

ChatGPT大模型技术与应用

夏润泽^{1,2}, 李丕绩^{1,2}

(1. 南京航空航天大学计算机科学与技术学院, 南京 211106; 2. 模式分析与机器智能工业和信息化部重点实验室 (南京航空航天大学), 南京 211106)

摘要: 通过回顾深度学习、语言模型、语义表示和预训练技术的发展历程, 全面解析了ChatGPT的技术渊源和演进路线。在语言模型方面, 从早期的N-gram统计方法逐步演进到神经网络语言模型, 通过对机器翻译技术的研究和影响也催生了Transformer的出现, 继而又推动了神经网络语言模型的发展。在语义表示和预训练技术发展方面, 从早期的TF-IDF、pLSA和LDA等统计方法发展到Word2Vec等基于神经网络的词向量表示, 继而发展到ELMo、BERT和GPT-2等预训练语言模型, 预训练框架日益成熟, 为模型提供了丰富的语义知识。GPT-3的出现揭示了大语言模型的潜力, 但依然存在幻觉问题, 如生成不可控、知识谬误及逻辑推理能力差等。为了缓解这些问题, ChatGPT通过指令学习、监督微调、基于人类反馈的强化学习等方式在GPT-3.5上进一步与人类进行对齐学习, 效果不断提升。ChatGPT等大模型的出现, 标志着该领域技术进入新的发展阶段, 为人机交互以及通用人工智能的发展开辟了新的可能。

关键词: 自然语言处理; 语言模型; 预训练技术; ChatGPT

中图分类号: TP183 **文献标志码:** A

Large Language Model ChatGPT: Evolution and Application

XIA Runze^{1,2}, LI Piji^{1,2}

(1. College of Computer Science and Technology, Nanjing University of Aeronautics & Astronautics, Nanjing 211106, China;
2. MIIT Key Laboratory of Pattern Analysis and Machine Intelligence (Nanjing University of Aeronautics & Astronautics), Nanjing 211106, China)

Abstract: This paper comprehensively analyzes the technical origins and evolution of ChatGPT by reviewing the development of deep learning, language models, semantic representation and pre-training techniques. In terms of language models, the early N-gram statistical method gradually evolved into the neural network language models. Researches and advancements on machine translation also led to the emergence of Transformer, which in turn catalyzed the development of neural network language models. Recording semantic representation and pre-training techniques, there has been an evolution from early statistical methods such as TF-IDF, pLSA and LDA, to neural network-based word vector representations like Word2Vec, and then to pre-trained language models, like ELMo, BERT and GPT-2. The pre-training frameworks have become increasingly sophisticated, providing rich semantic knowledge for models. The emergency of GPT-3 revealed the potential of large language models, but hallucination problems like uncontrollable generation, knowledge fallacies and poor logical reasoning capability still

existed. To alleviate these problems, ChatGPT aligned further with humans on GPT-3.5 through instruction learning, supervised fine-tuning, and reinforcement learning from human feedback, continuously improving its capabilities. The emergency of large language models like ChatGPT signifies this field entering a new developmental stage, opening up new possibilities for human-computer interaction and general artificial intelligence.

Key words: natural language processing; language model; pre-training technique; ChatGPT

引 言

自然语言处理(Natural language processing, NLP)是计算机科学与人工智能领域中研究人类语言与计算机之间交互的一门学科,一直以来都是人工智能研究的热点^[1]。在过去的几十年发展中,NLP取得了显著的进展,引发了广泛的研究和应用^[2]。语言模型作为NLP的核心技术之一,在机器翻译、文本生成和语音识别等任务中都发挥着重要的作用。然而由于人类语言的复杂性和多义性以及数据和计算资源的限制,语言模型难以对大规模的语言数据和复杂的语义任务进行有效处理。近年来,随着深度学习技术的不断发展、大数据的爆炸式增长以及硬件资源的性能提升,模型规模不断扩大,其能力也得到了显著提升。

ChatGPT是由OpenAI团队研发的生成式可交互多任务大语言模型,在2022年11月30日推出后一夜之间火爆全网,仅5天内就得到百万用户注册,展现出极大的解放生产力潜质,引起各行各业广泛关注,成为AI界的热点。ChatGPT是一种基于GPT(Generative pre-trained transformer)的大语言模型,是一款由人工智能驱动和自然语言处理工具实现的系统,可以用于各种对话类应用,如问答、文本生成、摘要、翻译和代码生成等任务。

ChatGPT的成功并非一蹴而就,要全面理解ChatGPT的能力路线,需要先回顾语言模型和神经网络的发展历程,以及近年来语义表示和预训练技术带来的突破。本文旨在通过相关技术的发展脉络解析ChatGPT的技术来源,以公开学术研究的视角,基于目前可获得的技术信息,推测ChatGPT的技术原理,分析其技术特点并合理利用。由于官方未公布详细方案,本文涉及的相关推论仅供学术讨论参考。本文前两部分从语言模型和神经网络、语义表示和预训练技术的发展出发,通过这些技术的迭代过程铺垫ChatGPT的技术背景,第3部分简述InstructGPT和ChatGPT的技术原理,分析ChatGPT语言能力和交互能力的来源。面对ChatGPT带来的巨大反响,亦有必要冷静理性地审视这一AI技术的光与影。第4部分全面分析了ChatGPT的优劣,既论述了其带来的便利与机遇,也明确它的风险与挑战,并讨论其应用场景与注意事项。此外,本文也讨论了部分开源大模型,它们的公开推动着新技术的发展。总之,面对ChatGPT的兴起,既不能盲目依赖,也不应片面地否定其价值,需要以平衡的态度推动ChatGPT等AI技术向着真正造福人类的方向健康发展。

1 神经网络和语言模型

ChatGPT作为一个基于GPT的大语言模型,其技术来源与语言模型的发展密不可分,此外不断取得技术突破的神经网络也发挥着至关重要的作用。语言模型是NLP领域的重要任务之一,其目标是对于给定的文本序列进行建模,以便能够预测出一个句子或文本的概率分布。如给定句子 $S = W_1, W_2, \dots, W_k, W_i(i=1, 2, \dots, k)$ 表示单词,其概率可表示为

$$P(S) = P(W_1, W_2, \dots, W_k) = P(W_1)P(W_2|W_1) \cdots P(W_k|W_1, W_2, \dots, W_{k-1}) \quad (1)$$

语言模型的研究有着悠久的历史,在近几年来得到了快速发展,而语言模型的突破性进展离不开

神经网络的进步。本节将从语言模型出发,从传统统计语言模型 N-gram 到基于神经网络的语言模型,其中循环神经网络(Recurrent neural network, RNN)模型在神经网络的发展中具有重要作用,故本节也重点分析了学者们在 RNN 模型上的探索和创新,这对 Transformer 模型的诞生创造了许多技术前提,并在最后介绍了基于自注意力机制的 Transformer 模型。各典型模型主要创新和贡献之处如表 1 所示。

表 1 神经网络和语言模型发展历程

Table 1 Development of neural networks and language models

模型	主要创新	主要贡献
N-gram ^[3]	基于词频统计	提供基础的统计语言模型
RNN LM ^[4]	循环网络结构	建模长序列依赖的语言模型
长短时记忆(Long short-term memory, LSTM) ^[5] / 门控循环单元(Gate recurrent unit, GRU) ^[6]	门控机制	解决 RNN 梯度消失
Transformer ^[7]	自注意力机制	全局依赖建模,提升效率

1.1 N-gram 模型

早期的语言模型主要基于统计方法,通过统计文本中不同单词或字符的频率来捕捉语言中的规律。为解决统计语言模型中参数空间巨大的问题,N-gram 模型^[3]基于马尔科夫假设,认为当前词的出现仅与前 $n-1$ 个词相关,通过统计文本中相邻 n 个词的频率来估计每个词出现的概率。N-gram 数学表达如式(2)所示,其中每个参数条件概率 $P(W_k|W_{k-1}, W_{k-2}, \dots, W_{k-n+1})$ 通过极大似然估计进行计算,如式(3)所示。

$$P(S) = P(W_1, W_2, \dots, W_k) = P(W_1)P(W_2|W_1) \dots P(W_k|W_{k-1}, W_{k-2}, \dots, W_{k-n+1}) \quad (2)$$

$$P(W_k|W_{k-1}, W_{k-2}, \dots, W_{k-n+1}) = \frac{\text{count}(W_k, W_{k-1}, W_{k-2}, \dots, W_{k-n+1})}{\text{count}(W_{k-1}, W_{k-2}, \dots, W_{k-n+1})} \quad (3)$$

式中 $\text{count}(\cdot)$ 表示连续单词片断在语料中出现的总次数。

N-gram 语言模型的效果与超参数 n 有关,当 n 增大时,每个词可依赖更多的上文信息,获得更多的信息量,对未来的预测也会更加准确,然而过大的 n 会导致稀疏问题,即某些 N-gram 未在文本中出现过,使得通过极大似然估计得到的条件概率为 0,从而导致模型计算出大部分句子的概率为 0,与实际情况不符^[3,8],此外也伴随着参数个数过多、计算代价巨大等问题。为解决数据稀疏性问题,数据平滑的方法被提出,一种解决方法是无论词组出现的次数是多少,均将次数加 1 即可解决出现概率为 0 的情况,也称为拉普拉斯平滑。此外,还有 Good-Turing 平滑、Kneser-Ney 平滑和 Interpolation 平滑等平滑方式^[8]。

