



**上海证券**  
SHANGHAI SECURITIES


# AIGC 系列专题：“大模型+小样本”快速适配下游场景，“AI+传媒”的效力取决于适配与迭代

——通用预训练模型技术拆解

## 增持（维持）

行业： 传媒  
日期： 2023年03月29日  
分析师： 陈旻  
Tel: 021-53686134  
E-mail: chenmin@shzq.com  
SAC 编号: S0870522020001

最近一年行业指数与沪深 300 比较



### 相关报告:

《周观点：ChatGPT 开放插件测试，“行业小样本”适配范围显著增加》

——2023 年 03 月 26 日

《2023W11 周数据跟踪》

——2023 年 03 月 20 日

《周观点：OpenAI 及百度先后发布生成式 AI，“大模型+小样本”适配垂类场景》

——2023 年 03 月 19 日

### 主要观点

我们拆解ChatGPT技术模型后认为，GPT与应用层的结合属于“通用大模型+行业小样本”的技术范式，通过上游通用预训练语言模型及下游任务知识迁移实现通用大模型与垂直应用的快速适配，形成独立且差异化的应用专属大模型。其中预训练大模型的构建可以将更多的资源和数据转移到上游，小样本学习可以提升模型迭代的速度并快速适配下游场景。

我们认为“AI+传媒”在应用层表现效力优劣的关键取决于通用大模型对垂直应用的适配程度及迭代速度。

- **适配程度是指：**多模态的输入及输出是否匹配应用层的输入及输出。比如GPT-4属于“图+文”多模态输入+“文”单模态输出，因此输入模态为“图或文”且输出模态为“文”的垂直应用更适配GPT-4。
- **迭代速度是指：**应用层产生的“行业小样本”的数据量是否匹配大模型的迭代要求。根据我们对GPT模型的理解，比如Bing AI产生的“行业小样本”源自Bing的搜索结果，ChatGPT产生的“行业小样本”源自用户的反馈和互动。因此我们认为，对于超出GPT所使用的预训练数据库范围（2021年9月前）的事实性表述，Bing AI反馈的是搜索的结果，ChatGPT反馈的是用户主动的观点，Bing AI反馈的效果比ChatGPT更好。

因此文字类/人声类（声音可有效转化为文字）输入及输出的应用或内容与以GPT为代表的生成式文本AI适配度最高。图片、视频、3D建模等更复杂的模态输出需要AI技术的进一步演进。对应到具体应用，我们认为（1）广告：适配场景包括搜索、虚拟数字人、文案类工作效率的提升等；（2）电商：适配场景包括智能客服、图文编辑、内容测评等；（3）游戏：适配场景包括智能NPC、IP化虚拟人等；（4）影视：适配场景包括编剧、互动电影等。

我们认为AIGC可分为技术方（直接收益）及场景/应用方（直接&间接收益）两类，前者为AIGC相关技术直接研发及相关上下游（如算力），变现模式预计包括会员付费、广告变现、B端变现等（如技术授权/服务/运维等）；后者为AIGC技术与落地场景深度融合，场景/应用方利用AIGC技术获得直接收益或间接收益：（1）直接收益对应收入弹性，对应市场空间的增量；（2）间接收益对应利润弹性，对应利润率的提高。

### 投资建议

- 1、建议关注A股稀缺的优质内容型平台公司【芒果超媒】，有望成为传媒估值中枢锚。
- 2、建议关注拥有海外用户/业务，有望接入GPT的优质标的，如【汤姆

猫】（全球用户）、【昆仑万维】（Opera）、【神州泰岳】（游戏出海+NLP）、【吉宏股份】（跨境电商SaaS）、【华凯易佰】（跨境电商）、【焦点科技】（跨境电商）、【蓝色光标】（出海）。

3、建议关注可与生成式图像AI Midjourney对标的【浙文互联】（米画）、【视觉中国】。

4、建议关注国内电商类的【新华都】（电商代运营）、【值得买】（内容测评）、【遥望科技】（虚拟人）、【壹网壹创】（电商代运营）、【青木股份】（电商代运营）、【若羽臣】（电商代运营）、【丽人丽妆】（电商代运营）。

