

基于循环一致性约束的LLM增强型语言模型训练框架

吴养睿, 罗丽, 赵才荣

引用本文

吴养睿, 罗丽, 赵才荣. 基于循环一致性约束的LLM增强型语言模型训练框架[J]. 计算机科学, 2026, 53(4): 377-383.

WU Qiaorui, LUO Li, ZHAO Cairong. [LLM-augmented Training Framework with Cycle-Consistency Constraints](#) [J]. Computer Science, 2026, 53(4): 377-383.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于多任务强化学习的优先级加权软模块化方法:SM-PHT](#)

SM-PHT:Robust,Scalable,and Efficient Method for Multi-task Reinforcement Learning
计算机科学, 2026, 53(4): 366-376. <https://doi.org/10.11896/jsjcx.250700198>

[Agent4Stu:基于大语言模型的学生作答行为高效模拟智能体](#)

Agent4Stu:Efficient LLM-based Student Answer Behavior Simulation Agent
计算机科学, 2026, 53(4): 347-355. <https://doi.org/10.11896/jsjcx.250800012>

[基于结构化知识蒸馏的轻量级伪装目标检测模型](#)

Lightweight Camouflaged Object Detection Model Based on Structured Knowledge Distillation
计算机科学, 2026, 53(4): 299-307. <https://doi.org/10.11896/jsjcx.250100105>

[大模型驱动的形式化定理证明:综述与展望](#)

Formal Theorem Proving Empowered by Large Language Model:Survey and Perspectives
计算机科学, 2026, 53(4): 1-23. <https://doi.org/10.11896/jsjcx.251000067>

[大语言模型驱动的言语障碍评估方法综述](#)

Review of Speech Disorder Assessment Methods Driven by Large Language Models
计算机科学, 2026, 53(3): 307-320. <https://doi.org/10.11896/jsjcx.250300125>

基于循环一致性约束的 LLM 增强型语言模型训练框架

吴养睿¹ 罗丽² 赵才荣¹

1 同济大学计算机科学与技术学院 上海 201804

2 国网湖南省电力有限公司长沙供电分公司 长沙 410000

(2331919@tongji.edu.cn)

摘要 针对专利摘要生成任务中的技术特征完整性缺失、合规性不足以及边缘部署效率受限等问题,提出一种基于循环一致性约束的大语言模型增强型语言模型训练框架(LACC)。LACC 框架通过构建摘要生成与权利要求扩写的双向可逆任务结构,引入循环一致性约束机制,实现技术特征与法律表述的联合优化。在此基础上,LACC 集成了由大语言模型驱动的可控数据增强策略,自动构建高质量专利样本对,并结合动态验证机制,提升了生成文本的技术准确性与合规稳定性。实验结果表明,LACC 在中文专利数据集 CPTD 上的 ROUGE-L 得分达到 56.74,较基线提升 8.99 个百分点,在循环一致性评分(RCS)方面亦取得显著优势。此外,该方法在边缘设备上的推理延迟控制在 420ms 以内,单卡内存占用不超过 4.5GB,具备良好的工业部署潜力。综上所述,LACC 框架为专利撰写辅助、法律文本生成与知识产权智能管理等下游任务提供了具备实用价值的技术路径,展现出推动知识产权全生命周期自动化处理的重要应用前景。

关键词: 自然语言处理;大语言模型;循环一致性;数据增强;知识蒸馏;协同训练

中图分类号 TP391

LLM-augmented Training Framework with Cycle-Consistency Constraints

WU Qiaorui¹, LUO Li² and ZHAO Cairong¹

1 School of Computer Science and Technology, Tongji University, Shanghai 201804, China

2 State Grid Hunan Electric Power Co., Ltd. Changsha Power Supply Branch, Changsha 410000, China

Abstract This paper proposes a training framework termed LACC (Large Language Model-Augmented Consistency-Constrained), designed to address key challenges in patent abstract generation, including incomplete coverage of technical features, insufficient legal compliance, and inefficiency in edge deployment. The LACC framework constructs a bidirectional reversible task structure between abstract generation and claim expansion, incorporating a cycle-consistency constraint to jointly optimize technical expression and legal formulation. On this basis, LACC integrates a controllable data augmentation strategy powered by large language models (LLMs) to automatically generate high-quality patent text pairs. A dynamic verification mechanism is further introduced to enhance the technical accuracy and regulatory reliability of generated content. Experimental results on the Chinese patent dataset CPTD demonstrate that LACC achieves a ROUGE-L score of 56.74, outperforming the baseline by 8.99 percentage points, and shows significant improvements in the recurrence consistency score (RCS). Moreover, the framework supports efficient edge deployment, with inference latency controlled within 420ms and single-GPU memory usage limited to 4.5GB. Overall, LACC offers a practical and scalable solution for downstream tasks such as patent drafting assistance, legal text generation, and intelligent intellectual property (IP) management, and shows strong potential in enabling the automation of the full lifecycle of IP processing.