1.2 RNN 模型

随着深度学习的兴起,基于神经网络的语言模型(Neural network based language model, NNLM)逐渐替代了上述基于统计的语言模型。Bengio 等^[9]在 2003 年首次提出使用神经网络解决语言模型的问题,以克服 N-gram 模型参数大和稀疏等问题。为了更好地捕捉上下文信息并建模词之间的语义关系,NNLM 引入了词向量作为一种单词表示,每个单词都被映射为一个固定长度的词向量,将离散的单词转化为连续的向量表示,可以对单词的上下文信息进行有效的编码和建模^[10]。NNLM 的主要流程如下:使用 one-hot 表示前 $n-1$ 个词,将其通过投影矩阵降维后得到词向量,将它们进行拼接,并将结果输入到使用 tanh 激活函数的隐藏层中计算,可产生富含上下文信息的向量,再将该向量输入线性层中得到每个词的预测得分,最终得分使用 softmax 计算后可得到每个词的概率^[9]。NNLM 的示意图如图 1 所示。

NNLM模型使用前馈神经网络结构决定了它只能利用有限的历史上下文窗口来对下一个词的概率分布进行建模。为解决该问题, Mikolov等^[4]在2010年提出了一种基于RNN的语言模型, 在处理序列数据时通过引入循环结构来捕捉上下文信息, 能够更好地建模长距离的依赖关系, 进一步提高了模型的性能。RNN是在网络内部建立循环连接, 将当前时刻的输入与前一时刻的隐藏状态相关联, 因此RNN可以将历史信息传递至当前时刻, 并在后续时刻继续传递^[11]。然而在实际应用中, 过长的序列会导致在训练过程中由于梯度的连乘运算造成梯度爆炸或梯度消失问题, 因此利用梯度下降训练RNN的长距离依赖十分困难^[12]。梯度裁剪是一种用于解决梯度爆炸问题的方案, 在训练模型时设定一个阈值, 将所有梯度的范数控制在该阈值以下, 当超过阈值时则按照一定的比例将梯度进行缩小, 使其范数不再超过该值, 可以有效地解决梯度爆炸问题。然而, 在处理梯度消失问题时, 梯度裁剪方法并非是一种彻底的解决方案。为了从更深层次上应对该问题, 有必要调整RNN层的结构, 例如加入记忆单元以及门控机制, 实现对重要梯度信息的选择性传递。典型的解决方案是LSTM网络^[5]和GRU单元^[6], 它们可以有效地解决梯度消失问题。LSTM是Hochreiter等在1997年提出^[5], 它的核心思想是引入了输入门、遗忘门和输出门3个门。这些门通过对信息的选择性保留和删除, 使得LSTM能够有效地学习和记忆长期依赖关系。GRU由Chung等在2014年提出^[6], 同样能够缓解RNN的长期依赖问题, 它简化了LSTM的结构, 仅采用了更新门和重置门2个门。更新门决定了当前时刻的输入和过去隐藏状态之间的权重, 从而进行信息的更新, 而重置门则控制着过去隐藏状态的遗忘程度。LSTM和GRU示意图如图2, 3所示^[13], 图中 $x_i(i=t-1, t, t+1)$ 表示 i 时刻输入到RNN中的数据(即当前时刻输入的数据特征), $h_i(i=t-1, t, t+1)$ 表示 i 时刻RNN单元输出的隐状态, σ 表示进行一个线性层运算后再通过sigmoid函数激活。

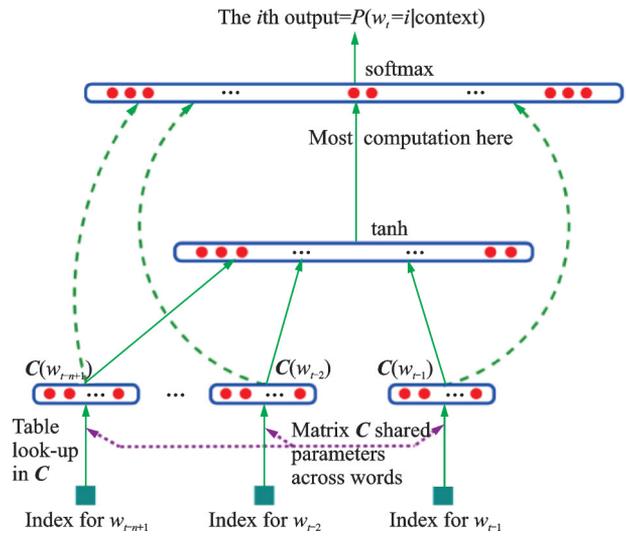


图1 NNLM示意图^[5]

Fig.1 Schematic diagram of NNLM^[5]

图2 LSTM示意图^[13]

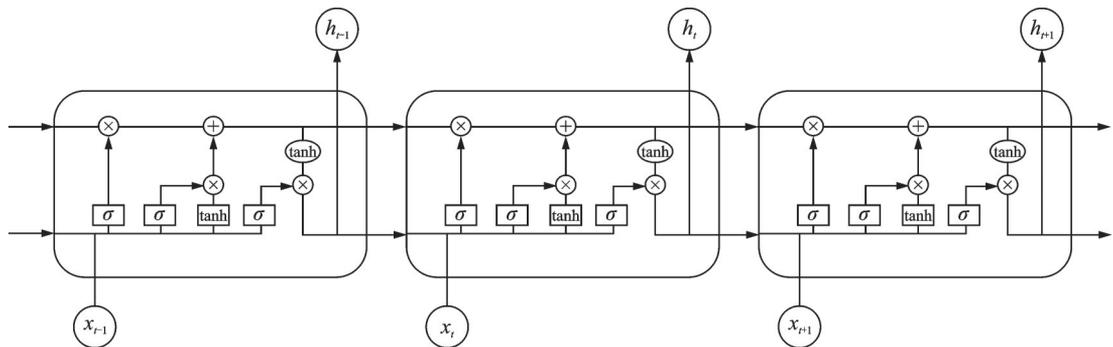


图2 LSTM示意图^[13]

Fig.2 Schematic diagram of LSTM^[13]

在计算路径增长时都或多或少面临着记忆衰退的困境,为彻底解决这一挑战,Vaswani等在前人工作启发下于2017年提出了Transformer模型^[7]。该模型是近年来取得重大突破的一种神经网络模型,采用Encoder-Decoder架构并引入Self-attention机制,极大地提升了模型性能。其中Encoder部分由Self-attention层和全连接层组成,可以并行计算捕获序列的特征,Decoder在此基础上加入Masked Self-attention层实现仅关注前文部分进行语言模型的学习。此外,Transformer通过位置编码将位置信息融入到序列中来保存词序信息。Transformer模型的架构如图4所示。

Transformer模型的核心是Self-attention机制,该机制使得模型能够关注输入序列各个位置的信息。具体而言,Self-attention机制通过将输入序列映射为相同维度的查询(Query)、键(Key)和价值(Value)向量来实现。其中,Query用于计算当前位置与序列所有位置的相关程度,Key和Value则分别用于表示其他位置的信息。通过计算Query与Key的关系,并将其作为权重对Value向量进行加权求和就可以实现根据不同位置之间的重要性自适应地整合信息,获得全局上下文感知的表示。在该计算过程中,由于每个位置的计算只取决于序列中其他位置的表示及对应的权重,即每个位置的表示是独立计算的,故可以并行地对整个输入序列的所有位置进行计算。Self-attention计算公式可以表示成式(4),其中 \mathbf{Q} 、 \mathbf{K} 、 \mathbf{V} 分别表示序列的Query、Key、Value向量构成的矩阵, d_k 表示向量映射后的维度。此外,多头注意力是Transformer中的一种扩展机制,模型可以同时从不同的表示子空间学习到更丰富的特征表示,提升模型的表达能力和泛化能力,实现更好的性能^[7]。

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}}\right)\mathbf{V} \quad (4)$$

Transformer模型在句子级语言建模任务上表现优异,成为了取代RNN的新标准。此外,得益于其可以高效利用计算资源进行并行训练,全注意力结构也可以使其更轻松地捕捉全局依赖关系,为构建更大规模的语言模型创造了优越条件,成为NLP领域中众多任务的基础。后续也相继涌现出一批如GPT-1、BERT、GPT-2和GPT-3等基于Transformer的大语言模型。

2 语义表示和预训练技术

语义表示建模是指在NLP领域中通过算法模型来捕捉和理解文本中的语义信息,目标是将文本从表面层的词汇和句法结构转化为更深层次的语义表示,以便计算机能够更好地理解文本含义并进行相关任务。语义表示关键在于构建能够将文本转化为向量表示的模型,这些表示可以捕捉到词汇、短语

