

大语言模型与脑认知机制

宗成庆

中国科学院自动化研究所

cqzong@nlpr.ia.ac.cn



1. 引言
2. 数据集构建
3. 神经解码
4. 大模型改进与应用

1. 引言

◆语言模型 — 如何计算一个句子的概率？

- 只考虑前 $n-1$ 个词对当前词的影响(一般 $1 \leq n \leq 5$)， 那么

$$p(s) = \prod_{i=1}^m p(w_i | w_{i-n+1}^{i-1})$$

语言模型(language model, LM) /
 n 元文法模型(n -gram model), 1970s

- 已知前面几个词就可预测出下一个最有可能出现的词：

2024年 阳春 …… ?

context

三月/白雪/面……

$$p(\text{word} | \text{context}) \quad \text{loss} = \max_{\theta} \sum_{i=1}^n P_{\theta}(x_i | x_{1:i-1})$$



离散符号 → 连续的实数空间 → 注意力机制 → Transformer



Frederek Jelinek
 (1932.11.18 ~ 2010.9.14)

1. 引言

◆ 预训练语言模型

- ELMo [Peters et al., 2018] (AllenAI&WU)
- BERT [Devlin et al., 2019] (Google)
- GPT [Radford et al., 2018] (OpenAI)
 - Generative Pre-Trained Transformer


◆ 大语言模型(Large Language Models, LLMs)

- GPT-3.5 (ChatGPT), Nov. 29, 2022
- GPT-4.0, March 14, 2023
- Sora, Feb. 15, 2024
- GPT-4o (Omni), May 13, 2024
- o1-preview, o1-mini, Sept. 12, 2024

✧ 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



- 人脑是如何表征和记忆语言的？
- 能否根据神经影像数据解码出大脑思考的内容？
- 能否借鉴大脑的认知机理改进现有的大语言模型？

➤ 100 – 47%

➤ 2500 – 97%+

➤ 4000 – 99%+

提 纲

1. 引言

 2. 数据集构建

3. 神经解码

4. 大模型改进与应用

2. 数据集构建

◆目的：构造大脑的语义图谱

- 大脑理解语言时是多脑区同时被激活的，如何通过影像数据解析网络结构与语义编码之间的关系，构建自然语言的语义图谱？
- 如何构建汉语的语义图谱？
- 在语义图谱的基础上，如何发现语义组合、概念形成及演变的规律？

2. 数据集构建

(1) 汉语词汇级的神经影像数据



11位被试的母语均为汉语，每个词看3s，间隔2s(十字空屏)。每个人每次看2小时，672个词全部看完。

● 实验刺激

选取《同义词词林》中每个类别的代表性词汇，包括名词、动词、形容词，共计672个，10类，每个词汇呈现6遍。



下雨



下雨



下雨



下雨



下雨




下雨


2. 数据集构建

- 观察

- 血流动力学响应



- 词汇概念响应



下雨

上课

奔放

太阳

思考

- 大脑每个体素编码了什么语义信息?
- 不同(类型)词汇的大脑表征有何异同?
- 词汇关系是如何在大脑中编码的?
- 大脑语义编码与语言学中概念表征的异同在哪里?



2. 数据集构建

(2) 脑磁图仪




+ 磁共振
成像仪



● 实验刺激

- 60个中文故事，长度在600~900个词之间，总计40145个中文单词，词汇量为10152，每个词出现的频次范围为1-210；
- 音频摘自《人民日报评论》；
- 已采集12个被试的9个小时fMRI和6个小时MEG数据。




“从奶茶味到水煮鱼味，从折耳根味到钵钵鸡味，刷新味蕾的不仅只有月饼、酸奶，薯片也爆款频出，甚至一袋难求…”

2. 数据集构建


- 故事理解
响应

大脑皮层展
开后示意图



2. 数据集构建

● 分析



从/p 奶茶味/n 到/p 水煮/n 鱼/n 味/n 、 /wp 从/p 折耳根/n 味/n 到 /p 钵钵鸡/n 味/n 。 /wp



- 不同语言特征（词义、词法、句法、篇章关系等）是如何在大脑中编码的？
- 不同语言特征的时间响应关系是什么？
- 大脑故事表征过程与通用语言模型之间有什么联系？

