



# 预训练大模型的应用技术

蒋芳清

鹏城实验室网络智能研究部开源所

# CONTENTS

01

基本框架

02

小样本学习

03

开源



# CONTENTS

01

基本框架

02

小样本学习

03

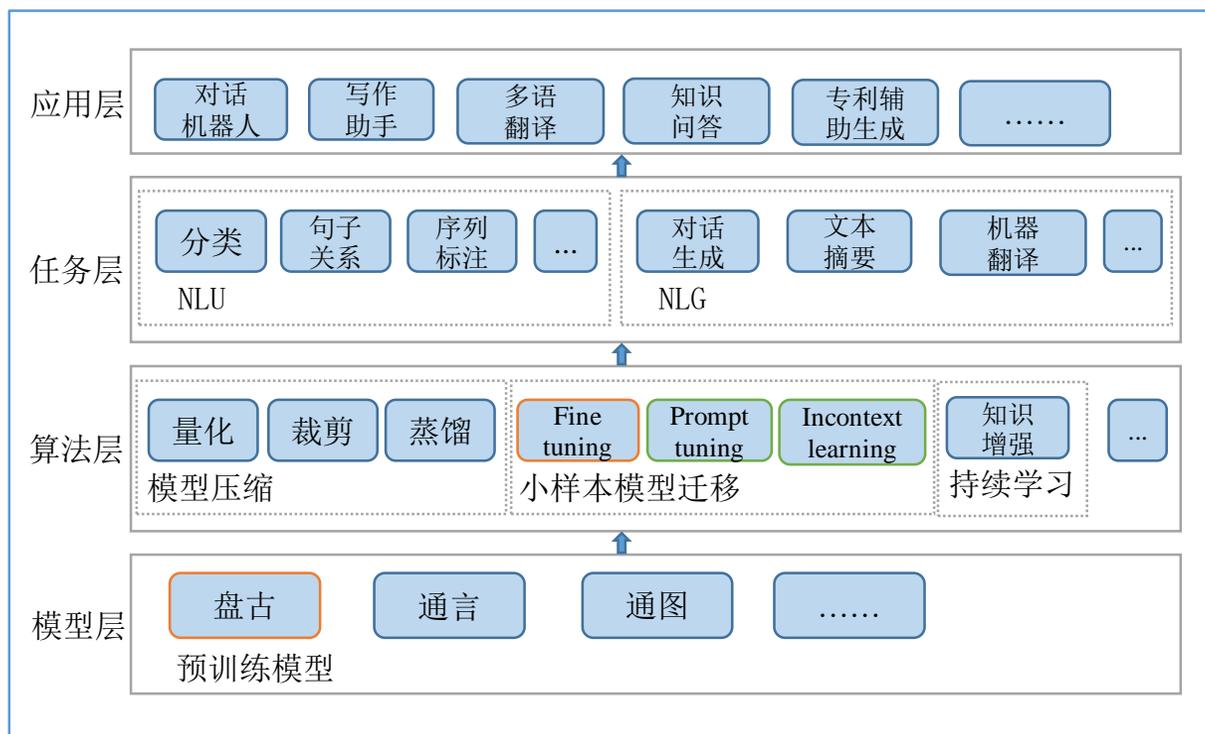
开源

鹏城实验室

鹏城实验室

# 模型应用-基本框架

## 基本框架

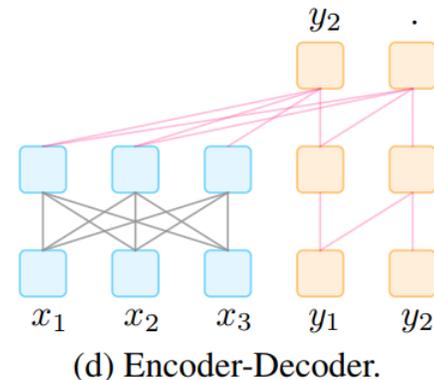
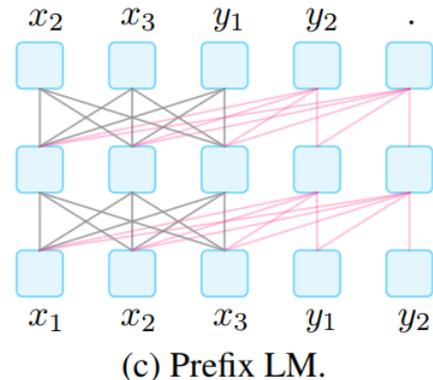
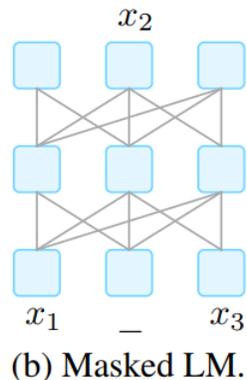
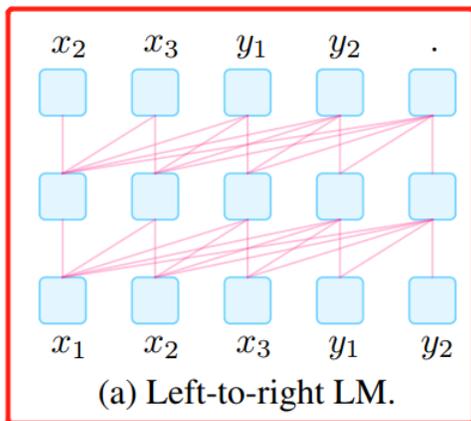


