02	0.02	0.01	0.01	0.02	0.03	0.01	0.02	0.01	0.01	1.00	0.01	0.01	0.02	0.02
uk	0.02	0.02	0.02	0.02	0.02	0.03	0.01	0.01	0.02	0.01	0.21	0.01	0.01	0.01	1.00	0.02	0.03	0.02
ur	0.09	0.08	0.02	0.05	0.11	0.06	0.02	0.03	0.03	0.01	0.02	0.07	0.06	0.01	0.02	1.00	0.07	0.06
vi	0.12	0.06	0.04	0.16	0.10	0.14	0.05	0.05	0.03	0.03	0.05	0.06	0.04	0.02	0.03	0.07	1.00	0.11
zh	0.10	0.06	0.03	0.09	0.09	0.07	0.04	0.06	0.03	0.03	0.03	0.05	0.03	0.02	0.02	0.06	0.11	1.00
	ar	bn	de	fr	hi	id	it	ja	ko	nl	ru	ta	te	th	uk	ur	vi	zh

Bloom_{1.7B}

3. 改进方法

- 将18种语言划分成不同的组

	ar	ur	bn	it	de	nl	ta	te	hi	id	fr	vi	ru	uk	th	ko	ja	zh
9G	1	1	2	2	3	3	4	4	5	5	6	6	7	7	8	8	9	9
6G	1	1	1	2	2	2	3	3	3	4	4	4	5	5	5	6	6	6
6G^(L)	1	1	2	3	4	3	5	5	5	6	1	6	4	4	6	2	2	3
6G^(R)	1	2	5	4	6	6	2	3	3	4	6	1	3	5	4	2	5	1
3G	1	1	1	2	2	2	1	3	1	1	2	2	3	3	3	3	3	2
2G	1	1	1	2	2	2	1	2	1	1	1	1	2	2	2	2	2	1

P. Littell et al., URIEL and lang2vec: Representing languages as typological, geographical, and phylogenetic vectors. Proc. EACL 2017.



3. 改进方法

➤ 实验结果(Perplexity)

Model	#Param.	High								Medium								Low			
		ar	de [†]	fr	it [†]	ja [†]	nl [†]	ru [†]	zh	bn	hi	id	ko [†]	th [†]	uk [†]	vi [†]	ta	te	ur	Avg [↓]	
BLOOM _{560M} (基模型)	560M	56.7	126.4	37.4	85.3	55.7	129.5	31.3	59.0	42.3	32.7	47.4	25.7	14.0	39.7	27.9	64.2	88.4	60.0	56.9	
+ Pre-train	560M	39.0	27.6	22.0	17.8	15.0	16.6	8.2	36.0	26.5	20.9	32.6	8.4	4.4	6.8	18.5	31.0	26.9	29.8	21.6	
X-ELM	5.03B	35.2	34.6	21.3	17.3	18.0	21.5	9.8	37.9	25.1	19.5	28.8	9.3	4.4	8.5	18.9	26.9	23.0	27.5	21.5	
Branch-Train-Mix	1.57B	39.4	25.8	21.6	17.1	14.7	15.3	8.0	35.8	26.4	21.0	32.1	8.1	4.1	6.6	18.1	31.4	27.0	30.0	21.2	
DMoE (2 Groups)	635M	37.9	25.0	21.5	17.1	15.0	14.5	7.4	34.4	25.4	20.5	31.3	7.9	3.8	5.9	18.4	30.3	26.7	28.6	20.6	
DMoE (3 Groups)	710M	37.0	25.3	21.8	17.2	14.4	14.4	7.1	35.0	24.6	19.9	30.4	7.7	3.7	5.6	18.4	29.3	26.3	27.4	20.3	
DMoE (6 Groups)	937M	<u>36.2</u>	<u>23.5</u>	20.9	16.0	<u>13.8</u>	<u>13.6</u>	7.3	34.1	<u>23.9</u>	19.1	30.7	<u>7.4</u>	3.9	5.9	17.6	27.9	23.4	26.8	19.5	
w/ Gemma Clusters	937M	36.7	<u>23.5</u>	21.4	16.1	<u>13.8</u>	<u>13.6</u>	7.3	34.1	23.7	19.7	31.8	<u>7.4</u>	<u>3.6</u>	5.6	<u>17.7</u>	27.8	<u>23.3</u>	27.1	<u>19.7</u>	
w/ LANG2VEC Clusters	937M	37.6	25.2	20.9	<u>15.8</u>	13.4	13.3	7.6	<u>34.2</u>	25.0	<u>19.3</u>	30.3	7.2	3.5	6.2	<u>17.7</u>	28.0	23.6	28.1	19.8	
w/ Random Clusters	937M	38.5	25.7	21.5	17.0	14.6	15.2	7.9	35.3	25.7	20.6	31.8	8.1	4.1	6.5	18.1	30.6	26.1	29.4	20.9	
w/o Class. Loss	937M	36.5	24.2	21.2	16.4	14.4	13.9	<u>7.2</u>	34.8	24.6	19.7	30.9	7.7	3.8	<u>5.8</u>	18.2	28.4	24.1	27.6	20.0	
DMoE (9 Groups)	1.16B	36.9	23.1	<u>21.1</u>	14.7	14.0	13.3	7.5	34.6	25.1	19.6	<u>29.7</u>	7.2	<u>3.6</u>	6.1	17.9	<u>27.6</u>	23.0	<u>27.0</u>	19.5	