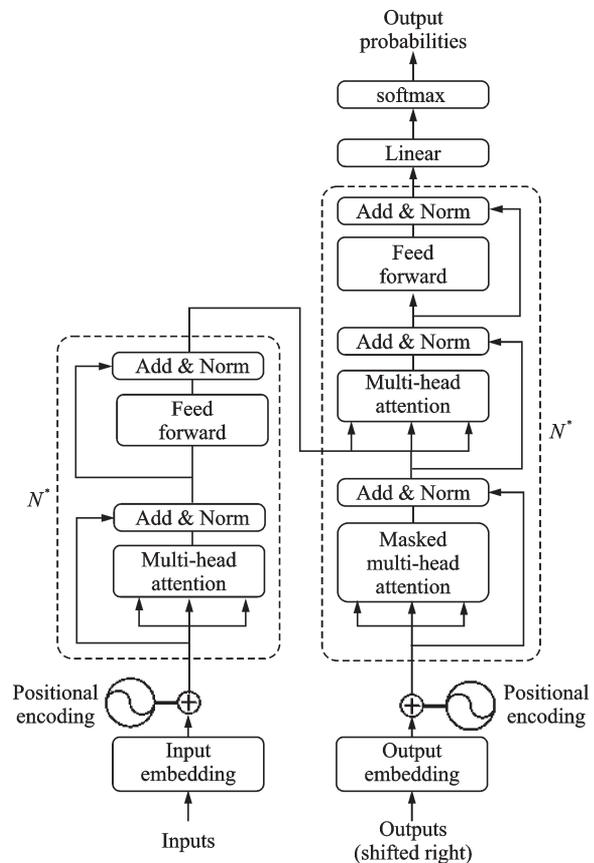


图4 Transformer架构图^[7]

Fig.4 Architecture diagram of Transformer^[7]

和句子之间的语义关系。研究者认识到直接在具体NLP任务的数据集上训练网络模型,会存在一定的局限性。近年来,随着深度学习的发展和语料数据规模的增长,研究者们开始尝试通过先在大规模语料上预训练网络模型,让模型学习丰富且统一的语义知识,并应用于下游的具体任务中。预训练微调框架也成为当今NLP领域中的重要范式。本节将从传统语义表示方法、Word2Vec以及预训练语言模型3个方面详细讲述语义表示和预训练技术的发展脉络。

2.1 传统语义表示

早期的语义表示研究主要基于统计学和词频分析方法。这些技术依赖单词之间的联合频率等统计信息揭示单词之间的关联模式,实现建模文本语义,代表性技术如下:

(1)词频-逆文本频率(Term frequency-inverse document frequency, TF-IDF)技术^[23]。该技术通过计算单词出现的频率和逆向文档频率评估单词在文本中的重要性。在互联网普及之前,主要的文本数据来源于图书等纸质文档,为从众多文档中快速找到与查询单词相关的文档,信息检索系统需要对文档进行数学表示,计算查询与文档之间的相关程度,TF-IDF因此被提出并纳入使用。尽管其计算简单,但TF-IDF存在稀疏性问题,对多义词和同义词的处理也较为困难,难以捕捉到单词间的语义信息。因此,研究者们开始将重点转向了单词背后的隐藏含义,探究单词与文档之间隐含关系,即主题关系。

(2)pLSA (probabilistic Latent semantic analysis)技术^[24]。LSA(Latent semantic analysis)^[25]是一种通过矩阵分解技术发现单词间的潜在语义相关性的方法。LSA将文本转换为矩阵,行和列分别表示为文档和单词,矩阵元素则为单词在文档中出现的频率,通过对该矩阵进行奇异值分解(Singular value decomposition, SVD),能够将文本表示为低维的向量空间模型,从而更好地处理单词的多义性和歧义性问题。然而,在处理文本语义复杂性方面,LSA存在一定的局限性,且无法直接解释主题的含义。pLSA是对LSA的改进,它假设文档和单词之间的生成过程受一组潜在的主题影响。在该方法中,文档以一定的概率选择特定的主题,同时主题也是一组单词的概率分布,从而将文档、主题和单词联系起来。通过引入概率模型,pLSA可以更好地解释文本的生成过程。然而作为一种生成模型,pLSA在生成新文档时由于无法确定主题分布,就无法利用已学习的参数生成完整的新文档,尽管可以通过生成词语序列或基于主题的填充等方法进行间接生成,但这些方法存在缺陷,无法捕捉到新文档的复杂性和多样性。此外,pLSA对数据的依赖较强,容易出现过拟合问题,这也限制了它被更广泛地使用。

(3)LDA(Latent Dirichlet allocation)技术^[26]。为了能够在生成新文档时更加准确灵活,LDA作为一种更高级的语义表示技术被提出。与pLSA相似,LDA也是一个概率生成模型,但LDA使用了贝叶斯统计方法,为主题分布引入了Dirichlet先验分布。通过采样方法学习Dirichlet参数,LDA可以挖掘单词与主题之间的关系,使主题含义更加明确建模语义信息。在生成新文档时,LDA也可以根据先验分布采样得到文档的主题分布,根据主题分布再生成词语,这样获得的新文档更能反映真实的数据分布。这种生成过程也使LDA对数据的依赖较小,避免了过拟合问题,同时LDA也成为一种重要的概率主题模型,被广泛应用于文本主题分析、信息检索和推荐系统等领域。LDA示意图如图5所示,图中 M 表示语料中文档个数; N 表示当前文档中单词个数; K 表示总的主题数,由用户确定; φ 表示当前主题的词表分布; β 表示用户设置的超参数,为 φ 的先验分布参数; θ 表示当前文档的主题分布; α 表示用户设置的超参数,为 θ 的先验分布参数; Z 表示从分布 θ 中采样出的一个主题; W 表示从分布 φ 中采样出的单词。

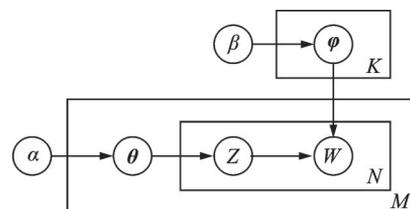


图5 LDA示意图^[26]

Fig.5 Schematic diagram of LDA^[26]

上述统计语义表示方法为后续的发展奠定了基础,但这些方法在处理词语的多义性、语义相关性等方面表示能力有限,在进一步提升语义表示能力上还面临着挑战。

2.2 Word2Vec

在深度学习技术不断发展的背景下,不少研究者试图使用神经网络实现语义表示建模,2013年由Google团队提出的 Word2Vec^[27-28],标志着基于神经网络的词向量表示方法的出现,引发了NLP领域对词嵌入的广泛研究,推动了语义表示的快速发展。

Word2Vec是一种用于学习词嵌入的技术,能够将单词映射到低维连续向量空间中的向量表示,在NLP任务中具有很强的表达能力。Word2Vec主要包含两种模型结构:CBOW (Continuous bag of words)模型和Skip-Gram模型,它们通过在大规模语料上进行无监督预训练,获得富有语义信息的词向量表示。具体来说, CBOW模型是根据目标词的上下文单词预测当前词, Skip-Gram模型则是给定目标词预测其上下文,两种模型都是通过邻近单词的预测获得词向量的表示。Word2Vec两种经典结构如图6所示,图中 w 表示词向量,与传统词袋模型表示不同, Word2Vec学习到的词向量在向量空间中反映了单词间的语义关系和上下问信息,语义相似的单词通常在向量空间中距离较近,这些经预训练学习到的词向量表示可以被应用于各种具体的NLP任务中^[27-28]。

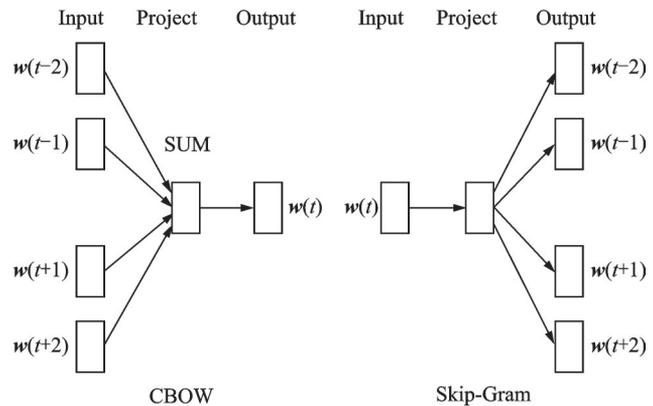


图6 Word2Vec示意图^[27]

Fig.6 Schematic diagram of Word2Vec^[27]

Word2Vec开创了基于神经网络的词嵌入新方向,引发NLP领域中对词向量表示的广泛研究,为后续的预训练技术积累了经验。然而,尽管Word2Vec在提出时是一项重要的突破,但它在某些方面存在一些局限性。例如,由于Word2Vec将每个单词表示成唯一的向量,无法处理词汇的多义性问题,并且在处理语料库中未出现过的新词汇及出现频率较低的单词时也存在困难。此外,Word2Vec主要关注单词级别的语义关系而无法捕捉到短语或句子级别的语义关系。其次,Word2Vec预训练后词向量不可改变,无法充分适应不同的下游任务。预训练语言模型的出现则为上述问题提供了一个更加全面的解决方案。