- **模型层:** 基于分布训练模架、大数据、高效算法训练大模型，构建文本、多语言、多模型、知识图谱等领域的AI底层基础设施。
- **算法层:** 基于预训练模型做模型压缩、小样本模型迁移、持续学习等方面的算法创新，构建基础算法模块，为预训练模型落地应用提供底层算法支撑。
- **任务层:** 基于算法层基础算法模块，构建两大基础任务NLU和NLG的实现样例，为上层应用提供底层任务建模支撑。
- **应用层:** 基于任务层基础任务，设计**对话机器人、写作助手、多语翻译、知识问答、专利辅助生成**等应用，为预训练模型落地应用提供示范应用，促进模型的加速落地和深度应用。

# 模型应用-基本框架

## 模型层-盘古模型

网络结构



预训练任务

预训练目标	描述	应用
标准语言模型LM	文本以自回归方式预测，从左到右依次预测序列中的词。	NLG
噪声文本重建CTR	输入句子引入噪声，将处理后的文本恢复到未损坏的状态。	NLU
全文本重建FTR	计算整个输入文本的损失来重构文本，无论输入文本是否有噪声。	NLU&NLG
辅助目标	描述	
NSP	下一句预测，二分类	
SOP	句子顺序预测，二分类	

# CONTENTS

01

基本框架

02

小样本学习

03

开源

鹏城实验室

鹏城实验室

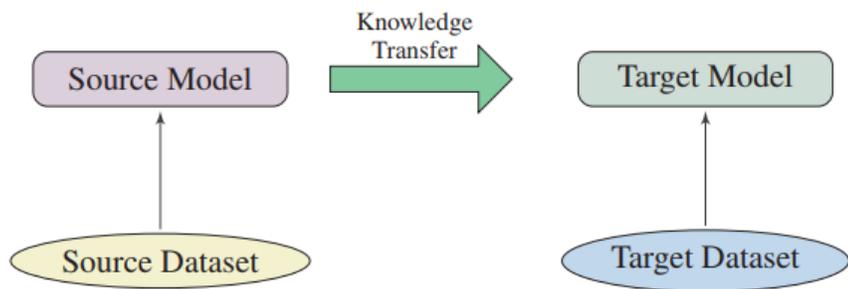
# 模型应用-小样本学习

## 什么是小样本学习

人类非常擅长通过极少量的样本识别一个新物体，比如小孩子只需要书中的一些图片就可以认识什么是“斑马”，什么是“犀牛”。

在人类的快速学习能力的启发下，研究人员希望机器学习模型在学习了一定类别的大量数据后，对于新的类别，只需要少量的样本就能快速学习，这就是小样本要解决的问题。

## 大规模预训练模型下的小样本学习

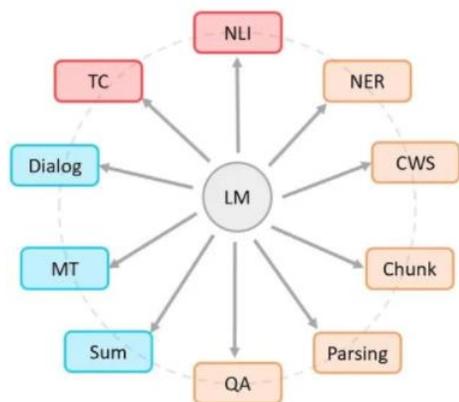


预训练模型通过大量数据训练学习到广泛的通用知识和知识表示，直接将其应用到特定领域任务并不能得到好的性能。

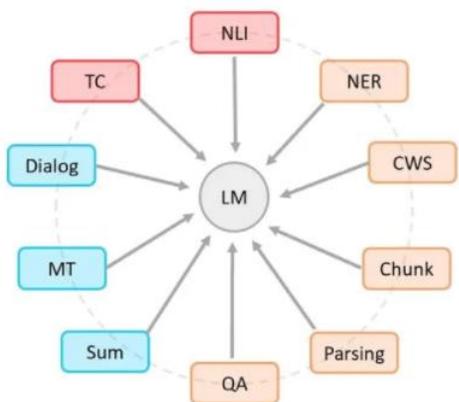
结合预训练语言模型通用和强大的泛化能力基础上，探索通小样本学习将预训练模型的知识 and 表示迁移到特定领域任务。

