

融合 K-BERT 与 KG-BART 的测井文本生成方法研究

曹茂俊, 田明家, 肖阳

(东北石油大学计算机与信息技术学院, 黑龙江 大庆 163318)

摘要: 测井文本生成是油气勘探开发中的关键环节, 其质量直接影响地层构造解释的效率与准确性。现有方法主要包括基于模板的规则策略、统计摘要技术以及基于循环神经网络 (recurrent neural network, RNN) /Transformer 的小规模数据驱动模型, 但这些方法普遍存在领域知识利用率不足、长文本语境与逻辑一致性差以及缺少多任务协同机制等问题。针对中文测井文本的高专业性与复杂性, 提出一种融合知识增强型基于 Transformer 的双向编码器表示 (knowledge-enhanced bidirectional encoder representations from transformer, K-BERT) 语义理解与知识图谱增强型双向自回归 Transformer (knowledge graph-enhanced bidirectional and auto-regressive transformer, KG-BART) 生成能力的多任务模型 K2-KGLogGen。该模型通过引入测井领域知识图谱以增强语义感知, 利用分类模块提供类别语境引导, 并借助自注意力机制实现分类与生成的协同优化。实验结果表明, 在分类任务中, K2-KGLogGen 模型的 F1-score 相较于现有主流模型均有显著提升。其中, 相较于 K-BERT (单任务) 提升约 2.2%, 相较于 BERT 模型、文本卷积神经网络 (text convolutional neural network, TextCNN)、支持向量机+词频-逆文档频率 (support vector machine+term frequency-inverse document frequency, SVM+TF-IDF) 分别提升 3.2%、4.7% 及 9.3%; 在生成任务中, ROUGE-1、ROUGE-2 和 ROUGE-L 分别达 0.63、0.41 和 0.54, 显著优于 Transformer、文本到文本迁移 Transformer (text-to-text transfer transformer, T5)、统一语言模型 (unified language model, UniLM)、指针生成网络 (pointer generator network, PGN) 和 BART 等方法。消融实验进一步验证了自注意力机制与知识注入模块对性能提升的关键作用, 表明 K2-KGLogGen 模型在专业测井文本生成中具有显著优势, 并在其他高专业性技术文本生成任务中具有推广价值。

关键词: 测井文本生成; 多任务学习; 知识图谱; K-BERT; KG-BART; 注意力融合机制

中图分类号: TP213

文献标志码: A

doi: 10.11959/j.issn.2096-6652.202538

Research on well logging text generation method combining K-BERT and KG-BART

CAO Maojun, TIAN Mingjia, XIAO Yang

School of Computer and Information Technology, Northeast Petroleum University, Daqing 163318, China

Abstract: Well-logging text generation is a key task in oil and gas exploration and development, and its quality directly affects the efficiency and accuracy of subsequent geological structure interpretation. Existing approaches mainly include template-based rule strategies, statistical summarization techniques, and small-scale data-driven models based on recurrent neural network (RNN)/Transformer architectures. However, these methods generally have problems such as insuffi-

收稿日期: 2025-06-04; 修回日期: 2025-09-16

通信作者: 肖阳, xyang201506@163.com

基金项目: 国家自然科学基金项目 (No.42172161, No.52474035); 黑龙江省自然科学基金项目 (No.ZL2024D003); 中国石油科技创新基金项目 (No.2024DQ02-0114); 东北石油大学特色领域团队专项项目 (No.2022TSTD-03)

Foundation Items: The National Natural Science Foundation of China (No.42172161, No.52474035), Heilongjiang Natural Science Foundation Joint Key Projects (No.ZL2024D003), CNPC Innovation Fund (No.2024DQ02-0114), Special Project for Featured Field Teams of Northeast Petroleum University (No.2022TSTD-03)

cient utilization of domain knowledge, poor contextual and logical consistency in long-text generation, and the absence of multi-task collaborative learning mechanisms. To address the high specialization and complexity of Chinese well-logging texts, this paper proposed a multi-task model, K2-KGLogGen, which integrated the semantic understanding capability of knowledge-enhanced bidirectional encoder representations from transformer (K-BERT) with the text generation strength of knowledge graph-enhanced bidirectional and auto-regressive transformer (KG-BART). The model incorporated a well-logging domain knowledge graph to enhance semantic awareness, used a classification module to provide category-specific contextual guidance, and employed a self-attention fusion mechanism to achieve joint optimization of classification and generation. The experimental results show that in the classification task, the proposed model achieves significant improvements in F1-score compared to existing mainstream models. Specifically, it outperforms K-BERT (single-task) by approximately 2.2%, BERT by 3.2%, text convolutional neural network (TextCNN) by 4.7%, and support vector machine + term frequency-inverse document frequency (SVM+TF-IDF) by 9.3%. In the generation task, it attains ROUGE-1, ROUGE-2, and ROUGE-L scores of 0.63, 0.41 and 0.54, significantly outperforming Transformer, text-to-text transfer transformer (T5), unified language model (UniLM), pointer generator network (PGN), and BART. Ablation studies confirm that the self-attention mechanism and knowledge injection module are key contributors to performance gains. The results demonstrate the effectiveness of K2-KGLogGen in professional well-logging text generation and its potential applicability to other highly specialized technical text generation tasks.