2.3 预训练语言模型

在发现Word2Vec通过神经网络学习词向量的优势后,研究者们开始考虑能否应用神经网络模型学习更全面的语言表示,于是使用语言模型进行预训练的思路被提出。

2015年,Dai等^[29]提出语言模型预训练并迁移学习到下游任务的思想,该工作使用基于单向LSTM的神经网络模型,在未标注的文本语料上进行无监督预训练得到语言模型,将预训练的语言模型作为固定的特征提取器,用于下游的监督学习任务中,只通过微调输出层处理具体的任务。这种由无监督预训练带来的先验语言知识,在特定任务上进行监督微调的方式,验证了预训练语言模型的有效性。在此基础上,Peters等^[30]提出更深层次的双向LSTM结构ELMo以进一步增强上下文的词向量表示。ELMo在输入层通过字符嵌入获得字符级表示,进一步得到词向量,基于双向LSTM训练前向和后向两个语言模型,并分别从两个模型中提取特征向量,经过一定的权重融合得到包含前后向信息的词向

量表示。值得注意的是,ELMo的前向和后向LSTM分开训练,无法同时获取完整的上下文信息,并非真正意义上的双向。此外,与Word2Vec和GloVe等静态词嵌入方式不同,ELMo的词嵌入是上下文相关的,同一个词在不同的上下文中可以有不同的嵌入,使得ELMo能够捕获词义消歧、词形变化等相对复杂的语言现象,在多个任务上都超过了先前的SOTA模型,进一步展示了使用预训练语言模型进行语义表示的巨大潜力^[30]。

随着研究者们对预训练语言模型进行的进一步的探索和改进,且受到Transformer模型在机器翻译领域的启发,OpenAI于2018年提出了GPT模型^[31],GPT在Transformer的基础上进行改进,以专注于进行单向的语言模型预训练。受益于Transformer的Self-attention机制和并行训练优势,GPT与基于LSTM的预训练相比,能够拥有更大的参数规模和更出色的语言理解能力,显著提升了文本生成的质量,在众多数据集和任务中大幅度超过了SOTA。GPT模型证明了以Transformer为基础的预训练-微调框架对于提升多种NLP任务非常有效,它的成功离不开Transformer处理长期依赖的优势,以及大规模无监督预训练带来的语言理解的全面提升。

然而,GPT的单向设计虽然能够降低预训练的难度,但人类对语言的理解往往是双向进行的,Google也因此提出了双向预训练的BERT(Bidirectional encoder representations from transformers)模型^[32]。BERT采用Transformer Encoder进行双向的语言理解预训练,预训练任务是通过掩码语言建模和句子关系检测学习语言表示,能够同时获取单词左侧和右侧的上下文信息,生成更全面的双向特征表示。掩码语言建模就是按照一定概率屏蔽输入序列中的单词,再预测被屏蔽掉的词,句子关系检测则是判断两个句子是否是同一含义。相较于单向的GPT模型,BERT的双向预训练可以获取更丰富的上下文表示,但面临着计算更复杂,对数据量和技巧也更敏感的问题,后续出现一批工作致力于提升BERT的训练稳定性。BERT模型的预训练数据集包括Books Corpus(约800M词)和Wikipedia(约2.5B词),并提供了2种规模的模型,其中Base模型包含12个Transformer层和110M参数,Large模型包含24个Transformer层,参数量也达到了340M^[32]。

增大模型规模和数据规模带来的效果提升启发OpenAI在2019年发布了GPT-2^[33]。GPT-2是GPT系列基础上的进一步发展,采用了更大的模型规模和更丰富的数据集进行预训练,其中最大规模的GPT-2模型包含1542M参数,预训练数据集为爬取自互联网的高质量文本数据集WebText(约40GB文本),规模增大的同时也增加了多样性,使得GPT-2学习到更广泛的语言知识和语境,在生成文本方面表现出更高的创造力和语言理解能力。GPT-2展示出了无需进行微调就可直接应用于下游NLP任务的zero-shot能力,仅使用预训练参数就在阅读理解和文本分类等任务上达到了不错的效果,证明预训练语言模型提取语义特征的通用性。GPT-2通过训练4组不同规模和词向量长度的模型,也进一步验证了模型效果随着模型的增大在不断提升,图7为不同规模GPT-2模型在不同zero-shot任务上的测试结果^[33]。

伴随着硬件的发展以及参数量对模型能力提升的启发,OpenAI研究团队斥巨资在2020年发布GPT-3^[34]。与前代结构相似,GPT-3在模型参数量上实现了飞跃,最大模型达到1750亿参数,是GPT-2的百倍以上,同时也使用了更大规模的数据集进行预训练,包含过滤后的Common Crawl、扩展的WebText、基于互联网的书籍语料库和英文Wikipedia。超大规模的GPT-3在阅读理解、翻译和推理等任务上效果惊人,在生成任务上也能够生成连贯的段落。然而在生成长文本时GPT-3存在诸多问题,如生成内容的一致性和准确性难以保证,倾向于生成误导性或有害的内容,缺乏常识和判断力,易生成不切实际甚至荒谬的建议等,即GTP-3在许多问题上不可控,难以满足人类的需求。为解决这些问题,让语言模型更准确地按照人类的指令输出,指令学习和用户反馈机制变得尤为重要,如通过监督学习和用户反馈优化模型与人类对齐,提升模型对指令的理解能力,使模型能够输出更符合人类期望的结果^[35]。

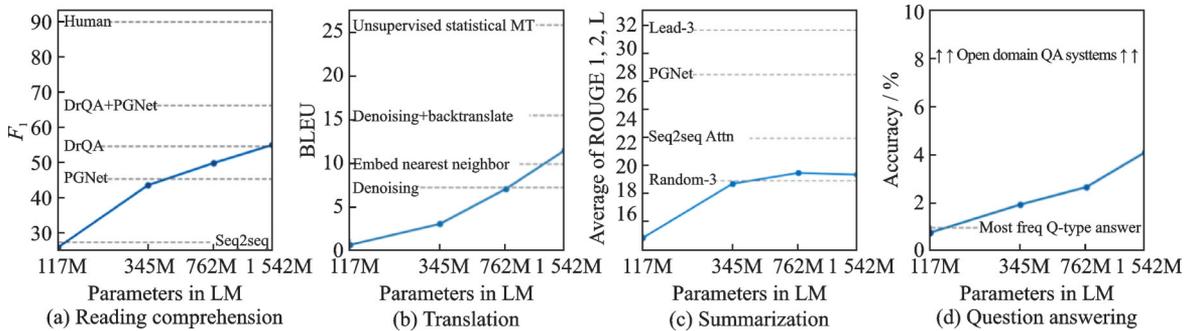


图7 GPT-2在不同任务上的不同规模模型对比^[33]

Fig.7 Comparison of different scale models of GPT-2 on different tasks^[33]

3 InstructGPT 和 ChatGPT

InstructGPT 是 OpenAI 于 2022 年发布的基于 GPT-3 的语言模型,其目的是让语言模型能够更准确地执行人类命令,生成符合人类期望的输出。相比 GPT-3 追求模型规模的扩增,InstructGPT 则更关注提升模型对指令的理解力^[35]。而 ChatGPT 的出现标志着超大规模语言模型成功落地到互动式对话领域,取得更高质量的问答交互和语言理解生成能力,对推进人机智能对话,实现真正智能、交互和可用的对话系统具有重要意义。作为兄弟模型,ChatGPT 在实现流程上与 InstructGPT 一致,由于官方未公布 ChatGPT 论文和其实现细节,本节则在公开研究信息范围内,通过 InstructGPT 采用的技术讨论 ChatGPT 可能采用的提供语义理解和交互能力的相关技术,其中监督微调(Supervised fine-tuning, SFT)可利用对话数据集进一步优化预训练模型在对话任务上的表现,基于人类反馈的强化学习(Reinforcement learning from human feedback, RLHF)能够向模型注入人类偏好,与人类对齐^[35]。ChatGPT 流程如图 8 所示^[36]。

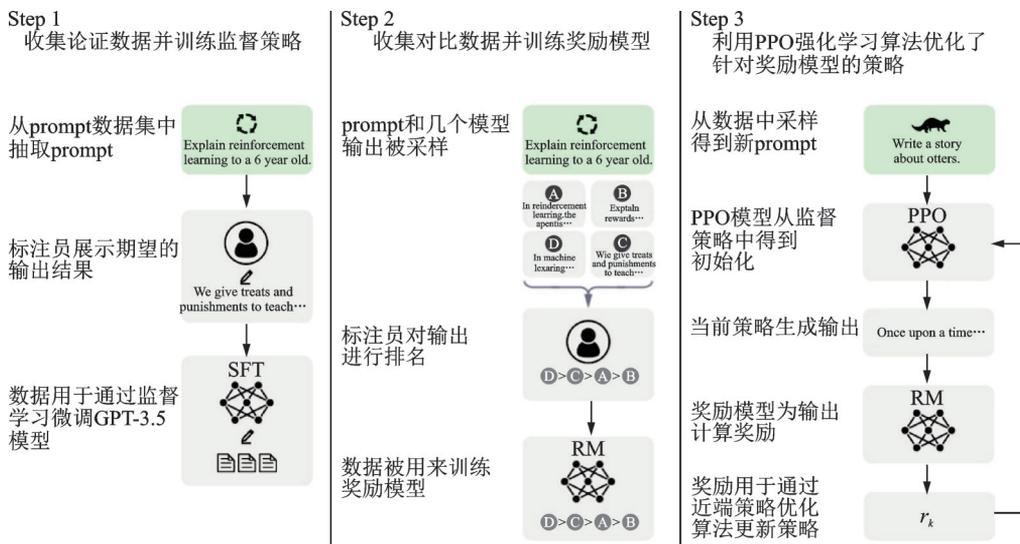


图8 ChatGPT 训练流程^[36]