# 模型应用-小样本学习

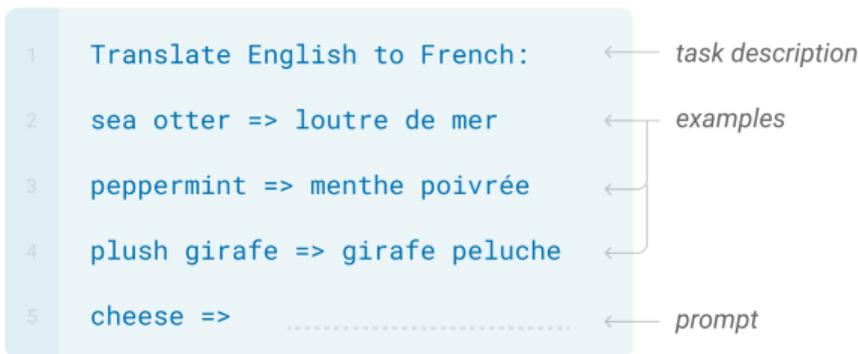
## 技术方向



Fine-tune



Prompt-tune



In-context learning

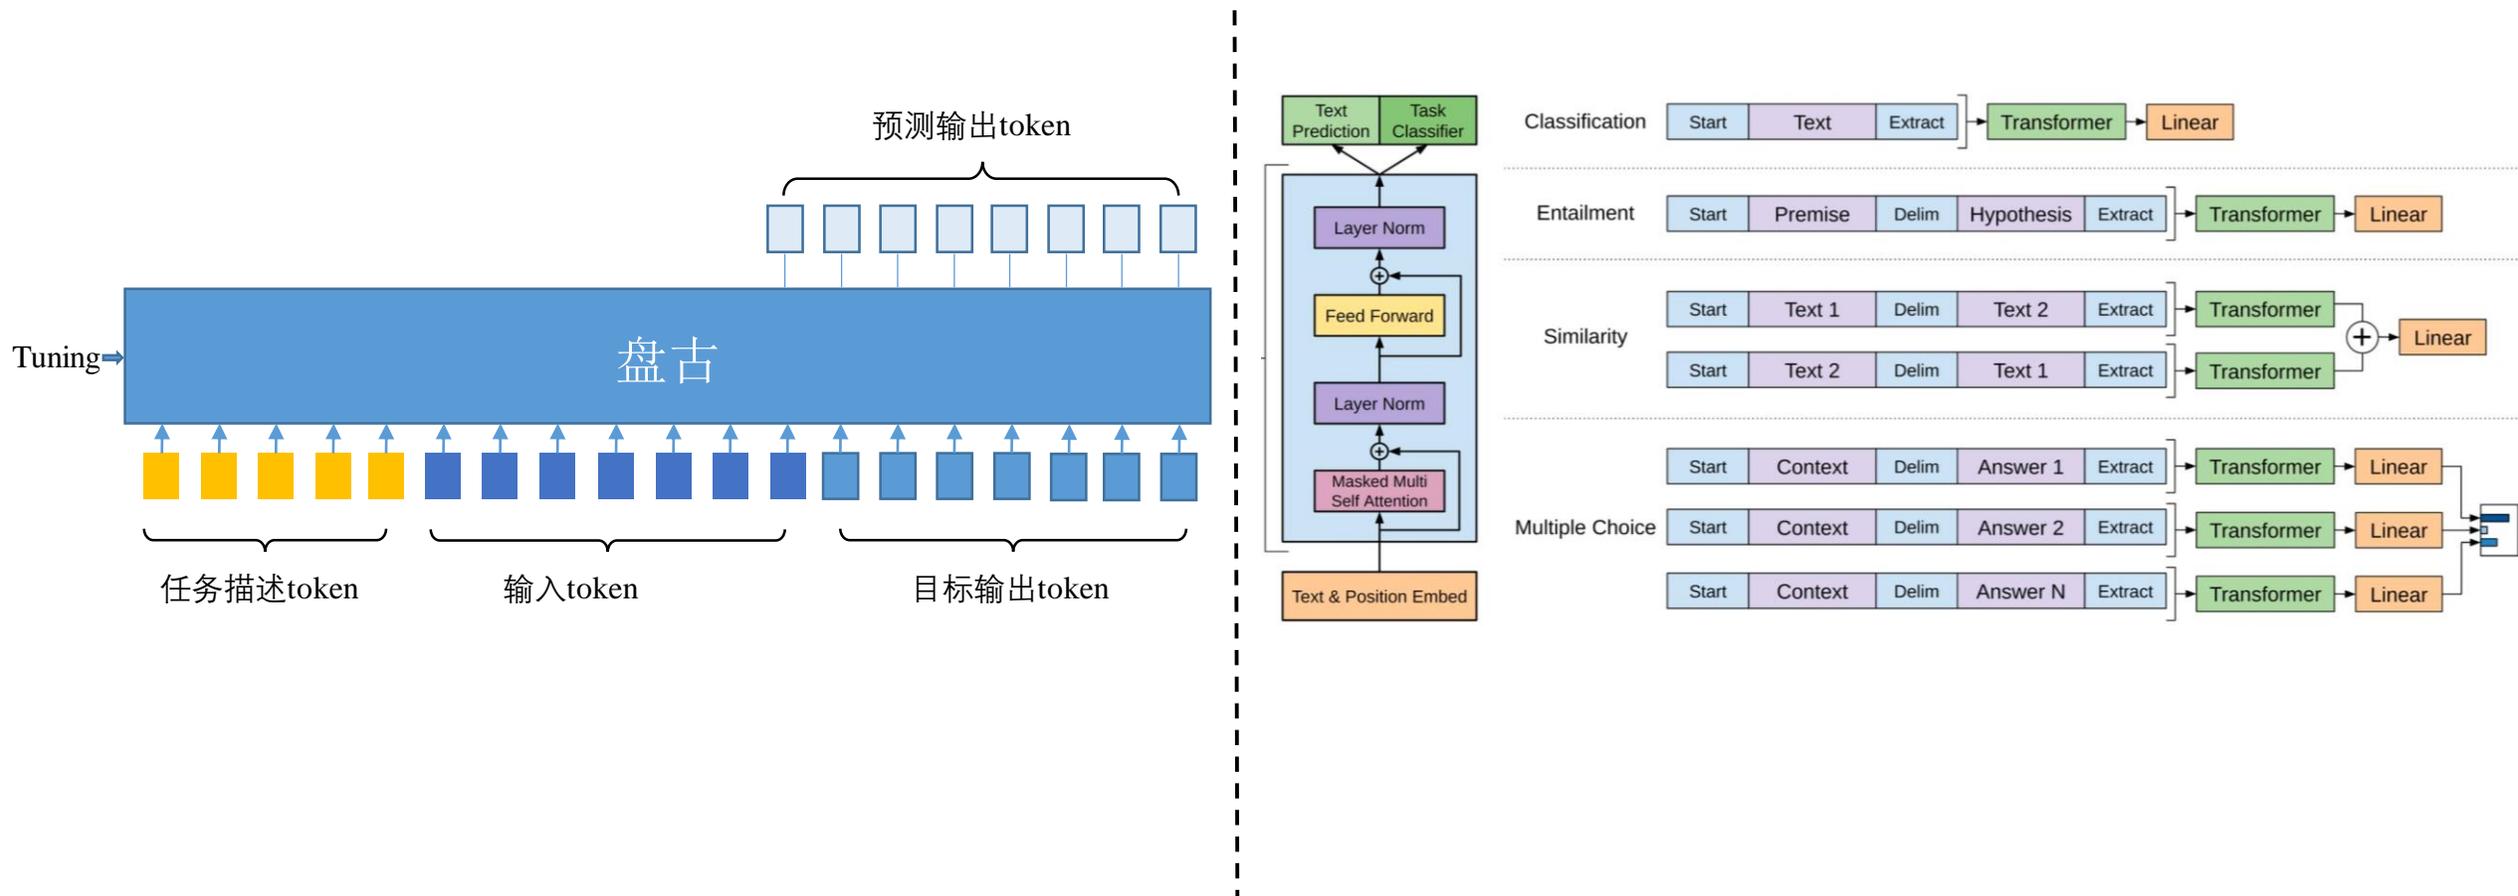
类别	工程	描述
Fine-tune	Objective Tuning	预训练微调范式，通过引入 <b>较多额外的参数</b> 并使用特定任务的目标函数对预训练模型进行微调，将预训练 <b>语言模型适应于不同的</b> 下游任务。
Prompt-tune	Prompt + Tuning	prompt-tune即预训练加提示的范式，这种范式不是让预训练的语言模型适应下游任务，而是 <b>形式化下游任务</b> 使之在提示(prompt)的帮助更适合预训练模型的原始任务来解决问题。
In-context learning	Prompt + Examples	上下文学习，通过给模型输入 <b>任务提示和相关示例</b> 使用预训练语言模型， <b>无需重新训练模型和增加额外参数</b> ，更接近人类解决新任务的机制。