Key words: well logging text generation, multi-task learning, knowledge graph, K-BERT, KG-BART, attention fusion mechanism

0 引言

在石油勘探与开发领域,测井技术是揭示地下地质特征与评估储层潜力的重要工具,其生成的测井文本对地质学家和工程师至关重要^[1-5]。然而,随着测井数据的急剧增长,如何高效、准确地生成专业测井文本,已成为亟待解决的关键问题。

近年来,预训练语言模型在自然语言处理(natural language processing, NLP)领域取得了显著成果^[6]。基于Transformer架构的预训练语言模型BERT^[7]凭借其双向编码器,在语义理解方面表现出色,但在处理专业领域文本时,仍面临领域知识缺乏与专业术语理解能力不足等挑战^[8]。相比之下,序列到序列预训练模型BART^[9]结合了编码器和自回归解码器结构,具备更强的文本生成能力,更适用于摘要、翻译等序列到序列任务。

为打破预训练模型在专业文本处理中的局限,研究人员提出了基于知识图谱的语言表示模型K-BERT^[10]和知识图谱增强的生成式模型KG-BART^[11]。K-BERT模型通过引入知识图谱,将结构化知识嵌入文本中,从而提升模型对复杂术语和实体关系的语义理解能力^[12]。KG-BART模型在BART模型的基础上融合知识图谱信息,提升生成文本的专业性与准确性,其双向注意力机制^[13]更适合中文语法特点,尤其适用于测井文本生成场景。

尽管K-BERT与KG-BART在各自任务中表现

优异,测井文本生成仍面临一个关键挑战,即如何将文本分类信息与领域知识有效融合,以共同引导生成过程^[14]。为此,本文提出一种融合K-BERT与KG-BART的多任务测井文本生成模型——K2-KGLogGen,该模型具备以下5个创新点。

(1) 引入测井领域知识图谱。针对测井文本高专业度与术语密集的特性,本文构建了覆盖常用专业术语、实体及其关系的测井领域知识图谱。在分类任务中,利用K-BERT模型实现对术语与实体关系的深度语义建模,增强模型对领域知识的理解能力。在生成任务中,将知识图谱嵌入KG-BART的生成模块中,使生成过程具备领域感知能力,从而提升文本的准确性与专业适配性。

(2) 提出多任务学习框架。本文设计了可联合执行分类与生成任务的多任务学习框架,使分类预测结果能够直接为生成阶段提供类别先验信息。在分类任务中,K-BERT能够精准捕捉关键特征与语义信息,实现高精度类别判定。在生成任务中,KG-BART结合知识图谱嵌入技术,生成符合目标类别特征的高质量文本,从而形成任务间的良性互补。

(3) 融合注意力机制实现深度信息交互。本文提出一种注意力融合模块,将分类模块输出的类别语义向量作为查询,与生成模块的编码向量进行注意力计算,从而将分类信息显式引入生成过程。同时,该模块能够引导模型关注与类别强相关的内容,并动态调节外部知识的使用比例,确保生成文

本既契合分类语义，又保持逻辑连贯性。

(4) 自适应的联合损失优化策略。针对分类与生成任务在训练过程中可能出现的梯度不均衡问题，设计了联合损失函数 $L_{total} = \alpha \cdot L_{cls} + \beta \cdot L_{gen}$ ，并在训练过程中根据任务性能动态调整损失权重比例，使两项任务在优化过程中协同提升。

(5) 多维度评估验证。除了采用基于召回导向的摘要评估 (recall-oriented understudy for gisting evaluation, ROUGE) 方法，本文在模型评估中引入领域专家的主观质量评分，从专业性、准确性、可读性等维度进行人工验证。实验结果表明，K2-KGLogGen 在测井文本生成任务中具有良好的有效性与实用价值。

1 相关工作

1.1 K-BERT 模型

K-BERT 模型是由北京大学与腾讯 AI 实验室联合提出的一种融合知识图谱的预训练语言模型。该模型在保留 BERT 双向编码与语言理解能力的基础上，通过引入外部知识图谱显著提升了其在专业领域文本处理中的性能。

1.1.1 K-BERT 模型框架

K-BERT 模型在 BERT 的基础上增加了知识层，用于将知识图谱中的三元组信息与文本中的实体进行关联。模型的整体框架包括知识层、嵌入层、视图层以及掩码转换器与编码器 4 个部分，其总体框架如图 1 所示。