Fig.8 Training process of ChatGPT^[36]

3.1 监督微调

在获得通用语言特征的基础上,InstructGPT 以 GPT-3 系列的模型为基础,使用对话交互数据集对

模型进行有监督微调,这是实现对话生成能力的关键一步。监督微调使用真实的人机对话数据,将预训练语言模型继续针对人机对话这一具体任务进行更新优化。

具体来说,Open AI雇佣人工团队对一个prompt数据集进行标注(prompt数据集来源:OpenAI API收集和OpenAI雇佣标注员撰写),即根据prompt撰写一系列的回复作为模型的期望输出,建立起一个有监督的数据集。其中prompt是指使用语言模型生成文本时为其提供的提示信息^[31]。使用标注好、有监督的对话数据对GPT-3模型进行微调,得到监督微调SFT模型。在大量高质量对话数据的驱动下,InstructGPT逐步学习到对话中的各种语法和语用规律知识,清晰把握人类交互对话的多种模式,能够更好地遵循人类的指令^[35]。相比预训练获得的通用语言特征,监督微调提供了直接面向目标任务学习语言表达能力的机会,能够利用好预训练模型的参数和结构避免从头开始训练,并提高模型在对话任务上的表现,使模型能够从人类对话数据中获得预训练难以触及的对话语用知识,如问答连贯、语用推理等方面。在大量真实对话数据的驱动下,模型逐步习得对话的各种语法和语用模式。

3.2 基于人类反馈强化学习

强化学习是机器学习中的一个重要分支,它不需要完整的监督数据,而是通过智能体与环境的相互作用来学习最优策略,通常包含环境、智能体和奖励3个要素^[37]。智能体会根据环境采取动作,环境会根据动作给予奖励,智能体通过积累最大化奖励学习最优策略。在SFT的基础上,InstructGPT采用了强化学习算法来进一步提升对话回复的质量,为能够得到与人类预期相符合的输出,与人类的理解、对话方式对齐,需要训练一个能够反应人类期望并对回答进行评估的奖励模型,这种强化学习包含了带人工操作的奖励,称为RLHF。

在RLHF过程中,需要先使用SFT模型生成回答的人工排序数据集训练奖励模型。具体来说,对于从问题库中挑选出的问题 x ,令SFT模型生成该问题的 K 个不同回答,人工地对这 K 个回答按照从好到坏的顺序进行排序,利用排序结果来训练奖励模型,即目标损失函数中包含了排序结果的信息,即最大化两个回答之间的奖励差距,损失函数为

$$\text{loss}(\theta) = -\frac{1}{C_K^2} E_{(x, y_w, y_l) \sim D} \left[\ln \left(\sigma \left(r_\theta(x, y_w) - r_\theta(x, y_l) \right) \right) \right] \quad (5)$$

式中: C_K^2 表示从 K 个回答中任选两个进行比较的可能数量; y_w 表示对于问题 x 较好的回答; y_l 则是相对较差的回答; $r_\theta(x, y_w)$ 和 $r_\theta(x, y_l)$ 分别表示在参数 θ 下,对问题 x 和回答 y_w 和 y_l 的评分; D 表示人类排序数据集^[35]。

奖励模型选择对答案进行人工排序而不是人工评分的原因在于评分操作的主观性较强,即使提供了规定的评分标准,对于相同的回答,不同的人也难以给出相同的评分,即给生成的文本直接评分是一件不容易衡量的工作,而对不同的答案进行好坏的排序相对容易得多。

通过上述训练可以得到一个奖励模型,能够替代人类对SFT新的回答做出奖赏,这种奖励模型包含着人类期望的对话交互质量特征。最后,利用近端策略优化(Proximal policy optimization, PPO)算法和奖励模型不断进行强化学习迭代,选择拥有最高奖励得分的模型即可认为得到拥有人类偏好的对话模型。在训练过程中,PPO目标函数为

$$\text{objective}(\phi) = E_{(x, y) \sim D_{\pi_\phi^{\text{RL}}}} \left[r_\theta(x, y) - \beta \ln \left(\frac{\pi_\phi^{\text{RL}}(y|x)}{\pi^{\text{SFT}}(y|x)} \right) \right] + \gamma E_{x \sim D_{\text{pretrain}}} \left[\ln \left(\pi_\phi^{\text{RL}}(x) \right) \right] \quad (6)$$

式中: π_ϕ^{RL} 表示待学习的策略,初始设置为 π^{SFT} ; D_{pretrain} 表示预训练分布; x 表示PPO数据集中的prompt,对于每个prompt,根据当前策略生成回复 y ,将 (x, y) 输入上一步训练出的奖励模型中计算分数,经过训练使得最大化 $r_\theta(x, y)$ 。随着模型不断更新,PPO模型与SFT模型差异将逐渐变大,为防止二者输出差异过大,在目标函数中加入了KL散度 $\beta \ln \left(\frac{\pi_\phi^{\text{RL}}(y|x)}{\pi^{\text{SFT}}(y|x)} \right)$ 。此外,预训练模型的目标

$\gamma E_{x \sim D_{\text{pertain}}} \left[\ln \left(\pi_{\phi}^{\text{RL}}(x) \right) \right]$ 被加入到目标函数中,避免模型只能对排序数据集产生较好结果而在通用 NLP 任务中性能下降。

ChatGPT 与 InstructGPT 训练流程一致,均采用了监督学习和基于人类反馈强化学习,主要区别可能在于训练时采用的语料,导致了模型用途上的差别。

3.3 ChatGPT 评估

ChatGPT 展现出的强大能力,引发了不少研究者开展对 ChatGPT 的评测,以更具体且准确地探究其性能。Qin 等^[38]针对 ChatGPT 零样本学习能力进行评估,在 20 个涵盖 7 个代表性任务的数据集上进行实验分析,发现 ChatGPT 在多个任务上显著优于 GPT-3.5 等模型。其中在算数推理任务中,ChatGPT 在 6 个数据集的测试上有 5 个性能优于 GPT-3.5,ChatGPT 在使用了 Chain of Thought(CoT)^[39]技术的对比中获得更大提升,但在解决如序列标记等问题上仍存在挑战。Zhong 等^[40]在 GLUE 基准^[41]上对 ChatGPT 进行评估,探究其语言理解能力。该工作发现 ChatGPT 能够在推理任务上显著优于多个 BERT 模型,在情感分析和问答上性能相当,但在处理转述和相似性任务中存在不足。其中,在使用标准零样本和少样本 CoT 技术时 ChatGPT 整体性能提升 5.1% 和 5.0%,超越除 RoBERTa-large^[42]外绝大多数 BERT 族模型。Yang 等^[43]为探索 ChatGPT 在基于查询的摘要等实际任务上的性能,在 4 个基准数据集上进行评估。实验表明,ChatGPT 性能能够与传统微调方法相当,且在新闻领域的 NEWTS 数据集上 ROUGE 指标全面优于传统微调方法。

中文通用大模型综合性基准 SuperCLUE^[44] 排行榜如图 9 所示,可以看出作为榜单中最早发布的模型,ChatGPT(即 GPT-3.5-turbo)综合性性能仍能够排行前列。

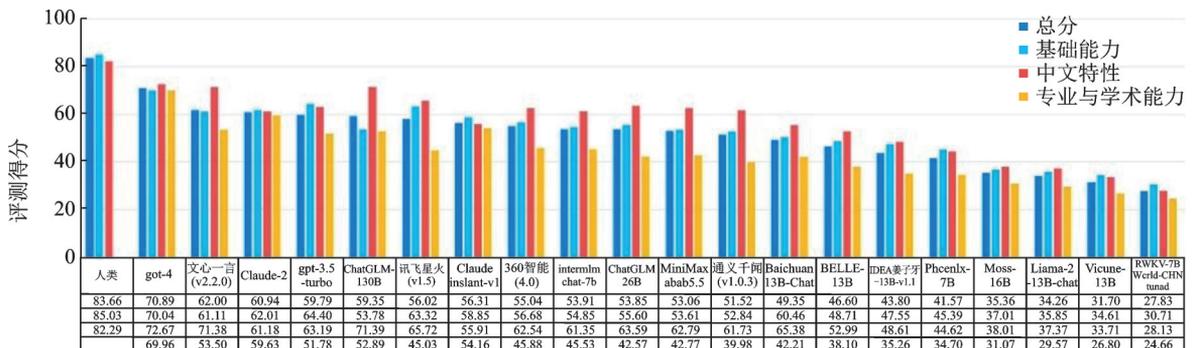


图9 SuperCLUE 7月榜单^[44]