# 模型应用-小样本学习

## ■ 盘古模型—Fune-tune

预训练阶段：采用文本下一词预测作为语言模型训练任务；

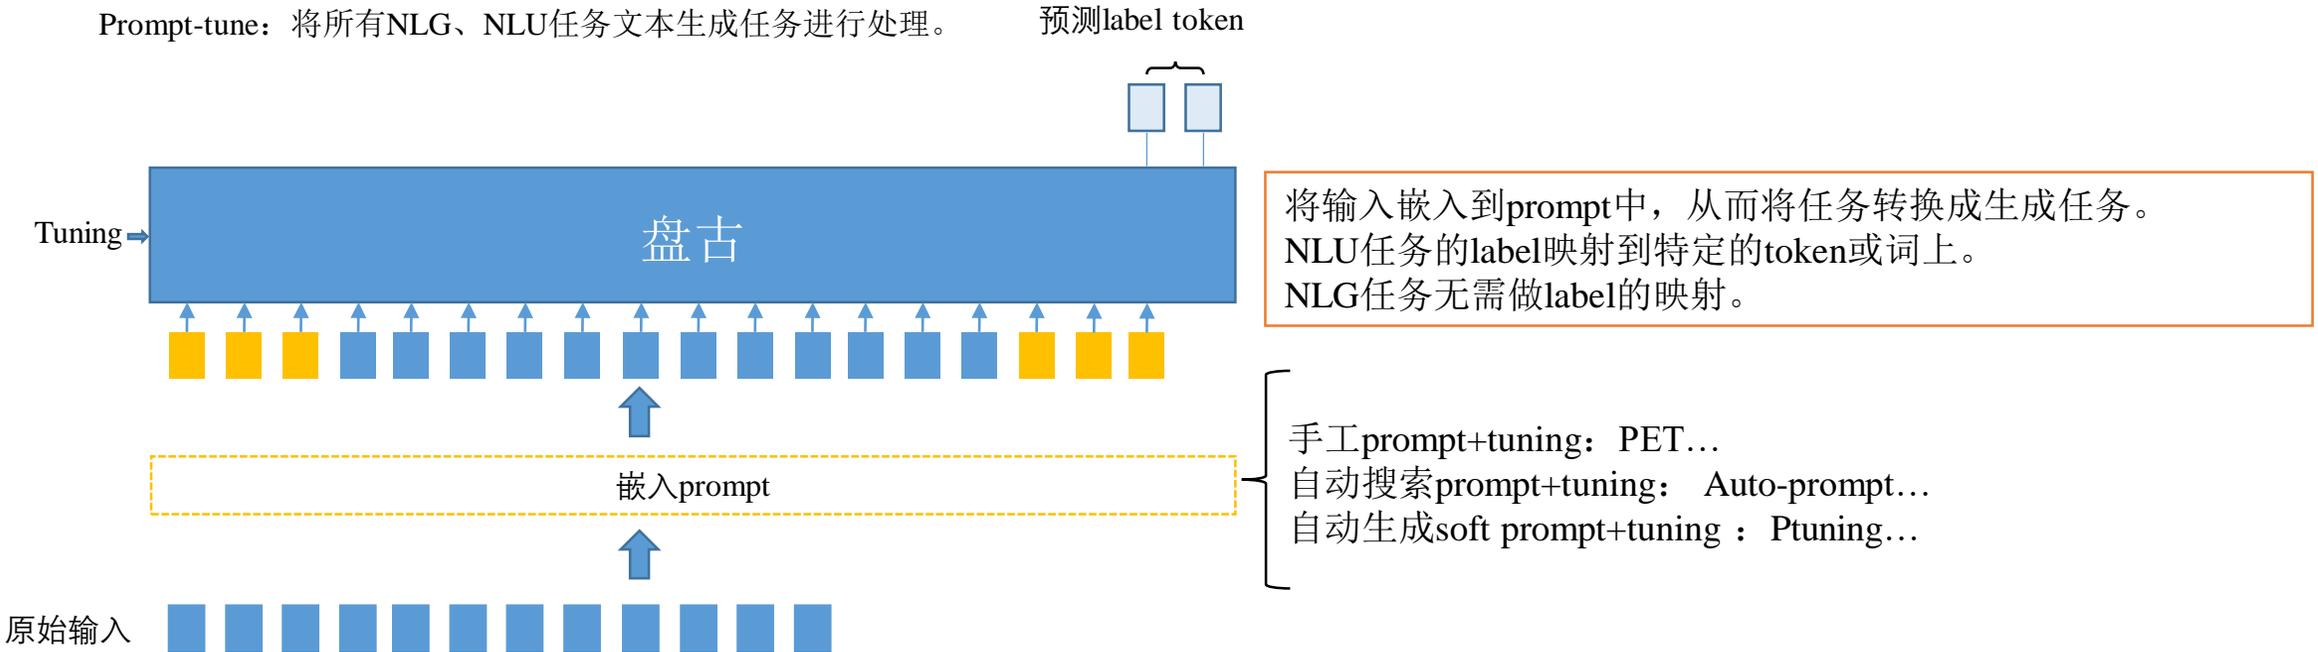
Fune-tune：NLG任务采用与预训练一致的方式进行处理，NLU任务加一层Linear Project来完成分类/相似度计算等任务。