图1 K-BERT 模型框架

具体而言，通过实体链接识别文本中的实体，并从知识图谱中查询相关三元组，将其注入原句中以构建知识增强的句子树。随后，嵌入层将句子树转换为嵌入表示，除了传统的令牌、位置和段嵌入，还引入软位置嵌入与可见矩阵以保留结构信息。视图层利用可见矩阵限制令牌的可见范围，避免注入知识导致的语义偏移。掩码转换器与编码器在 Transformer 基础上引入掩码自注意力机制，结合可见矩阵实现有效的信息交互，从而完成对句子树的深度语义建模，掩码自注意力机制的具体定义分别如式 (1) ~ 式 (3) 所示：

$$Q^{i+1}, K^{i+1}, V^{i+1} = h^i W_q, h^i W_k, h^i W_v \quad (1)$$

$$S^{i+1} = \text{softmax} \left(\frac{Q^{i+1} K^{i+1} + M}{\sqrt{d_k}} \right) \quad (2)$$

$$h^{i+1} = S^{i+1} V^{i+1} \quad (3)$$

其中， W_q 、 W_k 和 W_v 均为模型待学习的矩阵参数； h^i 为隐状态的第 i 个 Mask-Self-Attention 模块； d_k 为缩放因子，用于控制训练过程中的梯度稳定性； M 为可见矩阵。

1.1.2 K-BERT 模型关键技术

K-BERT 模型的成功得益于其引入的 4 项关键技术，如图 2 所示。

知识注入将知识图谱中的三元组信息融入文本，增强了模型的领域知识表达能力。软位置嵌入解决了由句子树重排序引发的语义混乱问题，保留了结构信息。可见矩阵通过限制令牌间的可见范围，减少了知识干扰，从而提升了模型的鲁棒性；掩码自注意力机制结合可见矩阵实现有效信息交互，进一步提升了对结构化文本的建模能力。K-BERT 在多个专业 NLP 任务中表现优异，尤其在测井文本处理方面，通过引入测井领域知识图谱^[15-16]，该模型显著提升了对专业术语与复杂语义关系的理解与生成能力。

1.2 KG-BART 模型

KG-BART 是一种预训练语言生成模型，通过将知识图谱与 BART 模型相结合，显著提升了模型在生成专业领域文本时的准确性和专业性。

1.2.1 KG-BART 模型架构

KG-BART 模型整体基于 BART 的编码器-解码器结构，并引入了知识融合模块，以实现知识图谱信息与文本表示的深度融合，其架构如图 3 所示。

KG-BART 模型采用多层 Transformer 结构，其




图2 K-BERT处理的关键技术




图3 KG-BART模型架构

编码器通过自注意力机制捕捉输入文本中的长距离依赖关系,生成高质量的语义表示,既保留了语义信息,又体现了上下文关系,为后续知识融合和文本生成奠定基础。模型的核心是知识融合模块,该模块通过实体链接识别文本中的实体,在知识图谱中查询相关的三元组,并利用知识图谱嵌入技术将三元组转换为向量表示,再与编码器输出进行融合。在此过程中,常采用注意力机制或门控机制,确保融合结果的同时具备语义与知识信息。解码器同样基于多层Transformer结构,以自回归方式逐步生成目标文本,在此过程中综合考虑已有文本、融合表示以及知识图谱信息,从而保证生成内容在语法、语义与专业性方面高度一致。

1.2.2 KG-BART模型关键技术

KG-BART模型的成功主要得益于实体链接技

术、知识图谱嵌入技术和融合机制的引入。实体链接是知识融合的基础,负责从输入文本中准确识别实体,并将其与知识图谱中的对应实体进行关联,KG-BART通过上下文感知消歧和多源图谱融合等策略,提升了链接的准确性与鲁棒性。知识图谱嵌入技术负责将三元组信息转化为向量表示,以保留语义与结构信息,常用方法包括知识图谱平移嵌入(translating embeddings for knowledge graph, TransE)模型^[17]、知识图谱实体与关系嵌入(embedding entities and relations for learning and inference in knowledge bases, DistMult)^[18]和复杂空间中基于关系旋转的知识图谱嵌入(knowledge graph embedding by relational rotation in complex space, RotatE)模型^[19]等,模型可根据具体任务灵活选择并优化嵌入方式。融合机制则负责将知识嵌入信息与编码

器输出的语义表示进行融合,生成兼具语义理解和领域知识的表示,通常采用注意力机制或门控机制计算相关性权重,以实现信息的自适应整合,从而显著提升生成文本的准确性与专业性。