Fig.9 Ranking of SuperCLUE in July^[44]

4 ChatGPT 的优劣与应用

鉴于 ChatGPT 的火爆带来的巨大关注,对其进行客观理性的分析评估尤为重要。本节将从多个角度剖析 ChatGPT 的长处与不足,既要看到 ChatGPT 等大模型带来的机遇,也要明确它存在的局限性与风险^[45],还需要审慎考虑 ChatGPT 的应用场景与注意事项,以推动该技术的健康发展。

4.1 优势

ChatGPT 作为新兴的预训练语言模型对话系统,能够理解自然语言并进行问答。主要优势如下:

(1) 强大的语言处理能力:ChatGPT 拥有接近人类的语言理解和生成能力,在语义、语法及语用方面均达到较高水平,能够与用户进行逻辑清晰且上下文协调的多轮对话^[46]。

(2) 便捷的交互方式:ChatGPT 采用对话方式与用户进行交互,自动化程度高,用户可在任意时间

和地点对其进行访问,且ChatGPT能够及时响应用户,方便用户解决问题、获取信息。

(3) 广博的知识覆盖:ChatGPT训练的语料覆盖极广,包含百科、文献、书籍及新闻等多个领域,模型能够从上述预料中学习到丰富的知识。因此,用户能够在较大范围中查询到自身所需的知识。

(4) 高度的智能化程度:ChatGPT能够模拟人类智能,进行复杂的语义理解、逻辑推理和知识应用,在理解用户意图、知识链接等方面较早期AI系统更加智能。

4.2 劣势

在充分肯定ChatGPT优势与价值的同时,也应正视其存在的缺陷和不足,防止利用不当造成危害。ChatGPT的劣势主要如下:

(1) 幻觉与可靠性问题:ChatGPT生成问题的真实性和可靠性难以保证,会生成虚假信息或对知识盲区进行貌似合理的错误回答。Guo等^[46]通过构建人类专家和ChatGPT的回答对比数据集HC3,并发现ChatGPT有时会捏造事实来回答问题。

(2) 隐私泄露风险:为进一步更新模型并提升性能,OpenAI将会在用户与模型的交互中收集用户信息来改进模型,用户与模型的交互信息可能会被记录至数据库中,导致用户的隐私信息泄露。

(3) 偏见、敏感及有害的言论:ChatGPT可能会生成带有偏见、敏感性和有害内容,在错误引导下会放大训练数据中的有害信息,生成不当内容。Deshpande等^[47]对ChatGPT生成的语言进行了大规模且系统的毒性分析。结果表明,当为ChatGPT分配角色时,可能会生成明显的有毒或偏见信息,在对待弱势群体时尤为严重。

(4) 逻辑推理能力较弱:ChatGPT拥有推理能力,然而在面对复杂逻辑推理或模糊问题时,ChatGPT可能无法准确理解或进行推理。Liu等^[48]分别在传统基准和新发布的基准上对ChatGPT进行逻辑推理分析,发现尽管在传统基准测试中表现较好,但处理新发布的基准数据集时面临较大挑战,表明其推理能力存在缺陷。

(5) 部署困难:作为千亿参数级别的大模型,ChatGPT的开发、运行耗费资源极大,训练和部署需要大规模算力支持,难以按照个人需求部署私人助理和垂直领域应用。因此,后续出现的大语言模型研究也将重心放在了缩小模型和降低模型部署成本上。

4.3 应用场景

在对ChatGPT技术和优劣势分析后,需要通过其应用场景的合理设计来发挥其应用价值,并防范其负面危害。下面介绍ChatGPT典型应用情况,旨在推进其合理利用。

(1) 内容辅助创作:用户可利用ChatGPT辅助完成各种内容的生成,用户列举创作要求,ChatGPT可根据要求快速生成文章草稿、广告、邮件、代码等内容,可大幅度提升用户内容创作效率,如ChatGPT能够为学生提供个性化学习反馈,自动生成总结等,为教育和学习提供便利^[49]。但由于ChatGPT有时会捏造事实,因此需要用户对其内容进行审查和筛选。

(2) 智能客服:ChatGPT可用来自动响应用户查询,即充当智能客服机器人,根据用户问题做出指导和解答。如使用ChatGPT等大模型替代企业中的人工客服,并能够根据用户反馈及时响应,较传统客服机器人更加智能,能够更高程度地解决用户问题并降低企业成本。但需要对其回复进行指导和监控,防止产生无效或有害言论,造成不必要损失。

(3) 私人助理:ChatGPT可充当私人智能助理,协助生活。如用户可通过将需求告知模型,并按照给定要求完成日程规划、进行信息查询等功能,但需注意个人隐私安全。

(4) 检索知识:ChatGPT丰富的知识面可用于检索需要的信息,或在专业领域内进行使用,如:在金融领域内分析市场走势并提供建议;在法律领域内提供法律咨询服务,给予解决建议;医疗领域内提

供健康咨询,或辅助医生提高诊断效率。由于 ChatGPT 存在的幻觉问题,需要注意在使用时对其内容进行判断。

值得一提的是, Park 等^[50]利用 ChatGPT 构建了模拟人类真实生活的 AI 小镇。其中该工作提出了生成式智能体,它们充当小镇成员,能够按照自己意愿规划自己的行为,且每个智能体均拥有与环境交互的记忆系统。该工作推动了 AI 智能体的发展和人们对大模型潜在应用场景的探索,也因其趣味性引发了广泛讨论。

得益于其优越性能, ChatGPT 为人们提供了许多便利,但它带来的问题不可忽视。加强对 ChatGPT 的管控必不可少,需避免 ChatGPT 等大模型的不当使用产生虚假信息,造成虚假信息和欺诈信息泛滥。同时要加强用户对用户信息的隐私保护,防止用户敏感信息泄露。此外, ChatGPT 易产生有害信息和幻觉问题也值得关注,如何减少 ChatGPT 等大模型生成有害、歧视信息,以及如何提升大模型生成内容的准确性,将是发展道路上的重要挑战。

5 开源大模型

ChatGPT 的成功引发了一波大语言模型的浪潮,研究者和企业争先开发自己的模型,其中不少参与者也将模型进行开源供学术研究。这些开源大模型推动着大语言模型的研究进程,使大语言模型在几个月内得到了飞速发展。本节将简要介绍在 ChatGPT 发布后国内外研发的部分开源大模型。

5.1 LLaMA 模型

LLaMA^[51]是 Meta AI 在 2023 年 2 月提出的一个系列模型,旨在为研究者们提供高质量的预训练语言模型,被誉为最强大的开源大模型。LLaMA 包括了参数量 7B、13B、33B 和 65B 的 4 个版本,并仅在可公开使用的数据上进行了训练,且 13B 版本的模型性能就超过了 GPT-3。LLaMA 进行训练的数据集包含了 Common Crawl、C4、Github 公开项目代码、维基百科、Gutenberg 公共领域书籍、Books3、Arxiv 学术论文和 Stack Exchange 问答数据,整个数据集约包含 1.4 万亿 tokens。LLaMA 使用全 Transformer 架构并进行了一定的改进,如使用预规范化提高模型的稳定性,使用 SwiGLU 激活函数代替了 ReLU,采用旋转位置编码代替原文的绝对位置编码。此外, LLaMA 在实现上也进行了一些优化,如更高效的因果自注意力计算减少了内存用量和运行时间,手动实现 Transformer 层的反向传播减少重复计算^[51]等。由于 LLaMA 模型的开源特性和优越效果,一大批基于 LLaMA 模型的工作也涌现出来。

2023 年 7 月 18 日, Meta AI 重磅发布 LLaMA2^[52]以释放大语言模型的力量。LLaMA2 不仅面向研究领域开放,还可直接商用,推动了大模型的进一步开放。LLaMA2 模型包含 7B、13B 和 70B 参数版本,训练仍使用公开的在线数据(约 2 万亿 tokens),数据量比上一代增加 40%,上下文长度也直接翻倍。在推理、编码、精通性和知识测试等外部基准测试任务上优于其他开源模型,与闭源模型性能相比, LLaMA2 70B 版本也能够与 540B PaLM 持平或更优,但与 GPT-4 仍差距较大^[52]。此外, Meta AI 同时发布微调后的 LLaMA2-Chat,使用监督微调和 RLHF 在 LLaMA2 上进行训练,其中使用的数据包含公开的指令数据集和超 100 万条人类注释数据,在人工评估上优于众模型,与 ChatGPT 结果也几乎一致^[52]。LLaMA2 使用安全微调提升模型的安全性,显著降低了模型产生带有毒性和偏见回答的概率。值得一提的是, Meta AI 在 2023 年 8 月 24 日又发布了开源可商用的 Code LLaMA 版本,该版本是 LLaMA2 在特定代码数据集上训练的代码专用版本,在开源代码生成模型中表现最优,对推动代码生成领域技术进步有重要意义。