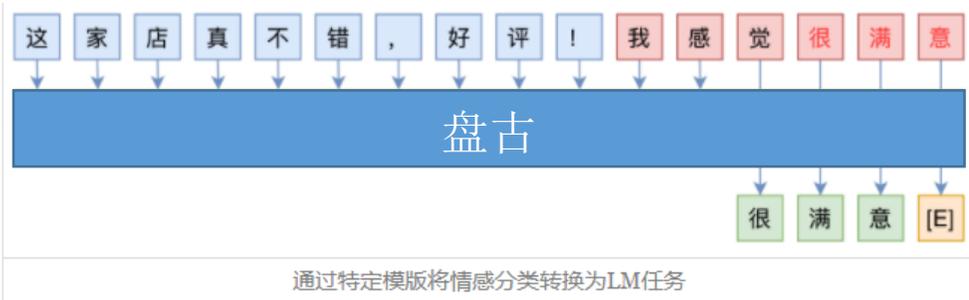
# 模型应用--小样本学习

## ■ 盘古模型—Prompt-tune

预训练阶段：采用文本下一词预测作为语言模型训练任务；  
 Prompt-tune：将所有NLG、NLU任务文本生成任务进行处理。



PET示例



pattern P: 原始输入到完形填空式问题的映射。

verbalizer v: 输出映射到label。

# 模型应用-小样本学习

## ■ 盘古模型—Incontext learning

预训练阶段：采用文本下一词预测作为语言模型训练任务；

Incontext few shot learning：将输入嵌入到prompt中同时加上示例输入给模型，类似人类解决新任务的机制。

16大下游任务的prompt

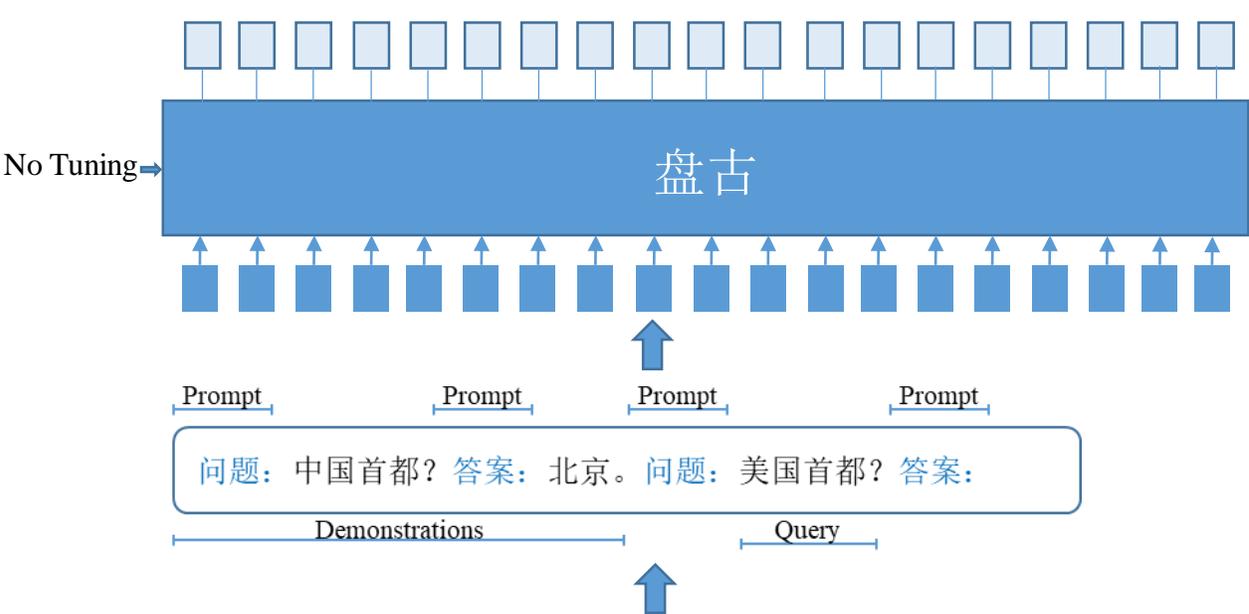
Task	Dataset	Input& Prompt
	WPLC	/
	CHID	/
完型填空与补全	PD&CFT	/
	CMRC2017	/
	CMRC2019	/
阅读理解	CMRC2018	阅读文章: \$Document\n 问: \$Question\n 答:
	DRCD	阅读文章: \$Document\n 问: \$Question\n 答:
	DuReader	阅读文章: \$Document\n 问: \$Question\n 答:
闭卷问答	WebQA	问: \$Question\n 答:
指代消解	CLUUEWSC2020	/
常识推理	C3	问: \$Question\n 答:\$Choice\n 该答案来自对话: \$Passage
自然语言推理	CMNLI	SS1?对/或许/错, SS2
	OCNLI	SS1?对/或许/错, SS2
文本分类	TNEWS	这是关于\$label的文章: \$passage
	IFLYTEK	这是关于\$label的应用程序: \$passage
	AFQMC	下面两个句子语义相同/不同: SS1, SS2
	CSL	摘要: \$passage, 关键词: \$keyword 是/不是真实关键词