Keywords Natural language processing, Large language model, Cycle consistency, Data augmentation, Knowledge distillation, Collaborative training

到稿日期:2025-06-06 返修日期:2025-07-19

基金项目:国家自然科学基金(62076184,62473286);上海市自然科学基金面上项目(22ZR1466700)

This work was supported by the National Natural Science Foundation of China (62076184, 62473286) and Shanghai Natural Science Foundation (22ZR1466700).

通信作者:赵才荣(zhaocairong@tongji.edu.cn)

1 引言

端侧语言模型在特定领域任务中的部署常面临双重挑战:模型容量受限与高质量标注数据匮乏^[1]。这些问题不仅限制了模型在复杂任务中的表现,也显著削弱了其泛化能力与鲁棒性^[2]。传统依赖人工专家评估的范式进一步增加了系统部署的时间与经济成本,制约了其在实际场景中的可扩展性^[3]。

为系统性应对上述挑战,本文提出一种基于大语言模型(LLM)增强与循环一致性约束的多阶段协作学习框架,旨在强化模型的语义表达能力、提升低资源场景下的性能稳定性,并支持在资源受限设备上的部署。

本文方法通过4个互相关联的维度实现技术创新:1)设计双任务学习机制,在循环一致性约束下同步优化主任务与逆任务,实现可逆转换过程中语义完整性的保持;2)开发基于LLM的双向数据增强策略,跨任务对生成合成数据并注入受控噪声,增强模型对分布偏移的适应能力;3)建立教师-学生协同训练范式,利用LLM生成的思维链(CoT)推理路径指导学习过程,同步获取任务处理能力与底层推理模式;4)构建动态验证系统,采用LLM作为语义验证器,通过训练与推理阶段的持续一致性验证形成迭代优化闭环。

综上所述,本文的贡献主要体现在3个方面:1)构建了基于循环一致性的闭环语言学习范式,有效保持生成内容的语义一致性与技术完整性;2)系统性解决了数据稀缺问题,实现LLM驱动的知识蒸馏;3)引入可解释、可泛化的验证机制,推动了语言模型从性能指标向语义层面转变的评估体系发展。

实验表明,本文方法在ROUGE-L等性能指标上平均提升8.99个百分点,并通过自动化验证策略显著降低了人工评估成本,展现出良好的工业部署潜力与学术推广价值。

2 相关工作

2.1 循环一致性

循环一致性(Cycle Consistency)是自监督学习的重要范式,其核心思想是通过可逆变换的闭环约束保持内容保真度。

早期研究主要聚焦于计算机视觉领域,Zhu等^[4]提出的CycleGAN首次将循环一致性损失应用于无配对图像风格迁移,通过构建 $G: X \rightarrow Y$ 与 $F: Y \rightarrow X$ 的双向映射,实现域间转换的语义保持。该工作启发了跨模态任务中一致性约束的广泛应用,在医学影像分析领域,Kim等^[5]提出的CycleMorph模型将循环一致性损失引入微分同胚图像配准任务,通过循环一致性约束与形变场正则化,确保了形变场的拓扑保持性及双向可逆性,在脑部MRI配准中显著提升了配准精度与变形场的平滑性。

在自然语言处理领域,循环一致性的应用面临更大挑战。Shen等^[6]尝试将CycleGAN框架迁移至文本风格迁移任务,通过强化学习策略,缓解离散文本空间的梯度传递问题。然而,该方法在长文本生成中常出现语义偏移,暴露出传统循环损失函数对深层逻辑一致性建模的不足。文献[7-8]针对多模态医学图像配准任务,提出了CoCycleReg方法,通过将图像配准与图像翻译以协同循环一致性方式联合建模,打破了

传统分阶段处理的限制。该方法利用双分支结构确保形变场的可逆性,实现配准与翻译的双向增强,在多种数据集上兼顾配准精度、形变规则性与计算效率,验证了协同循环一致性策略的有效性。