5.2 百川大模型

百川智能于 2023 年 4 月 10 日成立,旨在打造中国版 OpenAI 基础模型和上层应用。2023 年 6 月 15

日,百川发布国内首款开源免费商用大模型 Baichuan-7B,该模型基于 Transformer 架构,在约 1.2 万亿 tokens 上进行训练,在 C-Eval、AGIEval 和 Gaokao 中文评测和英文评测基准上均取得同量级模型最佳效果^[53]。2023 年 7 月 11 日,百川发布更大规模的 Baichuan-13B-Base 和对齐模型 Baichuan-13B-Chat^[54],应用 ALiBi 位置编码^[55],并将训练语料扩展到 1.4 万亿 tokens,在各大权威中英文评测基准上均取得较大提升,为同量级模型中最好的模型。

5.3 通义千问模型

通义千问是阿里云自主研发的大语言模型,并于 2023 年 4 月 11 日阿里云峰会上正式被揭幕,并通过钉钉和天猫精灵等产品将其应用于客户服务及业务流程等场景,并计划将其接入工业机器人^[56]。继国外 LLaMA2 等开源大模型提出可供商用后,阿里云于 8 月 3 日宣布通义千问自研大模型开源并可免费商用,并开源了 Qwen-7B 基座模型和 Qwen-7B-Chat 对话模型^[57],推动国内大厂将自研大模型开源和商业化应用。Qwen-7B 模型架构与 LLaMA 相似,在标准 Transformer 上进行改进,并使用公开数据进行训练,主要来源是公开的网页文档和代码文件,以英文和中文语料为主,在多项中文和英文基准测试上(如知识理解、代码和数学能力),性能优于其他规模相近的开源模型,甚至超过一些更大的模型。而微调版本的 Qwen-7B-Chat 也展示出超越同级别模型的语言理解与生成能力。

5.4 ChatGLM 模型

ChatGLM 是清华大学发布的一个开源中英双语对话模型,基于 GLM 架构并针对对话任务进行了优化^[58-59]。GLM 是一个通用语言模型预训练架构,基于自回归填充空白的目标进行训练,引入二维位置编码处理可变长度的填充任务,通过改变遮蔽片段数量和长度实现多任务学习。ChatGLM 参考了 ChatGPT 的设计思路,通过监督微调、反馈自助和 RLHF 等技术实现与人类对齐,此外通过量化技术可大大降低用户部署门槛。ChatGLM2 是在 ChatGLM 基础上的升级,采用了混合目标函数以取得性能提示,并通过 FlashAttention 技术^[60]扩展了模型上下文长度,以及采用 Multi-Query Attention 技术^[61]提升推理速度并降低显存使用。

由于篇幅原因,除上述介绍的模型外,还有一批具有重要影响的开源大模型,如通过 LLaMA 微调得到的 Alpaca 模型^[62]和 Vicuna 模型^[63],以及复旦大学开发的 MOSS 模型^[64]等。

6 结束语

本文首先回顾了语言模型和神经网络、语义表示和预训练技术的主要发展脉络。在语言模型方面,本文简述了从 N-gram 统计语言模型到神经网络语言模型的发展历程,以及从 RNN 到 LSTM,再到 Transformer 的神经网络结构发展,Transformer 的出现也推动了语言模型和预训练模型的进一步发展。在语义表示发展的部分中,统计类方法如 TF-IDF、LSA 及 LDA 等为语义分析奠定了基础,而 Word2Vec 等基于神经网络的词向量技术也推动了语义理解能力的提升,促进了预训练语言模型的产生和发展。这些技术均是 ChatGPT 等大规模语言模型的产生的前提。

在此基础上,本文进一步探究了 InstructGPT 和 ChatGPT 的关键技术,如监督微调和基于人类反馈的强化学习。这些技术增强了 ChatGPT 生成更加符合人类预期回复的交互能力。同时,对 ChatGPT 的优势与局限性的分析也提示了其应用场景,而当前各类开源大模型也在积极拓展应用领域。总之,ChatGPT 应被视为一个工具或资源进行合理利用,而非完全依赖或盲目信任,需要警惕其生成的误导信息。ChatGPT 的出现只是一个开始,要以积极的态度应对新技术带来的变革,推动语言模型技术造福人类社会。

参考文献:

- [1] NADKARNI P M, OHNO-MACHADO L, CHAPMAN W W. Natural language processing: An introduction[J]. *Journal of the American Medical Informatics Association*, 2011, 18(5): 544-551.
- [2] YOUNG T, HAZARIKA D, PORIA S, et al. Recent trends in deep learning based natural language processing[J]. *IEEE Computational Intelligence Magazine*, 2018, 13(3): 55-75.
- [3] BROWN P F, DELLA P V J, DESOUZA P V, et al. Class-based N-gram models of natural language[J]. *Computational Linguistics*, 1992, 18(4): 467-480.
- [4] MIKOLOV T, KARAFIÁT M, BURGET L, et al. Recurrent neural network based language model[C]//*Proceedings of the 11th Annual Conference of the International Speech Communication Association*. Makuhari, Chiba, Japan: DBLP, 2010: 1045-1048.
- [5] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [6] CHUNG J, GULCEHRE C, CHO K, et al. Empirical evaluation of gated recurrent neural networks on sequence modeling [EB/OL].(2014-02-01)[2023-08-30]. <https://arxiv.org/abs/1412.3555>.
- [7] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//*Proceedings of the 31st Conference on Neural Information Processing Systems (NIPS 2017)*. [S.l.]: ACM, 2017: 5998-6008.
- [8] CHEN S F, GOODMAN J. An empirical study of smoothing techniques for language modeling[J]. *Computer Speech & Language*, 1999, 13(4): 359-394.
- [9] BENGIO Y, DUCHARME R, VINCENT P. A neural probabilistic language model[J]. *Machine Learning Research*, 2003, 3: 1137-1155.
- [10] HINTON G E. Learning distributed representations of concepts[C]//*Proceedings of the Eighth Annual Conference of the Cognitive Science Society*. [S.l.]: American Psychological Association, 1986: 1-12.
- [11] ELMAN J L. Finding structure in time[J]. *Cognitive Science*, 1990, 14(2): 179-211.
- [12] BENGIO Y, SIMARD P, FRASCONI P. Learning long-term dependencies with gradient descent is difficult[J]. *IEEE Transactions on Neural Networks*, 1994, 5(2): 157-166.
- [13] Colah. Understanding LSTM networks[EB/OL]. (2015-08-27) [2023-08-21]. <http://colah.github.io/posts/2015-08-Understanding-LSTMs>.
- [14] SOCHER R, PERELYGIN A, WU J, et al. Recursive deep models for semantic compositionality over a sentiment treebank [C]//*Proceedings of the 2013 Conference on Empirical Methods in Natural Language Processing*. Washington, USA: [s.n.], 2013: 1631-1642.
- [15] SUTSKEVER I, MARTENS J, HINTON G E. Generating text with recurrent neural networks[C]//*Proceedings of the 28th International Conference on Machine Learning (ICML-11)*. Washington, USA: DBLP, 2011: 1017-1024.
- [16] GRAVES A. Generating sequences with recurrent neural networks[EB/OL]. (2014-06-05)[2023-08-21]. <https://arxiv.org/abs/1308.0850v5>.
- [17] YANG C, SUN M, YI X, et al. Stylistic chinese poetry generation via unsupervised style disentanglement[C]//*Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing*. Brussels, Belgium: Association for Computational Linguistics, 2018: 3960-3969.
- [18] GRAVES A, MOHAMED A R, HINTON G. Speech recognition with deep recurrent neural networks[C]//*Proceedings of 2013 IEEE International Conference on Acoustics, Speech and Signal Processing*. Washington, USA: IEEE, 2013: 6645-6649.
- [19] CHO K, VAN MERRIËNBOER B, GULCEHRE C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation[EB/OL]. (2014-03-15)[2023-08-23]. <https://arxiv.org/abs/1406.1078>.
- [20] SUTSKEVER I, VINYALS O, LE Q V. Sequence to sequence learning with neural networks[J]. *Advances in Neural Information Processing Systems*, 2014, 27: 3104-3112.
- [21] BAHDANAU D, CHO K, BENGIO Y. Neural machine translation by jointly learning to align and translate[EB/OL]. (2014-03-15)[2023-08-23]. <http://10.48550/arXiv.1409.0473>.
- [22] GEHRING J, AULI M, GRANGIER D, et al. Convolutional sequence to sequence learning[C]//*Proceedings of International*