OCNLI的 few shot

```

<句子1>, 对?<句子1>
<句子2>, 或许?<句子2>
<句子3>, 错?<句子3>
...
<句子k>, 对?<句子k>
<句子k+1>, 或许?<句子k+1>
<句子k>, 错?<句子k>
<测试句子1>, <标签>?<测试句子2>

<Sentence1>,Yes?<Sentence1>
<Sentence2>,Maybe?<Sentence2>
<Sentence3>,No?<Sentence3>
...
<Sentencek>,Yes?<Sentencek>
<Sentencek+1>,Maybe?<Sentencek+1>
<Sentencek>,No?<Sentencek>
<Test-sentence1>,<Label>?<Test-sentence2>
    
```



所有的任务分为两类：分类类型和生成类型。  
 分类类型任务：将任务分解为困惑度比较任务。

# CONTENTS

01

基本框架

02

小样本学习

03

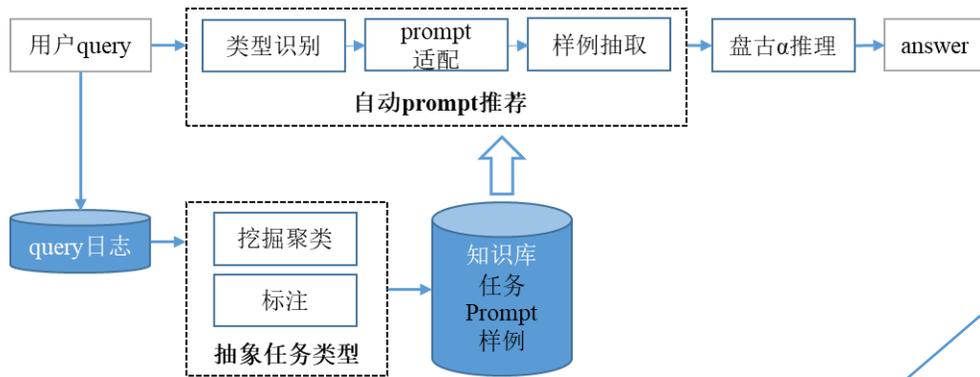
开源



# 模型应用-开源

## ■ 盘古模型—在线推理服务自动提示推荐

基于盘古 $\alpha$ 在线推理服务的历史数据，进行数据挖掘分类，抽象出任务类型，构造知识库。  
抽象出的任务并构建知识库，自动生成prompt和demonstration examples推荐，提升模型推理性能。



当前版本已做到自动判定用户输入任务类型，推荐相应手工prompt和topk/topp参数，后续计算实现自动生成prompt、topk/topp参数和demonstration examples。



# 模型应用-开源

## 盘古模型—应用技术开源

<https://git.openi.org.cn/PCL-Platform.Intelligence/PanGu-Alpha-Application>



### 鹏程·盘古α介绍

「鹏程·盘古α」由以鹏城实验  
动混合并行模式实现在2048+  
预训练生成语言模型。鹏程·盘  
理解等文本生成领域表现突出

[\[技术报告\]](#)