- 与基线系统相比，我们的方法在更少参数量的情况下获得了更优的性能
- 当参数量增加、语言分组更多时，性能更好




3. 改进方法

➤ 对不同的参数量和不同的模型结构，这种方法都有效

Model	#Param.	High								Medium							Low			Avg ↓
		ar	de [†]	fr	it [†]	ja [†]	nl [†]	ru [†]	zh	bn	hi	id	ko [†]	th [†]	uk [†]	vi [†]	ta	te	ur	
BLOOM _{1.7B}	1.72B	41.2	63.0	24.3	44.0	35.2	63.0	20.1	40.1	27.0	22.6	32.7	17.4	9.8	23.9	19.2	40.1	43.6	36.3	33.5
+ Pre-train	1.72B	<u>25.1</u>	21.0	<u>15.3</u>	15.5	11.7	17.4	7.0	23.4	16.8	15.3	23.0	7.8	4.3	8.5	<u>13.1</u>	21.6	21.1	22.6	16.1
X-ELM	15.50B	24.9	20.2	15.0	<u>12.1</u>	12.1	12.3	7.1	24.3	<u>17.4</u>	14.4	21.0	7.5	3.8	6.0	12.9	19.3	16.6	19.4	14.8
Branch-Train-Mix	5.75B	25.4	18.7	16.0	15.2	11.3	13.6	6.0	23.6	17.6	15.3	24.1	7.4	3.7	7.0	13.4	23.1	21.1	20.5	15.7
DMoE (3 Groups)	2.33B	26.3	17.5	16.0	12.5	11.0	10.5	5.7	25.2	17.5	15.1	22.4	6.3	<u>3.2</u>	4.5	13.8	21.1	19.6	19.9	14.9
DMoE (6 Groups)	3.23B	26.1	<u>17.2</u>	15.8	12.4	10.7	<u>10.2</u>	<u>5.8</u>	24.9	17.4	<u>14.5</u>	22.8	<u>6.1</u>	3.3	<u>4.6</u>	13.3	<u>20.3</u>	17.5	<u>19.6</u>	<u>14.6</u>
DMoE (9 Groups)	4.14B	26.6	16.8	16.0	11.5	<u>10.8</u>	10.0	5.9	25.1	17.8	14.8	<u>22.2</u>	5.9	3.1	4.8	13.5	20.1	<u>17.0</u>	19.8	14.5
Gemma _{2B}	2.51B	54.8	12.5	23.6	13.4	11.1	11.4	5.1	69.1	68.9	44.2	45.5	5.6	2.8	4.0	19.8	70.5	62.8	54.2	32.2
+ Pre-train	2.51B	28.8	<u>10.1</u>	<u>17.1</u>	<u>9.3</u>	<u>7.3</u>	<u>6.5</u>	<u>4.1</u>	<u>29.4</u>	21.7	14.9	<u>21.9</u>	<u>3.8</u>	<u>2.3</u>	3.1	<u>13.6</u>	20.4	17.0	20.4	14.0
X-ELM	22.56B	30.2	11.1	19.3	10.2	8.0	7.3	4.3	34.6	22.7	15.3	23.9	3.9	<u>2.3</u>	3.3	14.4	19.9	16.5	22.8	15.0
Branch-Train-Mix	11.57B	27.7	10.7	18.2	9.7	7.5	6.8	4.2	30.6	18.5	14.4	23.8	3.9	2.3	3.2	13.6	17.4	14.5	19.3	13.7
DMoE (9 Groups)	6.53B	24.8	9.9	16.8	9.1	7.0	6.3	4.0	27.8	17.6	12.9	19.6	3.6	2.2	3.1	12.2	15.3	12.8	17.3	12.4


3. 改进方法

➤ Top- ϵ 对模型参数数量和性能的影响



3. 改进方法


➤ 分析: Top-1 Expert Distribution



(a) DMoE (6 Groups) w/o language group classification loss.

3. 改进方法

➤ 分析: Top-1 Expert Distribution



(b) DMoE (6 Groups) w/ language group classification loss.