1.3 注意力机制

注意力机制^[20]是深度学习领域,尤其是NLP任务中的关键技术,它使模型能够动态聚焦于输入数据的不同部分,从而在处理复杂任务时表现出更高的灵活性和准确性。

1.3.1 注意力机制的基本原理

注意力机制的基本思想源于人类在处理信息时的注意力分配方式,即在处理信息时重点关注重要信息,而忽略次要信息^[21]。在NLP任务中,注意力机制允许模型在处理序列数据时,根据上下文信息动态调整对不同单词或子序列的关注度。具体来说,注意力机制通过计算一组注意力权重来分配对输入序列不同部分的关注度,从而引导模型聚焦对当前任务更重要的信息。

1.3.2 自注意力机制

自注意力机制是注意力机制的一种特殊形式,该机制在处理序列数据时,不仅关注当前位置与输入序列的相关性,还能捕捉序列内部各位置之间的依赖关系,特别适用于建模长距离依赖关系,这是传统RNN或卷积神经网络难以实现的。在该机制中,输入序列分别被映射到查询(query)、键(key)和值(value)3个空间,通过计算查询与键的点积运算,并经softmax归一化得到注意力权重,再对值向量进行加权求和,最终生成每个位置的输出表示,从而有效提升整体语义建模能力^[22]。

1.4 多任务学习机制

K2-KGLogGen在模型设计中引入多任务学习框架^[23],同时优化了测井文本分类与生成任务,其联合损失函数定义如式(4)所示:

$$L_{total} = \alpha \cdot L_{cls} + \beta \cdot L_{gen} \quad (4)$$

其中, L_{total} 为联合损失函数总值, L_{cls} 为分类任务的交叉熵损失, L_{gen} 为生成任务的负对数似然损失,任务权重设置为 $\alpha=0.4$, $\beta=0.6$ 。

在训练过程中,K-BERT编码器的参数在分类与生成任务间共享,以保证特征一致性。同时,分类模块输出的隐向量经注意力融合模块引入KG-BART解码器,从而动态引导生成过程聚焦于分类标签相关的关键信息,实现类别语境与生成内容之

间的有效对齐。

1.5 测井知识图谱构建流程

本文基于行业标准与现场测井报告数据,构建了一个面向测井领域的知识图谱,具体步骤如下。

(1) 实体抽取:基于BERT与条件随机场(BERT with conditional random field, BERT-CRF)模型^[23]并结合人工校对,从数据中识别出测井设备、地层、岩性、测井曲线、参数等10类实体,累计约12 000个实体。

(2) 关系抽取:采用规则模板与深度学习关系抽取模型,识别实体间的关系类型,包括“属于”“测量于”“相关于”等18类关系,共计约36 000条关系。

(3) 图谱存储:将数据存储于Neo4j数据库中,以实现高效的知识检索与嵌入调用。

(4) 覆盖范围:图谱涵盖了常见的产出剖面、注入剖面、工程测井等作业类型,并包含井别、地层层系、岩性类型及各类测井设备与参数。

该知识图谱在模型的训练和推理阶段均可提供领域知识支持,提升了生成文本的专业性和一致性。

2 融合K-BERT与KG-BART的测井文本生成模型

测井文本生成任务主要面临以下难点:①测井数据具有多源异构特性,既包含数值型参数,又涉及大量专业术语与符号信息;②不同任务(如分类和生成)的目标不同,如何实现高效共享语义表示与任务互补是一大挑战。

K-BERT能够在语义编码阶段引入领域知识图谱,从而有效缓解通用语言模型在专业术语与知识关系理解方面的不足。而KG-BART在长文本生成中能够很好地利用外部知识结构,保证生成文本的逻辑连贯性与专业一致性。

因此,本文提出测井文本生成模型K2-KGLogGen,该模型融合了K-BERT的语义理解与知识图谱能力,以及KG-BART在文本生成方面的优势。K2-KGLogGen模型采用多任务学习框架,联合执行文本分类与生成任务,并通过注意力机制融合信息,确保生成文本既符合分类语义,又具备专业性与流畅性。

K2-KGLogGen模型架构如图4所示,主要由

K-BERT 分类模块、KG-BART 生成模块以及注意力融合模块3个部分组成。

(1) K-BERT 分类模块

K-BERT 分类模块通过对测井文本的深度语义理解和知识融合, 完成文本分类任务。K-BERT 模型能够精准捕捉文本中的关键特征和语义信息, 并通过 softmax 函数将文本表示映射到相应的分类标签, 实现测井文本的准确分类。知识图谱的引入显著增强了文本表示的深度, 使模型能够更深入地理解测井文本中的专业术语和复杂语义关系。K-BERT 的双向编码能力和强大的语言理解能力进一步提升了分类任务的准确性和效果。