5、建议关注AIGC+游戏，如【三七互娱】、【完美世界】、【吉比特】、【盛天网络】、【世纪华通】、【巨人网络】；AIGC+影视，如【百纳千成】、【欢瑞世纪】、【光线传媒】、【华策影视】、【上海电影】、【慈文传媒】、【中文在线】等。

6、建议关注【万兴科技】、【福昕软件】、【光云科技】、【力盛体育】。

## ■ 风险提示

宏观经济风险、地缘政治风险、GPT 与应用结合表现低于预期、AIGC 行业发展不及预期等。

## 目录

1 “大模型+小样本”协同进化，实现下游场景快速适配 .....	4
1.1 Self Attention：里程碑式进化，考虑全局又聚焦重点 .....	4
1.2 上游任务：预训练语言模型，积累强大底层通用能力 .....	5
1.3 下游任务：知识迁移调试，实现垂直领域微调适配 .....	8
2 风险提示 .....	10

## 图

图 1：基于 Transformer 的编码器框架 .....	5
图 2：基于 Transformer 的解码器框架 .....	5
图 3：“预训练+微调”机制解决 NLP 任务碎片化问题 .....	6
图 4：监督调优（SFT）模型 .....	6
图 5：训练奖励模型 .....	7
图 6：通过近端策略优化对奖励模型进行强化学习 .....	7
图 7：大规模预训练模型在多种模态数据的训练和下游任务应用中处于中心地位 .....	8
图 8：基础模型将转换为适应模型以反映更新的信息、期望的行为或部署约束 .....	8
图 9：迁移学习的过程 .....	9

人工智能技术正迅速发展，可以观察到的明显趋势是 AI 正从感知智能快速向以自然语言处理技术（NLP）为核心的认知智能迈进，并进一步推动了产业智能化革命。本文主要从技术底座的角度，对通用预训练语言模型（GPT）的技术流程进行拆解，并从中归纳其能够成为自然语言处理技术领域中的重要模型之一的的原因。

## 1 “大模型+小样本”协同进化，实现下游场景快

### 速适配

通用预训练语言模型（Generative Pre-trained Transformer，简称 GPT）是由 Open AI 提出的一款非常强大的预训练语言模型。该模型的原理是通过利用 Transformer 特征抽取器，基于大规模语言模型进行训练的语言模型。目前该模型已经成为自然语言处理领域乃至整个人工智能领域中的基础模型，能够在复杂的自然语言处理任务中取得出色的效果，例如文章生成、机器翻译、提问回答等（截至 22 年 11 月）。


#### 1.1 Self Attention：里程碑式进化，考虑全局又聚焦重点

Open AI 发表的论文《Attention is all you need》中提出了一种新的注意力机制：Transformer 的自注意力机制（Self Attention）。Transformer 是一种用于序列到序列（Sequence-to-Sequence）任务的神经网络模型，它使用了自注意力机制来计算输入序列和输出序列之间的关系。根据蓝海星智库，与循环神经网络（RNN）和卷积神经网络（CNN）相比，Transformer 模型的主要优势在于能够捕获全局信息，进行并行计算，可用于处理和析大型结构化数据集，适用于自然语言处理任务。

将人脑的注意力机制引入自然语言处理中，摆脱海量信息下计算能力的掣肘。随着数据量和参数量越来越多，训练模型需要记住的“信息”就会变多，模型变得越来越复杂，而计算能力依然是限制神经网络发展的瓶颈。人脑在面对海量信息时，会把注意力放在主要的信息上，这是大脑的注意力机制。把注意力机制运用到自然语言处理任务中，提出了 Attention 机制。从本质上来理解，我们认为 Attention 是从大量信息中筛选出少量重要信息，并聚焦到这些重要信息上，忽略不重要的信息，权重越大越聚焦于对应的值向量上，即权重代表了信息的重要性。