现有方法在文本生成任务中的局限性主要体现在3个方面:1)多数研究(如文献[9])仅关注单向任务(如摘要或翻译),缺乏双向可逆变换的联合优化;2)传统损失依赖表面特征匹配(如ROUGE),难以捕捉逻辑连贯性等深层语义属性;3)医学影像等领域的成功案例^[7-8]表明了该机制的有效性,但文本领域尚未建立有效的在线修正框架。本研究通过构建摘要-扩写的可逆任务对,并引入LLM驱动的动态语义验证,突破了上述限制。

2.2 数据增强

数据增强技术是突破数据稀缺瓶颈的核心手段^[10],其发展历程呈现从规则驱动到语义感知的范式转变^[11]。早期研究主要依赖人工规则与统计先验。Schick等^[12]提出基于模板的回译增强方法,通过双向翻译生成释义样本,但该方法受限于模板覆盖度,难以处理复杂语义结构。Wei等^[13]的系统性研究表明,简单的词级替换(如同义词替换)仅能提升模型对局部扰动的鲁棒性,而对全局语义一致性的改善有限。

大语言模型(LLMs)的兴起推动了数据生成技术的质变^[14]。Zelikman等^[15]提出的STaR(Self-Taught Reasoner)框架首次实现LLM驱动的推理数据自生成,通过迭代生成-精炼过程创建包含逻辑链的训练样本,在数学推理任务上将准确率提升了22.4%。这一突破性工作证明了LLM生成数据的潜在价值,但其单向生成模式(问题→解答)难以确保数据的可逆一致性。近期医学影像领域的研究^[16]则通过多参数扰动生成对抗样本,在保持诊断关键特征的同时增强模型对设备差异的适应性,为文本数据的可控噪声注入提供了跨领域启示。

现有数据增强方法在面向可逆任务训练时面临三重挑战:1)传统方法(如文献[17])采用独立增强策略,导致摘要与扩写任务的数据分布偏移;2)多数LLM生成方法(如文献[15])缺乏对生成质量的在线验证,可能引入语义噪声;3)医学领域的受控扰动机制^[16]尚未有效迁移至文本领域。本研究通过LLM生成双向任务对(摘要&扩写)并实施动态质量过滤,同时设计基于语义相似度阈值的噪声注入策略(如句式重构、实体替换),实现了增强数据的分布对齐与质量可控。

2.3 知识蒸馏与动态验证

知识蒸馏与动态验证的协同进化标志着模型训练从单向知识迁移向闭环自优化的范式跃迁^[18]。经典知识蒸馏框架^[19]通过软化标签实现教师-学生模型的知识传递,但其静态蒸馏模式难以捕捉复杂推理过程。这一局限在思维链(CoT)技术兴起后尤为显著,例如Kumar等^[20]提出的知识蒸馏方法将推理路径作为知识载体,通过对齐师生模型的逻辑步骤,在数学推理任务上提升学生模型的泛化能力,揭示了结构化知识迁移的潜力。

在该领域的最新进展中,Liu等提出的SCORE框架^[21]利用LLM作为验证器,对生成文本进行多轮迭代修正,但其验证信号仅用于后处理阶段,未能深度融入训练过程。

现有方法面临的双重挑战在于^[22]:1)多数知识蒸馏研究(如文献[19])依赖固定教师模型,无法实现 LLM 与边缘模型的协同进化;2)动态验证系统(如文献[21])通常独立于训练回路运行,导致反馈延迟与知识断层。本研究通过构建双向蒸馏通道(教师 LLM→学生模型→验证 LLM)和实时验证奖励机制,实现知识迁移与质量评估的闭环耦合。该机制在专利文本摘要生成任务中较传统方法显著减少了事实性错误,验证了动态协同的优越性。

3 LACC 框架

3.1 整体框架

本文提出了一个训练框架 LACC(LLM-Augmented Cycle-Consistent Framework),它是一种面向端侧小语言模型的闭环学习系统,如图 1 所示。其核心思想是通过循环一致性约束与大语言模型增强的深度融合,实现数据生成、知识迁移与动态验证的三阶段协同优化。框架由以下核心模块构成。

1) 双任务可逆学习模块

构建摘要任务($f_{\text{sum}}: X \rightarrow Y$)与扩写任务($f_{\text{exp}}: Y \rightarrow X$)的闭环映射;通过共享编码器提取跨任务语义特征,通过任务特定解码器实现参数隔离。

2) LLM 增强数据引擎

使用 LLM 生成高质量可逆数据对 $\mathcal{D}_{\text{aug}} = \{(x_i, y_i, \epsilon_i)\}$, 其中 ϵ_i 为受控噪声。