(2) KG-BART 生成模块

KG-BART 生成模块基于 BART 架构, 引入知识图谱信息以处理测井文本的生成任务。该模块通过知识融合模块将知识图谱嵌入与编码器输出进行融合, 生成包含领域知识的文本表示。然后, 利用解码器的自回归生成机制, 逐步生成目标文本中的词或短语, 确保生成的文本既符合语言规范, 又包含丰富的领域知识。

(3) 注意力融合模块

注意力融合模块是 K2-KGLogGen 模型的核心部分, 负责将 K-BERT 分类模块的输出与 KG-BART 生成模块中的文本编码向量进行融合, 以指导文本生成过程。

该模块采用注意力机制, 通过计算分类结果与文本编码向量之间的相关性权重, 将分类信息有效融入文本生成中。

K-BERT 分类模块的输出作为查询向量, KG-BART 生成模块中的文本编码向量作为键向量和值向量。首先, 计算查询向量与键向量的点积, 并采

用 softmax 函数进行归一化以得到注意力权重。随后, 利用权重对值向量进行加权求和, 生成融合后的文本表示作为 KG-BART 生成模块的输入, 用于指导后续的文本生成过程。

注意力融合模块的计算过程如式 (5)、式 (6) 所示:

$$\alpha_i = \frac{\exp(C \cdot e_i)}{\sum_{j=1}^n \exp(C \cdot e_j)} \quad (5)$$

$$E_{\text{fused}} = \sum_{i=1}^n \alpha_i e_i \quad (6)$$

其中, C 为 K-BERT 分类模块的输出; KG-BART 生成模块中的文本编码向量为 $E = [e_1, e_2, \dots, e_n]$, n 为编码向量的长度; α_i 为第 i 个编码向量 e_i 的注意力权重; $\cdot$ 表示点积运算; E_{fused} 为融合后的文本表示, 它将作为 KG-BART 生成模块的输入, 指导后续文本生成过程。

3 实验结果及分析

3.1 数据集与知识图谱规模

在数据集部分, 本文使用大庆测试服务分公司和中国石油勘探开发研究院的测井文本数据集, 经过严格筛选与标注, 包含 10 000 条记录。数据涵盖产出剖面类、注入剖面类、工程测井类等类别。该数据集采用结构化数据库表的形式存储文档数据, 整体上呈现为文本标注信息与数值型参数混合的结构化数据。所有数据均经过标准化处理与缺失值筛选, 确保基础数据的可靠性。数据集按 8:2 比例划分为训练集和测试集, 用于检验模型在不同测井场景下的性能。




图4 K2-KGLogGen 模型架构

在知识图谱部分，本文构建的测井领域知识图谱具有覆盖范围广、结构完整的特点，包括测井设备、地层、岩性、测井曲线、参数等10类，共计约12 000个实体；涵盖18种常见关系类型，如“属于”“测量于”“相关于”等，约36 000条关系。

在模型训练与推理阶段，测井知识图谱作为外部知识被嵌入编码与解码过程中，有效提升了生成文本的领域术语一致性和逻辑连贯性。

3.2 实验环境与超参数设置

本文使用阿里云平台进行模型训练与测试。阿里云平台通过其强大的技术实力和多样化服务，为企业和个人用户提供了全面的云计算解决方案，助力数字化转型和业务创新。本次实验的实验环境设置见表1。

表1 实验环境设置

相关名称	配置
操作系统	Ubuntu-20.04.1
CPU	Hygon C86 3285 8-core Processor
内存	32 GB
GPU	NVIDIA V100
语言	Python3.8
框架	Pytorch2.0.1-CUDA11.7.1

本文实验的模型超参数设置见表2。

表2 模型超参数设置

参数	参数含义	值
learning_rate	学习率	2×10^{-5}
batch_size	批量大小	128
max_sequence_length	最大序列长度	128
masking_proportion	掩码比例	0.15
attention_heads	注意力头数	8

3.3 评价指标

本文实验采用NLP领域常用的指标ROUGE-N和ROUGE-L进行评估。其中，ROUGE-N是ROUGE指标家族的基础形式，通过计算生成文本与参考文本之间的n-gram重叠率来评估相似度，N表示n-gram的长度（即连续N个词的组合）；ROUGE-L为衡量生成文本与参考文本之间最长非连续但顺序一致的词序列匹配程度的评估指标，L表示最长公共子序列。

这些指标能够综合反映模型在文本生成或摘要任务中的表现，衡量模型生成的文本与参考文本之

间的重叠程度，从而评估模型的准确性和流畅性，ROUGE-N和ROUGE-L的计算式如式（7）、式（8）所示：

$$\text{ROUGE-N} = \frac{\sum_{n\text{-grams} \in \text{Candidate}} \text{Count}_{\text{match}}(n\text{-gram})}{\sum_{n\text{-grams} \in \text{Candidate}} \text{Count}(n\text{-gram})} \quad (7)$$

$$\text{ROUGE-L} = \frac{(1 + \beta^2) \cdot \text{Recall} \cdot \text{Precision}}{\beta^2 \cdot \text{Recall} + \text{Precision}} \quad (8)$$