Transformer 模型的核心结构是编码器（encoder）-解码器（decoder），通过多层注意力增强机制提取文本特征。对于 Transformer 最初应用的翻译任务而言，其过程为输入文本通过 encoder 编码，经过多层注意力增强机制提取特征后，学习并理解语句含义转为词向量，再由 decoder 解码，基于前文词向量生成文本，完成翻译任务。

图 1：基于 Transformer 的编码器框架



资料来源：《Attention Is All You Need》，Ashish Vaswani, Noam Shazeer 等，上海证券研究所

图 2：基于 Transformer 的解码器框架



资料来源：《Attention Is All You Need》，Ashish Vaswani, Noam Shazeer 等，上海证券研究所

Transformer 模型推动计算结构从串行走向并行，优化计算能力和算法的限制。Transformer 的主要优点是它可以并行地处理输入序列中的所有位置，因此在训练和推理时都有着很好的效率。此外，Transformer 没有使用循环结构，因此它不会受长序列的影响，并且在处理长序列时不会出现梯度消失或爆炸的问题。相比之下，基于循环的模型（例如基于 LSTM 的模型）可能在处理长序列时会出现问题，因为它们必须逐个处理序列中的位置，这会使它们的训练速度变慢。另一方面，Transformer 在处理短序列时可能不如基于循环的模型那么准确，因为它没有循环结构可以保留先前位置的信息。

自然语言处理正在形成新的技术范式，任务可以分成上下游进行区分。目前，预训练模型对下游任务的提升非常明显，自然语言处理正在形成新的技术范式，即上游大规模的预训练模型配合下游任务的知识迁移调试。

## 1.2 上游任务：预训练语言模型，积累强大底层通用能力

“预训练-微调”机制可以解决自然语言处理（NLP）任务碎片化问题，已经成为 NLP 领域主流范式。2018 年以来，预训练语言模型（PLM, Pre-trained Language Model）及其“预训练-微调”方法已成为自然语言处理（NLP）任务的主流范式，该范式先利用大规模无标注数据通过自监督学习预训练语言大模型，得到基础模

型，再利用下游任务的有标注数据进行有监督学习微调模型参数，实现下游任务的适配。用一套机制（预训练+微调）解决 NLP 任务碎片化问题，大幅度提高研发效率，标志着 NLP 进入工业化实施阶段。

图 3：“预训练+微调”机制解决 NLP 任务碎片化问题



资料来源：澜舟科技，上海证券研究所

上游任务，即构建预训练语言模型，主要分为三个步骤：收集数据并训练监督策略模型、训练奖励模型、通过近端策略优化 (PPO) 对该奖励模型进行强化学习，以上构成了 GPT 的内核，即基于反馈指令的 PPO 强化学习。

1) 第一步，收集数据，用来训练监督策略模型，即 SFT 模型。在整个模型训练的步骤开始，先抽取样本进行小范围训练，并施以奖励或者惩罚，构建监督策略模型，该模型为预训练语言模型的主模型。

图 4：监督调优 (SFT) 模型

第一步：

收集实证数据并训练监督方案


一个提示词从我们的数据库中作为样本取出



撰写提示词的工作人员演示所需的输出行为



该数据用于完善 GPT-3 的监督学习



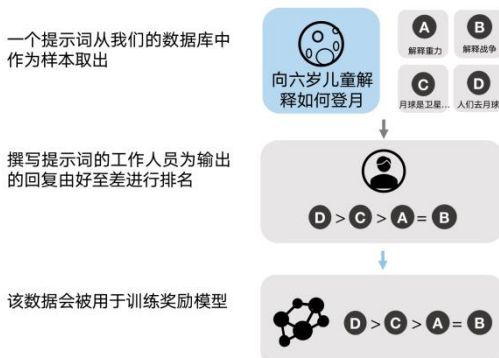
资料来源：《Training language models to follow instructions with human feedback》，Long Ouyang, Jeff Wu 等，上海证券研究所