2. 数据集构建

◆ 相关论文

- ① S. Wang et al., An fMRI Dataset for Concept Representation with Semantic Feature Annotations. *Scientific Data*, <https://doi.org/10.1038/s41597-022-01840-2>
- ② S. Wang et al., A large dataset of semantic ratings and its computational extension. *Scientific Data*, <https://doi.org/10.1038/s41597-023-01995-6>
- ③ S. Wang et al., A synchronized multimodal neuroimaging dataset for studying brain language processing. *Scientific Data*, (2022) 9: 590
- ④ Y. Zhang et al. A Comprehensive Neural and Behavioral Task Taxonomy Method for Transfer Learning in NLP. In *Findings of IJCNLP-AACL 2023*, pp. 233–241
- ⑤ Y. Zhang et al. Navigating Brain Language Representations: A Comparative Analysis of Neural Language Models and Psychologically Plausible Models. In *Proc. of the Annual Meeting of the Cognitive Science Society*. Vol. 46. 2023


提 纲

1. 引言
2. 数据集构建
-  3. 神经解码
4. 大模型改进与应用


3. 神经解码




Stimuli



words



fMRI image




Voxel selection




fMRI -
functional Magnetic
Resonance Imaging
(功能性磁共振成像)


dog
?



Word
embedding



Decoder




fMRI vector

3. 神经解码

◆ 句子的神经解码

- 基本思路：借助预训练语言模型

fMRI2text Task




3. 神经解码

● 实现方法：两步走

➤ Step-1: 映射步

- 采用基于Transformer的映射器将fMRI影像数据映射到文本表征
- 针对 fMRI 数据的噪声和空间冗余，利用随机掩码进行对比学习



$$\hat{T} = D(\mathcal{E}(F))$$

$$H = P(\mathcal{E}(F))$$

$$H^m = P(\mathcal{E}(F^m))$$

$$\mathcal{L}_{MSE} = \frac{1}{N} \sum_{i=1}^N \sum_{j=1}^D (e_{ij} - \hat{e}_{ij})^2$$


$$\mathcal{L}_{infoNCE} = - \sum_{i=1}^N \log \frac{\exp(h_i \cdot h_i^m / \eta)}{\sum_{j=1}^N \exp(h_i \cdot h_j^m / \eta)}$$

$$\mathcal{L} = \alpha \mathcal{L}_{MSE} + \beta \mathcal{L}_{infoNCE}$$

3. 神经解码

➤ Step-2: 引导步


- 在第一阶段学习的映射器的指导下，使用预训练的文本生成器**引导**生成文本



3. 神经解码

● 数据集

fMRI2text Task: (**{a series of fMRI }, coherent text generated word by word**)




LeBel, A. et al. (2022). A natural language fMRI dataset for voxelwise encoding models. Scientific Data, 10(1), 555.

3. 神经解码

● 实验设置

- 评测指标：WER、BLEU-1、METEOR、BERTScore
- 序列窗口：采用固定长度(20 秒)，该窗口沿基本真实序列 W 和预测序列 $\hat{W}$ 滑动，覆盖从开始到结束的时间段。



3. 神经解码

➤ 基线设置

- 选择线性编码模型的方法作为文本解码的基准。

➤ 训练设置

- 第一阶段训练集和验证集划分比例为 80%、20%。针对不同的研究被试分别训练不同的模型。
- 实验过程均使用 NVIDIA GeForce GTX 1080 Ti GPU进行。

3. 神经解码

● 测试结果：解码准确率

被试	方法	正值率(%)				标准得分			
		WER	BLEU	METEOR	BERT	WER	BLEU	METEOR	BERT
S1	基线	89.7	80.1	79.6	81.2	9.57	4.77	5.67	9.53
	本方法	96.5	94.7	92.2	93.3	14.02	11.14	11.56	13.81
S2	基线	80.9	87.2	83.8	82.4	7.70	6.87	6.67	7.79
	本方法	91.5	95.9	92.4	90.2	11.84	10.31	10.11	12.36
S3	基线	94.1	83.1	85.8	87.0	13.01	7.61	10.46	15.21
	本方法	90.9	90.8	89.2	95.4	13.02	11.27	11.09	16.57


- 我们的模型在所有参与评估的三名受试者中均显著超越了基线模型。
- BLEU 分数平均提升达到了77%，METEOR 分数平均提升达到了54%。

3. 神经解码

● 测试结果

- Our method employs a simpler decoding approach, delivering better performance on the same dataset.
- The upper-bound results highlight the considerable potential of neural decoding-based frameworks.