- Conference on Machine Learning. [S.l.]: PMLR, 2017: 1243-1252.
- [23] SPARCK J K. A statistical interpretation of term specificity and its application in retrieval[J]. *Journal of Documentation*, 1972, 28(1): 11-21.
- [24] HONG Liangjie. Probabilistic latent semantic analysis[EB/OL]. (2012-12-24)[2023-08-30]. <http://arxiv.org/abs/1212.3900v2>.
- [25] DEERWESTER S, DUMAIS S T, FURNAS G W, et al. Indexing by latent semantic analysis[J]. *Journal of the American Society for Information Science*, 1990, 41(6): 391-407.
- [26] BLEI D M, NG A Y, JORDAN M I. Latent dirichlet allocation[J]. *Journal of Machine Learning Research*, 2003, 3: 993-1022.
- [27] MIKOLOV T, CHEN K, CORRADO G S, et al. Efficient estimation of word representations in vector space[C]// *Proceedings of International Conference on Learning Representations*. [S.l.]:[s.n.], 2013.
- [28] MIKOLOV T, SUTSKEVER I, CHEN K, et al. Distributed representations of words and phrases and their compositionality [J]. *Advances in Neural Information Processing Systems*, 2013, 26: 3111-3119.
- [29] DAI A M, LE Q V. Semi-supervised sequence learning[J]. *Advances in Neural Information Processing Systems*, 2015, 28: 3079-3087.
- [30] PETERS M E, NEUMANN M, IYYER M, et al. Deep contextualized word representations[EB/OL]. (2018-03-22)[2023-08-23]. <https://arxiv.org/abs/1802.05365v1>.
- [31] RADFORD A, NARASIMHAN K, SALIMANS T, et al. Improving language understanding by generative pre-training[EB/OL]. (2018-06-11) [2023-07-22]. https://cdn.openai.com/research-covers/language-unsupervised/language_understanding_paper.pdf.
- [32] DEVLIN J, CHANG M W, LEE K, et al. BERT: Pre-training of deep bidirectional transformers for language understanding [EB/OL]. (2019-05-24)[2023-08-23]. <https://arxiv.org/abs/1810.04805v2>.
- [33] RADFORD A, WU J, CHILD R, et al. Language models are unsupervised multitask learners[J]. *OpenAI Blog*, 2019, 1(8): 9.
- [34] BROWN T, MANN B, RYDER N, et al. Language models are few-shot learners[J]. *Advances in Neural Information Processing Systems*, 2020, 33: 1877-1901.
- [35] OUYANG L, WU J, JIANG X, et al. Training language models to follow instructions with human feedback[C]// *Proceedings of Advances in Neural Information Processing Systems*. [S.l.]:[s.n.], 2022: 27730-27744.
- [36] OpenAI. Introducing ChatGPT[EB/OL]. (2022-12-30)[2023-08-02]. <https://openai.com/blog/chatgpt>.
- [37] KAEHLING L P, LITTMAN M L, MOORE A W. Reinforcement learning: A survey[J]. *Journal of Artificial Intelligence Research*, 1996, 4: 237-285.
- [38] QIN C, ZHANG A, ZHANG Z, et al. Is ChatGPT a general-purpose natural language processing task solver[EB/OL].(2023-02-15)[2023-08-23]. <https://arxiv.org/abs/2302.06476v1>.
- [39] WEI J, WANG X, SCHUURMANS D, et al. Chain-of-thought prompting elicits reasoning in large language models[J]. *Advances in Neural Information Processing Systems*, 2022, 35: 24824-24837.
- [40] ZHONG Q, DING L, LIU J, et al. Can chatgpt understand too? A comparative study on ChatGPT and fine-tuned bert[EB/OL]. (2023-03-10)[2023-08-23]. <https://arxiv.org/abs/2302.10198>.
- [41] WANG A, SINGH A, MICHAEL J, et al. GLUE: A multi-task benchmark and analysis platform for natural language understanding[EB/OL]. (2019-02-22)[2023-08-23]. <http://arxiv.org/abs/arXiv:1804.07461>.
- [42] LIU Y, OTT M, GOYAL N, et al. Roberta: A robustly optimized bert pretraining approach[EB/OL]. (2019-07-26)[2023-08-23]. <https://arxiv.org/abs/1907.11692>.
- [43] YANG X, LI Y, ZHANG X, et al. Exploring the limits of chatgpt for query or aspect-based text summarization[EB/OL]. (2023-02-26)[2023-08-23]. <https://arxiv.org/abs/2302.08081>.
- [44] XU L, LI A, ZHU L, et al. SuperCLUE: A comprehensive Chinese large language model benchmark[EB/OL]. (2023-07-08) [2023-08-23]. <https://arxiv.org/pdf/2307.15020.pdf>.
- [45] TLILI A, SHEHATA B, ADARKWAH M A, et al. What if the devil is my guardian angel: ChatGPT as a case study of using chatbots in education[J]. *Smart Learning Environments*, 2023, 10(1): 15.
- [46] GUO B, ZHANG X, WANG Z, et al. How close is ChatGPT to human experts? Comparison, evaluation, and detection[EB/OL]. (2023-01-15)[2023-08-23]. <https://arxiv.org/abs/2301.07597>.

- [47] DESHPANDE A, MURAHARI V, RAJPUROHIT T, et al. Toxicity in ChatGPT: Analyzing persona-assigned language models[EB/OL]. (2023-04-01)[2023-08-23]. <https://arxiv.org/abs/2304.05335>.
- [48] LIU H, NING R, TENG Z, et al. Evaluating the logical reasoning ability of ChatGPT and GPT-4[EB/OL]. (2023-04-07)[2023-08-23]. <https://arxiv.org/abs/2304.03439>.
- [49] BAIDOO-ANU D, ANSAH L O. Education in the era of generative artificial intelligence (AI): Understanding the potential benefits of ChatGPT in promoting teaching and learning[J]. *Journal of AI*, 2023, 7(1): 52-62.
- [50] PARK J S, O'BRIEN J C, CAI C J, et al. Generative agents: Interactive simulacra of human behavior[EB/OL]. (2023-04-08)[2023-08-23]. <https://arxiv.org/abs/2304.03442>.
- [51] TOUVRON H, LAVRIL T, IZACARD G, et al. LLaMA: Open and efficient foundation language models[EB/OL]. (2023-04-02)[2023-08-23]. <https://arxiv.org/abs/2302.13971>.
- [52] TOUVRON H, MARTIN L, STONE K, et al. LLaMA 2: Open foundation and fine-tuned chat models[EB/OL]. (2023-07-25)[2023-08-23]. <https://arxiv.org/abs/2307.09288>.
- [53] BaichuanAI. Baichuan-7B[EB/OL]. (2023-06-11)[2023-08-11]. <https://github.com/baichuan-inc/Baichuan-7B>.
- [54] BaichuanAI. Baichuan-13B[EB/OL]. (2023-07-09)[2023-08-11]. <https://github.com/baichuan-inc/Baichuan-13B>.
- [55] PRESS O, SMITH N A, LEWIS M. Train short, test long: Attention with linear biases enables input length extrapolation [EB/OL]. (2022-04-22)[2023-08-23]. <https://arxiv.org/abs/2108.12409v2>.
- [56] NEWSWIRE P. Alibaba cloud unveils new AI model to support enterprises' intelligence transformation[EB/OL]. (2023-04-10)[2023-08-11]. <https://finance.yahoo.com/news/alibaba-cloud-unveils-ai-model-031300094.html>.
- [57] AlibabaCloud. Qwen-7B[EB/OL]. (2023-07-30)[2023-08-15]. <https://github.com/QwenLM/Qwen-7B>.
- [58] ZENG A, LIU X, DU Z, et al. GLM-130b: An open bilingual pre-trained model[EB/OL]. (2022-08-04)[2023-08-23]. <https://arxiv.org/abs/2210.02414>.
- [59] DU Z, QIAN Y, LIU X, et al. GLM: General language model pretraining with autoregressive blank infilling[EB/OL]. (2022-03-17)[2023-08-23]. <https://arxiv.org/abs/2103.10360>.
- [60] DAO T, FU D, ERMON S, et al. Flashattention: Fast and memory-efficient exact attention with IO-awareness[J]. *Advances in Neural Information Processing Systems*, 2022, 35: 16344-16359.
- [61] SHAZEER N. Fast transformer decoding: One write-head is all you need[EB/OL]. (2019-11-06)[2023-08-23]. <https://arxiv.org/abs/1911.02150v1>.
- [62] ROHAN T, ISHAAN G, TIANYI Z, et al. Alpaca: A strong, replicable instruction-following model[EB/OL]. (2023-03-13)[2023-08-15]. <https://crfm.stanford.edu/2023/03/13/alpaca.html>.
- [63] CHIANG W L, LI Z, LIN Z, et al. Vicuna: An open-source chatbot impressing GPT-4 with 90% ChatGPT quality[EB/OL]. (2023-03-30)[2023-08-15]. <https://lmsys.org/blog/2023-03-30-vicuna>.
- [64] SUN T, ZHANG X, HE Z, et al. MOSS: Training conversational language models from synthetic data[EB/OL]. (2023-07-10)[2023-08-15]. <https://github.com/OpenLMlab/MOSS>.

作者简介:



夏润泽(2000-),男,硕士研究生,研究方向:脑驱动多模态大模型。



李丕绩(1986-),通信作者,男,教授,博士生导师,研究方向:自然语言处理、大模型、多模态等,E-mail: pjli@nuaa.edu.cn。

(编辑:张黄群)