3. 改进方法

➤ 增加4种新的语言：be(白俄罗斯语), ml(马拉雅拉姆语), mr(马拉地语), sr(塞尔维亚语)

• 方法：

✓w/ LAPT: 语言适配预训练

✓w/ DLA: 动态语言适配

• 结果: 对新增加的语言更好地适配, 较少的以往原有的语言

Model	New Languages				Old Languages		
	be	ml	mr	sr	High	Medium	Low
Gemma _{2B}	10.0	7.1	11.4	12.5	26.9 $\pm$ 9.4	15.1 $\pm$ 7.9	10.5 $\pm$ 4.3
+ Pre-train	9.3	11.7	11.2	17.1	15.1 $\pm$ 4.4	8.5 $\pm$ 3.7	5.4 $\pm$ 1.7
w/ LAPT	<u>6.4</u>	<u>4.3</u>	<u>6.1</u>	<u>8.3</u>	16.5 $\pm$ 4.6	10.6 $\pm$ 3.8	7.3 $\pm$ 3.1
DMoE	8.9	10.0	11.8	17.2	14.4 $\pm$ 4.2	7.7 $\pm$ 3.4	4.8 $\pm$ 1.6
w/ DLA	6.2	4.0	5.4	8.2	15.0 $\pm$ 4.2	8.5 $\pm$ 3.2	5.4 $\pm$ 1.8

3. 改进方法


➤ 增加到128种语言之后

Model	High					Medium					Low					Extremely-Low					ALL 128L
	ar	de [†]	en	it [†]	ja [†]	hi	id	th [†]	uk [†]	vi [†]	kk [†]	mn [†]	my [†]	te	ur	br [†]	pa [†]	sw	ug [†]	zu	Avg ↓
BLOOM _{560M}	42.4	111.3	66.8	82.4	55.5	30.6	41.3	13.7	44.5	21.8	29.0	31.2	6.1	91.4	72.5	261.7	131.6	224.9	44.5	1278.9	154.4 $\pm$ 157.0
+ Pre-train	34.4	23.8	44.6	20.5	12.9	20.5	26.9	3.6	7.3	15.1	5.7	6.8	<u>2.8</u>	<u>30.3</u>	37.6	40.2	<u>32.5</u>	45.5	9.2	36.2	20.7 $\pm$ 12.8
Branch-Train-Mix	32.5	21.0	40.3	17.1	12.1	20.0	26.1	3.5	6.6	14.6	5.4	6.3	2.8	31.6	37.1	35.4	34.1	43.5	9.0	31.2	19.2 $\pm$ 12.2
DMoE	32.1	19.5	<u>40.8</u>	16.3	11.3	19.8	25.8	3.4	6.4	<u>14.7</u>	5.2	6.2	2.7	29.3	35.2	31.4	30.5	39.7	8.1	28.3	17.7$\pm$11.2
BLOOM _{1.7B}	30.4	56.4	45.3	44.9	35.0	20.8	27.8	9.7	26.7	15.3	19.1	21.1	4.4	46.8	44.0	113.2	61.7	80.3	28.4	260.8	71.9 $\pm$ 52.1
+ Pre-train	22.9	15.9	<u>30.3</u>	14.1	9.7	<u>14.7</u>	19.3	<u>3.1</u>	5.4	<u>11.3</u>	<u>4.5</u>	<u>5.4</u>	2.5	<u>22.3</u>	26.8	27.9	<u>23.9</u>	30.8	<u>7.4</u>	26.0	14.9 $\pm$ 8.7
Branch-Train-Mix	21.1	15.3	29.7	13.1	9.4	14.1	18.6	3.1	5.3	10.9	4.5	5.4	2.6	22.4	25.7	26.2	24.2	29.8	7.5	24.1	14.3 $\pm$ 8.4
DMoE	<u>22.7</u>	14.9	31.3	12.8	8.9	<u>14.7</u>	19.1	3.0	5.1	<u>11.3</u>	4.3	5.1	2.5	22.1	26.0	23.9	23.2	29.2	6.8	22.8	13.7$\pm$8.1

C. Li et al., Group then Scale: Dynamic Mixture-of-Experts Multilingual Language Model, *Proc. ACL 2025*

结束语

Percentage of Examples Where Each Model Ranks First



- 通用大模型确保的是整体最优，适用于通用领域对特定任务和语言没有准确率特别要求的一般性用户；
- 针对特定领域、具体任务和特定语言的用户需求，需要在可控成本和有限资源情况下利用特殊的方法进行最优、可信和安全地改进，在确保任务和语言内最优的前提下照顾其通用性。

- MixInstruct
- 3 Metrics (BERTScore, BLEURT, BARTScore)
- GPT-Rank

D. Jiang et al., LLM-Blender: Ensembling Large Language Models with Pairwise Ranking and Generative Fusion. *ACL2023*, pp. 14165–14178

谢谢!
Thanks!