[a] Subject	Method	WER _{zs}	BLEU _{zs}	METR _{zs}	BERT _{zs}	Avg _{zs}	WER _{pos}	BLEU _{pos}	METR _{pos}	BERT _{pos}	Avg _{pos}
S1	Tang w/ N-E	7.08	4.35	4.11	5.40	5.24	79.57	75.31	69.09	76.91	75.22
	Tang	9.57	4.77	5.67	9.53	7.39	89.70	80.11	79.57	81.17	82.64
	MapGuide	14.02	11.14	11.56	13.81	12.63	96.45	94.67	92.18	93.25	94.14
S2	Tang w/ N-E	4.85	2.82	2.57	4.00	3.56	77.98	66.96	63.77	73.00	70.43
	Tang	7.70	6.87	6.67	7.79	7.26	80.82	87.21	83.84	82.42	83.57
	MapGuide	11.84	10.31	10.11	12.36	11.16	91.47	95.91	92.36	90.23	92.49
S3	Tang w/ N-E	8.28	5.58	5.73	8.16	6.94	86.15	83.66	80.46	77.26	81.88
	Tang	13.01	7.61	10.46	15.21	11.57	94.14	83.13	85.79	87.03	87.52
	MapGuide	13.02	11.27	11.09	16.57	12.99	90.94	90.76	89.17	95.38	91.56



3. 神经解码

● 示例

(蓝色：内容一致；橙色：内容相似)

Ground Truth	MapGuide
<i>i say you know what uh this is a little funny but you're gonna have to show me the way to get home because although i'm twenty three years old i don't have my driver's license yet</i>	<i>i say no and then he goes i can't i don't know i'm too old to drink i didn't have a license for years i couldn't do it and</i>
<i>and i just jumped out right when i needed to and she says well why don't you come back to my house and i'll give you a ride i say ok great and we start walking and uh</i>	<i>but i wanted to so i said no so we go back to her place and i say hey come over and we start talking and then we get</i>
<i>that's not i don't know where i want to be but i know it's not that and then it gets a little deeper and we share some other stuff about what our lives are</i>	<i>i know that i didn't really understand it but i remember a lot of other stories i used to share with my friends that are related</i>

X. Zhao et al., MapGuide: A Simple yet Effective Method to Reconstruct Continuous Language from Brain Activities. In *Proceedings NAACL 2024*.

3. 神经解码

◆ 相关论文

- ① S. Zou et al., Cross-Modal Cloze Task: A New Task to Brain-to-Word Decoding. In *Findings of the Association for Computational Linguistics (ACL 2022)*, pages 648 - 657, May 22-27, 2022
- ② S. Zou et al., Towards Brain-to-Text Generation: Neural Decoding with Pre-trained Encoder-Decoder Models. *Proc. of NeurIPS 2021 AI for Science Workshop*. December 6 - 14, 2021(online)
- ③ X. Zhao et al., MapGuide: A Simple yet Effective Method to Reconstruct Continuous Language from Brain Activities. *Proc. of NAACL 2024*

提 纲

1. 引言
2. 数据集构建
3. 神经解码
-  4. 大模型改进与应用


4. 大模型改进与应用

(1) 借鉴人脑的分区工作机理

- Efficiently to handle multiple tasks
- Easier to solve a new problem
- Avoid the huge cost to redesign

● 基本思路


- Whether there is functional specialization in Transformer based LLM models?



We propose an Important Attention-head Pruning (IAP) method to quantify the degree of functional specialization in the multi-head attention of Transformer-based models.

4. 大模型改进与应用


第1步：用多任务学习方法微调一个大模型



传统的多任务学习方法

4. 大模型改进与应用


第2步： 通过 head mask 机制测试不同头对不同任务的重要，观察分析多头注意力机制中是否存在功能专用现象



量化的功能分化方法

4. 大模型改进与应用

第3步： 对于不同的任务只微调它们的前 k 个重要的头(heads)



改进的功能训练方法(IAT)