2) 第二步，在数据库中收集比较性的数据，训练奖励模型。通过引入人类反馈强化学习 (Reinforcement Learning from Human Feedback, 即 RLHF) 机制，由人工训练师进行打分，构建评价体系，也即训练奖励模型。

图 5：训练奖励模型

第二步：

收集比较数据并训练奖励模型



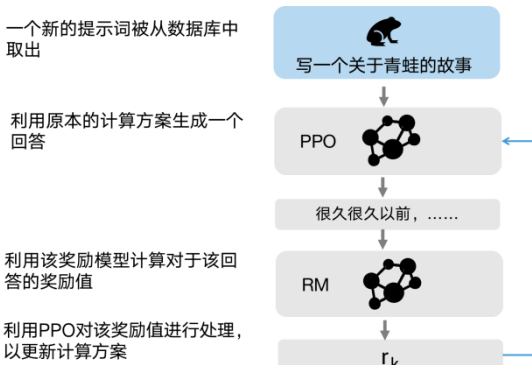
资料来源：《Training language models to follow instructions with human feedback》，Long Ouyang, Jeff Wu 等，上海证券研究所

3) 第三步，通过近端策略优化（PPO）对该奖励模型进行强化学习。另取数据集，先由监督模型初始化近端策略优化（PPO, Proximal Policy Optimization）模型，之后让模型作出回答，并由奖励模型对模型进行打分并排序，再通过 PPO 算法进行强化。

图 6：通过近端策略优化对奖励模型进行强化学习

第三步：

通过强化学习优化奖励学习模型的计算方案



资料来源：《Training language models to follow instructions with human feedback》，Long Ouyang, Jeff Wu 等，上海证券研究所

单一大模型可以积累强大的底层通用能力，与人类学习过程类似。通过构建大数据处理量、大参数量、大训练计算量来构建的预训练语言模型，具有强大的通用能力，能够提高下游不同业务应用场景的效果。大规模预训练模型与人类学习过程类似，人类通过先学习怎么学习，再构建听说读写能力，最后去下游的不同学科去拓展，机器也是先构建底层通用能力，再由通用到特殊，实现下游不同领域任务的迭代。预训练模型对下游任务的提升非常明显，在数据训练和下游应用过程中处于中心地位，已成为自然语言处理乃至整个人工智能领域的基础模型。

图 7：大规模预训练模型在多种模态数据的训练和下游任务应用中处于中心地位

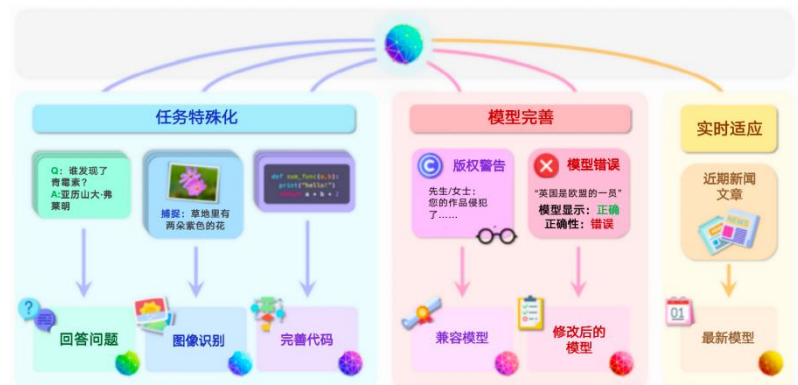


资料来源：《On the Opportunities and Risks of Foundation Models》，Rishi Bommasani, Drew A. Hudson 等，上海证券研究所

### 1.3 下游任务：知识迁移调试，实现垂直领域微调适配

下游任务，即知识迁移调试，指的是将已有的预训练模型更快更好的迁移到下游应用上。下游任务是将预训练模型应用于特定的处理任务中的步骤，通过将预训练模型中学习到的语言信息和特征推广到下游任务中，可以极大地提高自然语言处理系统的性能和效率。常见的下游任务包括文本分类、命名实体识别、关系抽取、机器翻译等多种任务。这些任务通常涉及从文本获取信息的不同方面，例如分类、实体识别、关系确定等。