[\[模型在线推理\]](#)

[\[模型下载\]](#)

[\[模型压缩\]](#)

[\[模型应用\]](#)

[\[GPU推理、Finetune\]](#)

[\[小样本学习\]](#)

[\[megatron中文预训练模型\]](#)

[\[语料数据收集及处理\]](#)

[\[评测数据集下载\]](#)

[\[serving展示视频下载\]](#)

[\[FAQ\]](#)

[\[MindSpore官网\]](#)

[\[加入微信交流群\]](#)

[\[许可证\]](#)

## PanGu-Alpha-Application

### 简介

本项目旨在为鹏程系列超大规模预训练模型提供从算法层到设施，加速大模型的应用技术创新和应用生态构建。

### 内容导引

	项目	描述
预训练模型	<a href="#">[鹏程盘古]</a>	鹏程系列预训练模型
算法层&任务层	<a href="#">[模型迁移]</a> <a href="#">[模型压缩]</a>	算法层与任务层位置
应用层	<a href="#">[应用]</a>	应用层项目位置

### 进展

- 2021.08.18
  - 小样本模型迁移第一版baseline发布。
  - 任务层：支持盘古模型nli任务，baseline: cmnli。
  - 算法层：支持盘古模型fine-tune, prompt-tune,

..		
distill	cmnli baseline with finetune, prompt tune and zeroshot on pangu.	1 天前
finetune	update readme.	11 分钟前
generate	cmnli baseline with finetune, prompt tune and zeroshot on pangu.	1 天前
incontext	update readme.	11 分钟前
increment	cmnli baseline with finetune, prompt tune and zeroshot on pangu.	1 天前
kgenhance	cmnli baseline with finetune, prompt tune and zeroshot on pangu.	1 天前
prompttune	update readme.	11 分钟前
README.md	更新 'method/README.md'	8 分钟前
__init__.py	cmnli baseline with finetune, prompt tune and zeroshot on pangu.	1 天前

### README.md

## 算法层&任务层

### 简介

此目录包含算法层&任务层的实现，应用算法常以一个任务做为实现实例，因此算法层和任务层在实现上归为一层。



# 模型应用-开源

## 问题与挑战

- 超大规模预训练研究较多，应用技术算法研究较少，无参考。
- 分布式训练问题，问题定位难。
- 代码规范问题。

```
predict: [0, 1, 0, 0, 0, 0, 0, 0].
loss_reduced: {'lm loss': tensor(1.5820, device='cuda:0')}.
target: [0, 2, 0, 1, 1, 1, 0, 2].
predict: [1, 0, 0, 0, 1, 1, 1, 0].
loss_reduced: {'lm loss': tensor(1.1885, device='cuda:0')}.
target: [0, 0, 2, 0, 2, 0, 1, 0].
predict: [0, 2, 1, 1, 2, 0, 0, 1].
loss_reduced: {'lm loss': tensor(1.1621, device='cuda:0')}.
Traceback (most recent call last):
  File "/opt/conda/lib/python3.6/runpy.py", line 193, in _run_module_as_main
    "__main__", mod_spec)
  File "/opt/conda/lib/python3.6/runpy.py", line 85, in _run_code
    exec(code, run_globals)
  File "/opt/conda/lib/python3.6/site-packages/torch/distributed/launch.py", line 263, in <module>
    main()
  File "/opt/conda/lib/python3.6/site-packages/torch/distributed/launch.py", line 259, in main
    cmd=cmd)
subprocess.CalledProcessError: Command '['/opt/conda/bin/python', '-u', '/userhome/gpt3/PanGu-Alpha-GPU/panguAlpha
--num-attention-heads', '32', '--batch-size', '8', '--seq-length', '1024', '--max-position-embeddings', '1024', '-
oot/pangu/model/pangu_fp16_4mp_2b6', '--data-path', '/root/pangu/data/cmnl_public', '--vocab-file', '/userhome/gp
'mmap', '--split', '949,50,1', '--distributed-backend', 'nccl', '--lr', '0.00005', '--lr-decay-style', 'cosine',
eval', '100', '--eval-interval', '100', '--eval-iters', '1000', '--attention-dropout', '0.1', '--hidden-dropout',
--fp16-lm-cross-entropy', '--use-cpu-initialization']' died with <Signals.SIGSEGV: 11>.
root@2734b4c399a7:/userhome/gpt3/PanGu-Alpha-GPU/panguAlpha_pytorch/examples#
```



**感谢聆听!**