4. 大模型改进与应用


● 在GLUE测试集上的实验（分类任务）

Model	Type	#Params	CoLA Mcc	MNLI-(m/mm) Acc	MRPC F1	QNLI Acc	QQP F1	RTE Acc	SST-2 Acc	STS-B r^s	Avg
TinyBERT [†]	ST	9.0×	46.3	83.0/82.4	85.1	90.0	70.7	65.6	92.9	84.6	77.8
TinyBERT +IAT	MTL	<u>1.0</u> ×	35.2	82.6/81.9	83.4	90.5	70.2	74.0	92.5	83.5	77.1
	MTL	<u>1.0</u> ×	39.3	82.5/81.9	85.4	90.3	70.5	74.1	92.7	84.2	77.9
BERT _{BASE} ¹	ST	9.0×	52.1	84.6/83.4	88.9	90.5	71.2	66.4	93.5	85.8	79.6
PALs ²	MTL	1.13×	51.2	84.3/83.5	88.7	90.0	71.5	76.0	92.6	85.8	80.4
CA-MTL _{BASE} ³	MTL	1.12×	53.1	85.9/85.8	88.6	90.5	69.2	76.4	93.2	85.3	80.9
Ticket-Share _{BASE} [†]	MTL	<u>1.0</u> ×	50.3	83.7/83.0	88.0	90.5	70.5	76.6	93.7	84.8	80.1
BERT _{BASE} +IAT	MTL	<u>1.0</u> ×	49.8	83.9/83.4	86.4	89.9	70.3	76.0	93.2	85.7	79.8
	MTL	<u>1.0</u> ×	51.6	83.9/83.1	87.6	90.6	71.2	76.8	94.1	86.2	80.6
BERT _{LARGE} ¹	ST	9.0×	60.5	86.7/85.9	89.3	92.7	72.1	70.1	94.9	86.5	82.1
Adapters-256 ⁴	ST	1.3×	59.5	84.9/85.1	89.5	90.7	71.8	71.5	94.0	86.9	80.0
CA-MTL _{LARGE} ³	MTL	1.12×	59.5	85.9/85.4	89.3	92.6	71.4	79.0	94.7	87.7	82.8
Ticket-Share _{LARGE} [†]	MTL	<u>1.0</u> ×	56.2	86.0/85.6	88.7	92.7	71.4	78.8	94.5	85.6	82.2
BERT _{LARGE} +IAT	MTL	<u>1.0</u> ×	56.8	85.6/84.9	86.6	92.4	71.3	79.0	94.3	86.2	81.9
	MTL	<u>1.0</u> ×	60.0	85.5/85.3	88.4	92.1	71.5	79.1	94.5	86.8	82.6
RoBERTa _{BASE} [†]	ST	9.0×	60.0	87.2/86.7	90.8	93.1	72.1	71.9	95.7	88.2	82.9
RoBERTa _{BASE} +IAT	MTL	<u>1.0</u> ×	55.3	87.2/86.7	89.6	92.3	71.4	80.0	95.1	87.1	82.7
	MTL	<u>1.0</u> ×	59.9	86.9/86.8	90.9	92.4	71.8	80.5	95.4	87.1	83.5
DeBERTaV3 _{BASE} [†]	ST	9.0×	67.1	90.0/89.2	90.6	94.4	73.9	81.5	96.2	88.9	85.8
DeBERTaV3 _{BASE} +IAT	MTL	<u>1.0</u> ×	63.1	89.9/89.2	89.4	93.8	73.7	86.7	95.5	89.6	85.7
	MTL	<u>1.0</u> ×	67.2	89.7/89.2	90.9	93.8	74.0	86.9	95.8	89.7	86.4

3. 大模型的改进

(2) 低资源语言的回复质量改进

- **安全性差**：相比高资源语言，大模型使用低资源语言回复容易包含不安全的内容。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。




- **忽略语言特定的文化知识**：由于不同语言之间语料的不均衡性，大模型通常忽略这些语言上的文化知识，使用英文中的习惯。例如，让ChatGPT写一封中文信时，ChatGPT通常会使用“**诚挚地**” (54.0%)、“**致意**” (38.4%)结尾，而不是中文常用的“**此致敬礼**” (0.8%)。

3. 大模型的改进


◆ 已有的工作

- **翻译方法：**将英文中高质量的指令微调数据翻译到低资源语言。
- **存在问题：**翻译过程中容易引入翻译错误，忽略语言特定知识。例如下图中，**fine** 和 **mine** 发音相同，但“好的”和“金矿”发音在中文就不同了。



3. 大模型的改进

- 基于蒸馏大模型的方法：将指令翻译到低资源语言，让ChatGPT或GPT-4生成回复。
- 问题：ChatGPT等模型在部分低资源语言上回复很差，无法得到高质量的回复。



产生回复后的低资源数据作为训练集训练低资源语言上的模型。

3. 大模型的改进

◆ 我们的方法：X-Instruction — 从原始语料中挖掘跨语言指令数据

● 三步走

(1) 利用大语言模型从预训练语料中生成合适的英文指令

ผู้เขียนนวนิยายเรื่อง “ชายชรา กับ ทะเล” คือ เฮมิงเวย์ (小说《老人与海》的作者是海明威。泰语)

→ 问题：Who is the author of the novel ‘The Old Man and the Sea’ ?