图 8：基础模型将转换为适应模型以反映更新的信息、期望的行为或部署约束



资料来源：《On the Opportunities and Risks of Foundation Models》，Rishi Bommasani, Drew A. Hudson 等，上海证券研究所

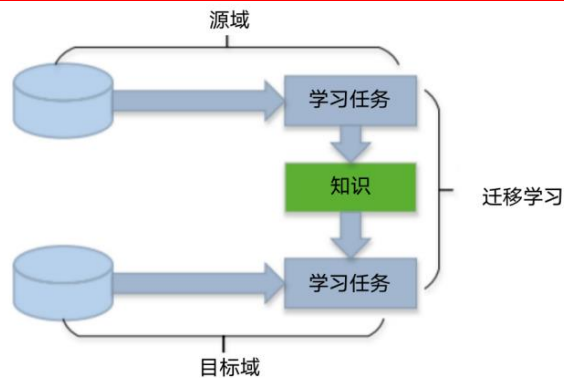
迁移学习侧重于跨领域的知识转移，通过将经验泛化达到迁移的目的。迁移学习（Transfer Learning）侧重于转移跨领域的知识，是一种很有发展前景的机器学习方法，概念最初来自于教育心理学，根据心理学家提出的转移泛化理论，学习转移是经验泛



化的结果。作为一种机器学习方法，其普遍应用场景就是把为任务 A 开发的模型作为初始点，重新使用在为任务 B 开发模型的过程中。

**迁移学习可以更好地复用已经训练好的模型参数，降低技术门槛。**人类具备在任务间迁移知识的内在能力，在学习一件任务时获取的知识，可以用来解决相关任务。任务越相关，人类迁移（交叉运用知识）起来越容易，迁移学习与之类似。上游大规模的预训练模型配合下游任务的知识迁移调试，是自然语言处理正在形成的新的技术范式。这种范式的出现也带来更高的灵活性，通过将整体任务拆分成序列到序列的范式，大大降低了技术门槛。

图 9：迁移学习的过程



资料来源：《A Survey on Deep Transfer Learning》，Chuanqi Tan, Fuchun Sun 等，上海证券研究所

具体来看，通过迁移学习将预训练模型所学到的知识迁移并适配到下游任务需要三个步骤：分别是上游任务的训练、挑选恰当的网络层，以及确定迁移方法。

1) **第一步，上游任务的训练。**在训练预训练模型阶段，要综合考虑预训练任务、模型架构与语料库的数据分布对于最终知识迁移效果的影响。

2) **第二步，挑选恰当的网络层。**在一个特定的预训练模型中，不同的网络层应当抓取对应的信息。一般而言有三种方法可以指导挑选网络层，一是只选已经经过预训练的静态 Embedding 层，其余的网络层则需要从零开始对下游任务进行训练；二是选取最高的网络层来输入到下游任务模型中，这是一种通常最简单有效方案；三是综合考虑全部层级的知识，通过权重融合来输入下游任务模型中，如 ELMo。

2) **第三步，确定迁移方法。**一般来说分为微调和特征提取两种，他们的主要区别在于预训练模型的参数是否被冻结，特征提取对应参数被冻结情况下的迁移，而微调则是参数不被冻结且可以调整情况下的迁移。特征提取方法的本质就是把预训练模型当成一个特征提取器来作用于下游任务，但这意味着针对特定的下游任务需要构建复杂的特定架构。

我们认为，预训练大模型将更多的资源和数据转移到上游，海量数据训练的大模型提供给各个业务，只需要用很少的标注数据微调，就可以取得较好的效果，从而降低了业务的使用成本；

请务必阅读尾页重要声明

小样本学习可以提升模型迭代的速度，从而在垂直领域实现快速迁移。这种“大模型+小样本”的学习能力也是人工智能追求的目标之一，即通用人工智能，并逐步走向以 NLP 为核心的产业化革命。