其中， $\text{Count}_{\text{match}}(n\text{-gram})$ 为候选文本中与参考文本匹配的n-gram数量， $\text{Count}(n\text{-gram})$ 为参考文本中n-gram的总数量。Recall和Precision分别为召回率和精确率， β 为权重参数，通常设置为较大的值，以强调召回率的重要性。

3.4 分类任务性能评估

为验证多任务框架中分类任务模块的有效性，本文引入以下主流分类模型作为基线进行对比。

（1）支持向量机（support vector machine, SVM）：基于TF-IDF特征的传统文本分类器。

（2）TextCNN：利用卷积神经网络捕捉局部n-gram特征。

（3）BERT：使用[CLS]向量进行分类。

（4）K-BERT：在BERT中引入领域知识图谱。

（5）本文多任务框架分类模块K2-KGLogGen-Classifier。

在本文实验中，分类任务采用与生成任务相同的数据集和类别标签，评价指标包括准确率、精确率、召回率和F1-Score，结果见表3。

表3 分类任务性能评估结果

模型	准确率	精确率	召回率	F1-Score
SVM+TF-IDF	85.4%	84.9%	85.1%	85.0%
TextCNN	89.7%	89.4%	89.9%	89.6%
BERT	91.2%	90.8%	91.4%	91.1%
K-BERT(单任务)	92.1%	91.5%	92.7%	92.1%
K2-KGLogGen-Classifier	94.3%	94.0%	94.7%	94.3%

从表3可以看出，K2-KGLogGen-Classifier的准确率、精确率、召回率和F1-Score均优于其他基线模型。相较于K-BERT（单任务），K2-KGLogGen-Classifier的F1-Score提升了约2.2%。实验结果表明，本文方法的分类模块具备更强的类别区分能力和鲁棒性。

图5为各模型的混淆矩阵可视化结果。由图5

可见，K2-KGLogGen-Classifer在主要类别上的预测准确率显著高于其他基线模型，同时对低频类别的预测效果更均衡，类别间的混淆度较低，有效提升了整体分类性能。

3.5 实验结果与分析

为全面评估K2-KGLogGen模型在测井文本生成任务中的性能，本文选取多种当前主流文本生成模型及知识增强型预训练语言模型作为对比基线，并进行严格的实验和全面评估。

具体选取的对比基线模型包括Transformer、T5、UniLM、PGN和BART。实验结果见表4，可视化柱状对比结果如图6所示。

由表4可见，K2-KGLogGen模型在所有评估指标上均显著优于其他对比模型。在ROUGE-1、ROUGE-2和ROUGE-L指标上，K2-KGLogGen分别获得0.63、0.41和0.54的分数，展现出更优的文本信息捕捉能力、连续词组匹配能力和整体文本结构一致性。

表4 实验结果

模型	ROUGE-1	ROUGE-2	ROUGE-L
Transformer	0.55	0.33	0.47
T5	0.57	0.34	0.49
UniLM	0.59	0.37	0.50
PGN	0.60	0.38	0.53
BART	0.60	0.38	0.52
K2-KGLogGen	0.63	0.41	0.54

3.6 消融实验

为深入分析K2-KGLogGen模型中各组件的作用，本文设计了消融实验，构建了4个模型变体进行性能评估。

K2-KGLogGen（无自注意力）模型去除了自注意力机制，以评估自注意力机制对性能的贡献；K-BERT+BART模型去除了知识图谱组件，以评估知识图谱的影响；KG-BART模型去除了K-BERT分类模块，以探究分类信息在文本生成任务中的作用；BART模型作为基线模型，去除了知识图谱与




图5 各模型的混淆矩阵可视化结果




图6 可视化柱状对比结果

分类信息。

所有模型变体均在相同的实验环境和超参数设置下进行训练和测试，以确保结果的公平性与可比性。消融实验结果见表5。

表5 消融实验结果

模型变体	ROUGE-1	ROUGE-2	ROUGE-L
K2-KGLogGen	0.63	0.41	0.54
K2-KGLogGen(无自注意力)	0.61	0.39	0.54
K-BERT+BART	0.60	0.38	0.53
KG-BART	0.61	0.39	0.54
BART	0.60	0.38	0.52

实验结果表明，K2-KGLogGen模型通过融合K-BERT的语义理解能力、KG-BART的文本生成能力以及自注意力机制，显著提升了测井文本的生成质量。

具体而言，自注意力机制有效整合了分类信息，增强了生成文本与分类意图之间的一致性。知识图谱为模型提供了丰富的领域知识支持。K-BERT分类模块凭借其强大的特征提取能力助力文本生成。与基线模型BART相比，K2-KGLogGen模型在ROUGE-1、ROUGE-2和ROUGE-L等关键指标上均表现优异，验证了各组件协同工作对整体性能的促进作用。