(2) 构造伪标签数据训练模型，过滤出高质量的指令数据

训练一个打分器：丰富语言的答案翻译成低资源数据得分最高；生成的伪数据略低；随机产生的(最差)打分最低。


(3) 将英文指令聚类，在不同聚类上均匀采样，得到多样化的指令数据

3. 大模型的改进

(I) X-Instruction Generation






(II) X-Instruction Refinement



3. 大模型的改进

(III) X-Instruction Diversification



优势:

- ① 仅提供原始语料和预训练好的大模型就能生成高质量跨语言指令数据;
- ② 生成的数据中包含原始语料的语言文化知识。

3. 大模型的改进

◆ GPT-4评价

- 效果：我们的方法(X-Instruction)取得了在10个语言上同参数量下模型的最高回复质量，甚至相比ChatGPT的回复能超过50%的胜率


Model	Medium										Low										Avg	
	fi		id		th		tr		vi		bn		hi		sw		ta		ur			
	W	S	W	S	W	S	W	S	W	S	W	S	W	S	W	S	W	S	W	S		
Alpaca-MT _{7B}	22.8	4.8	24.5	5.4	23.5	3.0	34.6	3.3	35.6	5.1	20.5	2.5	26.8	2.1	27.5	3.1	24.8	2.3	33.9	3.3	27.5	3.5
Bactrian-X _{7B}	14.1	2.3	19.1	2.8	0.7	0.2	18.8	1.3	4.7	0.5	1.7	0.2	1.3	0.2	27.2	2.8	0.3	0.0	4.7	0.4	9.3	1.1
Bactrian-M _{7B}	32.9	6.2	37.2	6.7	37.6	5.4	52.0	6.7	47.7	6.4	34.2	3.7	53.4	4.8	46.3	6.1	22.1	1.9	49.0	5.2	41.2	5.3
X-Instruction _{7B}	37.2	6.6	41.3	7.1	40.6	5.8	49.7	6.0	53.0	7.3	41.3	4.9	62.4	6.3	54.0	7.0	54.7	5.2	57.4	6.4	49.2	6.3
X-Instruction [†] _{7B}	35.6	6.2	37.2	6.9	35.2	5.0	47.0	5.9	48.0	6.4	35.2	4.2	52.0	5.3	41.9	6.0	55.7	5.3	51.0	5.6	43.9	5.7
Bactrian-X _{13B}	18.5	3.3	21.8	3.5	3.0	0.4	25.5	1.9	6.0	0.7	1.0	0.2	1.0	0.3	29.5	3.6	1.7	0.2	5.4	0.5	11.3	1.5
Bactrian-M _{13B}	37.6	6.6	39.6	7.5	41.6	6.0	49.0	6.8	50.7	7.3	38.6	4.4	58.7	5.5	50.0	6.7	28.9	2.6	51.0	5.2	44.6	5.9
X-Instruction _{13B}	47.0	7.5	50.3	8.2	53.0	7.6	53.7	7.0	57.0	7.8	68.8	7.4	64.4	7.1	54.4	7.1	76.8	7.6	71.1	7.5	59.7	7.5
X-Instruction [†] _{13B}	42.6	7.1	44.0	7.5	43.0	6.1	53.4	6.5	54.7	7.5	58.4	6.7	65.8	6.6	49.3	6.6	67.1	6.8	57.7	6.7	53.6	6.8

“W” represents the average win rates against ChatGPT and “S” represents the average GPT-4 score on *Vicuna* and *WizardLM* benchmarks. † denotes the zero-shot evaluation results, where the X-Instruction model is prompted in the output language rather than the English prompt used in training.

3. 大模型的改进

◆ 人工评价

- 效果：我们的方法在**乌尔都语、斯瓦希里语**和**孟加拉语**上都比ChatGPT好



(a) X-Instruction_{13B}(■) vs. ChatGPT(■)

C. Li et al. X-Instruction: Aligning Language Model in Low-resource Languages with Self-curated Cross-lingual Instructions. *Proc. ACL 2024*

*The performance of models given prompts with different difficulties on **WizardLM** dataset in 10 languages.*

结束语

- 大语言模型为探索人脑理解语言的神经机制提供了新的研究思路和技术手段;
- 借助于预训练语言模型根据 **fMRI** 数据直接生成词语, 甚至在给定上下文的情况下生成连贯的自然语言文本句子是可能的, 而且有令人期待的结果;
- 借助于对大脑功能和认知机理的认识, 改进大模型结构, 压缩大语言模型的规模, 提升大模型在低资源语言上的处理能力, 甚至改进模型结构等, 都是值得探索的技术路线;
- 明确目标和定位, 研发自主可控的、具有强大推理和泛化能力的低成本大模型是未来**AI**发展的必然趋势。



谢谢!
Thanks!



清华大学出版社，2024.1