## 2 风险提示

宏观经济风险、地缘政治风险、GPT 与应用结合表现低于预期、AIGC 行业发展不及预期等。

### 分析师声明

作者具有中国证券业协会授予的证券投资咨询资格或相当的专业胜任能力，以勤勉尽责的职业态度，独立、客观地出具本报告，并保证报告采用的信息均来自合规渠道，力求清晰、准确地反映作者的研究观点，结论不受任何第三方的授意或影响。此外，作者薪酬的任何部分不与本报告中的具体推荐意见或观点直接或间接相关。

### 公司业务资格说明

本公司具备证券投资咨询业务资格。

### 投资评级体系与评级定义

<b>股票投资评级：</b>	分析师给出下列评级中的其中一项代表其根据公司基本面及（或）估值预期以报告日起 6 个月内公司股价相对于同期市场基准指数表现的看法。
买入	股价表现将强于基准指数 20%以上
增持	股价表现将强于基准指数 5-20%
中性	股价表现将介于基准指数±5%之间
减持	股价表现将弱于基准指数 5%以上
无评级	由于我们无法获取必要的资料，或者公司面临无法预见结果的重大不确定性事件，或者其他原因，致使我们无法给出明确的投资评级
<b>行业投资评级：</b>	分析师给出下列评级中的其中一项代表其根据行业历史基本面及（或）估值对所研究行业以报告日起 12 个月内的基本面和行业指数相对于同期市场基准指数表现的看法。
增持	行业基本面看好，相对表现优于同期基准指数
中性	行业基本面稳定，相对表现与同期基准指数持平
减持	行业基本面看淡，相对表现弱于同期基准指数
相关证券市场基准指数说明：A 股市场以沪深 300 指数为基准；港股市场以恒生指数为基准；美股市场以标普 500 或纳斯达克综合指数为基准。	

#### 投资评级说明：

不同证券研究机构采用不同的评级术语及评级标准，投资者应区分不同机构在相同评级名称下的定义差异。本评级体系采用的是相对评级体系。投资者买卖证券的决定取决于个人的实际情况。投资者应阅读整篇报告，以获取比较完整的观点与信息，投资者不应以分析师的投资评级取代个人的分析与判断。

### 免责声明

本报告仅供上海证券有限责任公司(以下简称“本公司”)的客户使用。本公司不会因接收人收到本报告而视其为客户。

本报告版权归本公司所有，本公司对本报告保留一切权利。未经书面授权，任何机构和个人均不得对本报告进行任何形式的发布、复制、引用或转载。如经过本公司同意引用、刊发的，须注明出处为上海证券有限责任公司研究所，且不得对本报告进行有悖原意的引用、删节和修改。

在法律许可的情况下，本公司或其关联机构可能会持有报告中涉及的公司所发行的证券或期权并进行交易，也可能为这些公司提供或争取提供多种金融服务。

本报告的信息来源于已公开的资料，本公司对该等信息的准确性、完整性或可靠性不作任何保证。本报告所载的资料、意见和推测仅反映本公司于发布本报告当日的判断，本报告所指的证券或投资标的的价格、价值或投资收入可升可跌。过往表现不应作为日后的表现依据。在不同时期，本公司可发出与本报告所载资料、意见或推测不一致的报告。本公司不保证本报告所含信息保持在最新状态。同时，本公司对本报告所含信息可在不发出通知的情形下做出修改，投资者应当自行关注相应的更新或修改。

本报告中的内容和意见仅供参考，并不构成客户私人咨询建议。在任何情况下，本公司、本公司员工或关联机构不承诺投资者一定获利，不与投资者分享投资收益，也不对任何人因使用本报告中的任何内容所引致的任何损失负责，投资者据此做出的任何投资决策与本公司、本公司员工或关联机构无关。

市场有风险，投资需谨慎。投资者不应将本报告作为投资决策的唯一参考因素，也不应当认为本报告可以取代自己的判断。