K2-KGLogGen在消融实验中展现出较强的鲁棒性。移除自注意力机制后，ROUGE-1和ROUGE-2分别下降至0.61和0.39，而ROUGE-L仍稳定在0.54，说明该机制对短语匹配的提升作用更显著，对长序列匹配的影响相对有限。与基准模型（K-BERT+BART）相比，K2-KGLogGen在ROUGE-1、ROUGE-2和ROUGE-L方面分别提高了0.03、0.03和0.01；与KG-BART相比，ROUGE-1和ROUGE-2方面均提高了0.02，ROUGE-L持平。这表明本文模型在知识图谱融合方面具有显著优势，能够更精准地捕捉实体间的语义关联。与BART相比，K2-KGLogGen各项指标均提高了0.02~0.03，进一步验证了知识图谱对生成质量的关键作用。整体而言，模型结构稳定性高，知识图谱的深度整合是性能提升的核心因素，即使在部分组件被移除的情况下，模型仍能保持较强的生成能力。

4 结束语

本文提出一种融合K-BERT与KG-BART的多

任务测井文本生成模型K2-KGLogGen。该模型结合K-BERT在语义理解和知识图谱融合方面的优势以及KG-BART在文本生成任务中的良好性能，并通过引入注意力机制实现分类任务与生成任务的有效融合。实验结果表明，K2-KGLogGen模型在ROUGE-1、ROUGE-2和ROUGE-L等评估指标上表现优异，验证了其生成准确专业测井文本的能力。消融实验进一步表明，自注意力机制和知识图谱对模型性能的提升具有关键作用。

K2-KGLogGen模型在需要深度融合领域知识、实现动态意图对齐及处理多源特征的专业场景中展现出显著优势。该模型尤其适用于地质测井报告、专利技术文档等专业文本生成任务，其知识图谱组件通过结构化领域术语与逻辑关系，有效保障了专业术语的一致性与生成文本的逻辑连贯性。

尽管K2-KGLogGen模型在测井文本生成任务中取得了显著成果，但仍存在若干可进一步研究的问题。未来的研究方向包括：①优化模型架构，采用轻量化设计及更高效的并行计算与分布式训练技术，以提升训练与推理效率，同时保持性能；②探索多源知识图谱的整合与动态更新机制，增强模型对复杂测井文本的理解与生成能力；③拓展模型至更多专业领域，并提升其可解释性，使生成过程更透明，易于用户理解和信任。

参考文献：

- [1] BANAEI H, AHMED M U, LOUFI A. Automatic generation of patient's daily summaries from electronic health records: a template-based approach[J]. IEEE Journal of Biomedical and Health Informatics, 2019, 23(5): 2103-2113.
- [2] EL-KASSAS W S, SALAMA C R, RAFAA A A, et al. Automatic text summarization: a comprehensive survey[J]. Expert Systems with Applications, 2021, 165: 113679.
- [3] 张汉清, 宋昊林, 李绍宇, 等. 基于Transformer的预训练语言模型在可控文本生成中的研究综述[J]. ACM计算调查, 2023, 56(3): 1-37.
ZHANG H Q, SONG H L, LI S Y, et al. A survey of controllable text generation using transformer-based pre-trained language models[J]. ACM Computing Surveys, 2023, 56(3): 1-37.
- [4] 李宁, 徐彬森, 武宏亮, 等. 人工智能在测井地层评价中的应用现状及前景[J]. 石油学报, 2021, 42(4): 508-522.
LI N, XU B S, WU H L, et al. Application status and prospects of artificial intelligence in well logging and formation evaluation[J]. Acta Petrolei Sinica, 2021, 42(4): 508-522.
- [5] 石玉江, 刘国强, 钟吉彬, 等. 基于大数据的测井智能解释系统开发与应用[J]. 中国石油勘探, 2021, 26(2): 113-126.
SHI Y J, LIU G Q, ZHONG J B, et al. Development and application of intelligent logging interpretation system based on big data[J]. China Petroleum Exploration, 2021, 26(2): 113-126.

- [6] 奚雪峰, 周国栋. 面向自然语言处理的深度学习研究[J]. 自动化学报, 2016, 42(10): 1445-1465.
XI X F, ZHOU G D. A survey on deep learning for natural language processing[J]. Acta Automatica Sinica, 2016, 42(10): 1445-1465.
- [7] KOROTEEV M V. BERT: a review of applications in natural language processing and understanding[EB]. arXiv preprint, 2021, arXiv: 2103.11943.
- [8] JAWAHAR G, SAGOT B, SEDDAH D. What does BERT learn about the structure of language?[C]//Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics. Stroudsburg: ACL, 2019: 3651-3657.
- [9] LEWIS M, LIU Y H, GOYAL N, et al. BART: denoising sequence-to-sequence pre-training for natural language generation, translation, and comprehension[EB]. arXiv preprint, 2019, arXiv: 1910.13461.
- [10] LIU W J, ZHOU P, ZHAO Z, et al. K-BERT: enabling language representation with knowledge graph[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(3): 2901-2908.
- [11] LIU Y, WAN Y, HE L F, et al. KG-BART: knowledge graph-augmented BART for generative commonsense reasoning[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35(7): 6418-6425.
- [12] 张天成, 田雪, 孙相会, 等. 知识图谱嵌入技术研究综述[J]. 软件学报, 2023, 34(1): 277-311.
ZHANG T C, TIAN X, SUN X H, et al. Overview on knowledge graph embedding technology research[J]. Journal of Software, 2023, 34(1): 277-311.
- [13] 石磊, 王毅, 成颖, 等. 自然语言处理中的注意力机制研究综述[J]. 数据分析与知识发现, 2020, 4(5): 1-14.
SHI L, WANG Y, CHENG Y, et al. Review of attention mechanism in natural language processing[J]. Data Analysis and Knowledge Discovery, 2020, 4(5): 1-14.
- [14] 朱靖波, 陈文亮. 基于领域知识的文本分类[J]. 东北大学学报(自然科学版), 2005, 26(8): 733-735.
ZHU J B, CHEN W L. An approach based on domain knowledge to text categorization[J]. Journal of Northeastern University (Natural Science), 2005, 26(8): 733-735.
- [15] 黄刚. 知识图谱构建方法及其在油气勘探开发领域应用研究[D]. 大庆: 东北石油大学, 2019.
HUANG G. Research on knowledge graph construction methods and their application in oil and gas exploration and development[D]. Daqing: Northeast Petroleum University, 2019.
- [16] 许智双, 张昆, 范俊超, 等. 基于本体的网络安全知识图谱构建方法[J]. 信息安全, 2025, 25(3): 451-466.
XU Z S, ZHANG K, FAN J C, et al. Construction Method of Cybersecurity Knowledge Graph Based on Ontology[J]. Netinfo Security, 2025, 25(3): 451-466.
- [17] ASMARA S M, SAHABUDIN N A, NADIAH I N S, et al. A review of knowledge graph embedding methods of TransE, TransH and TransR for missing links[C]//Proceedings of the 2023 IEEE 8th International Conference on Software Engineering and Computer Systems (ICSECS). Piscataway: IEEE, 2023: 470-475.
- [18] YANG B S, YIH W T, HE X D, et al. Embedding entities and relations for learning and inference in knowledge bases[EB]. arXiv preprint, 2014, arXiv: 1412.6575.
- [19] SUN Z Q, DENG Z H, NIE J Y, et al. RotatE: knowledge graph embedding by relational rotation in complex space[EB]. arXiv preprint, 2019, arXiv: 1902.10197.
- [20] 鞠默然, 罗江宁, 王仲博, 等. 融合注意力机制的多尺度目标检测算法[J]. 光学学报, 2020, 40(13): 132-140.
JU M R, LUO J N, WANG Z B, et al. Multi-scale target detection algorithm based on attention mechanism[J]. Acta Optica Sinica, 2020, 40(13): 132-140.
- [21] 李思聪, 王飞, 魏子令, 等. 面向恶意代码检测的深度注意力网络架构[J]. 信息安全, 2025, 25(8): 1208-1222.
LI S C, WANG F, WEI Z L, et al. Deep attention network architecture for malicious code detection[J]. Netinfo Security, 2025, 25(8): 1208-1222.
- [22] 张钰, 刘建伟, 左信. 多任务学习[J]. 计算机学报, 2020, 43(7): 1340-1378.
ZHANG Y, LIU J W, ZUO X. Survey of multi-task learning[J]. Chinese Journal of Computers, 2020, 43(7): 1340-1378.
- [23] SOUZA F, NOGUEIRA R, LOTUFO R. Portuguese named entity recognition using BERT-CRF[EB]. arXiv preprint, 2019, arXiv: 1909.10649.

[作者简介]



曹茂俊 (1978-), 男, 博士, 东北石油大学计算机与信息技术学院副教授, 主要研究方向为油气领域人工智能、领域软件工程、测井工业软件、知识图谱、大模型。



田明家 (2002-), 男, 东北石油大学计算机与信息技术学院硕士生, 主要研究方向为自然语言处理、知识图谱、大模型。



肖阳 (1998-), 男, 东北石油大学计算机与信息技术学院硕士生, 主要研究方向为自然语言处理、知识图谱。