3) 动态协同训练框架

在训练过程中实时监测生成质量,当数据表现不佳时调用 LLM 进行分析,触发条件为:

$$\text{Trigger}(x, y) = \mathbb{I}(\text{ROUGE-L}(y, x) < 0.6 \vee \text{Conf}(y|x) < 0.3)$$

调用 LLM 验证器生成修正信号 Δ ,并转换为策略梯度奖励。

$$r = \lambda_1 F1_{\text{fact}} + \lambda_2 \text{Coherence}_{\text{LLM}}$$



图 1 LACC 算法框架图

Fig. 1 Architecture of LACC framework

综上,LACC 的训练流程如算法 1 所示。

算法 1 LACC 框架训练过程

输入:初始训练数据集 $\mathcal{D} = (x_i, y_i)_{i=1}^N$,大语言模型 LLM,边缘模型 M_0 ,预设阈值 τ_r (ROUGE)与 τ_c (置信度)

输出:训练优化后的学生模型参数 θ

1. 初始化学生模型 M_0 ,加载预训练权重
2. 使用 LLM 生成高质量种子数据 $\mathcal{D}_{\text{seed}}$
3. 对 $\mathcal{D}_{\text{seed}}$ 应用双向扰动与语义过滤,得到增强数据集 \mathcal{D}_{aug}

4. 构造完整训练集 $\mathcal{D}_{\text{train}} = \mathcal{D} \cup \mathcal{D}_{\text{aug}}$

5. for 每轮训练 do

5.1. for $(x, y) \in \mathcal{D}_{\text{train}}$ do

5.1.1. 计算前向摘要输出 $\hat{y} = f_{\text{sum}}(x)$

5.1.2. 计算逆向扩写输出 $\hat{x} = f_{\text{exp}}(y)$

5.1.3. 计算循环一致性损失 $\mathcal{L}_{\text{cycle}}$

5.1.4. 若启用教师 LLM,则获取 CoT 推理路径 C ,计算 \mathcal{L}_{cot}

5.1.5. 若 $\text{ROUGE-L}(\hat{y}, y) < \tau_r$ 或 $\text{Conf}(\hat{y}) < \tau_c$

→ LLM 验证器生成修正信号 Δ

→ 计算奖励 r

→ 应用策略梯度更新模型参数 θ

5.1.6. 计算基础任务损失 $\mathcal{L}_{\text{task}}$

5.1.7. 计算总损失融合 $\mathcal{L}_{\text{total}}$

5.1.8. 更新模型参数

$$\theta \leftarrow \theta - \eta \cdot \nabla_{\theta} \mathcal{L}_{\text{total}}$$

5.2. end for

6. end for

3.2 双任务循环学习机制

LACC 框架通过构建摘要与扩写的双向可逆 $\text{sim}(s, e) = \frac{\phi(s)^T \phi(e)}{\|\phi(s)\| \|\phi(e)\|}$ 任务对,形成闭环学习系统。其数学形式化定义如下。

前向任务($f_{\text{sum}} \phi$):

$$y = f_{\text{sum}}(x; \theta_s) = \text{Decoder}_s(\text{Encoder}(x))$$

其中, $x \in X$ 为原始文本, θ_s 为摘要任务参数。

逆向任务($f_{\text{exp}} \phi$):

$$\hat{x} = f_{\text{exp}}(y; \theta_e) = \text{Decoder}_e(\text{Encoder}(y))$$

其中, $y \in Y$ 为摘要文本, θ_e 为扩写任务参数。

为强制模型保持语义可逆性,定义双向循环一致性损失为:

$$\mathcal{L}_{\text{cycle}} = \mathbb{E}_{x \sim X} \|f_{\text{exp}}(f_{\text{sum}}(x)) - x\|_2 + \mathbb{E}_{y \sim Y} \|f_{\text{sum}}(f_{\text{exp}}(y)) - y\|_2$$

与传统方法(如 CycleGAN)的单任务循环约束不同,LACC 引入动态权重调整机制。

$$\omega_{\text{forward}} = \frac{\text{sim}(x, \hat{x})}{\text{sim}(x, \hat{x}) + \text{sim}(y, \hat{y})}$$

$$\omega_{\text{reverse}} = 1 - \omega_{\text{forward}}$$

其中, sim 为基于 SBERT 的语义相似度计算函数。该机制优先优化当前生成质量较低的任务分支。

3.3 LLM 增强的双向数据生成

3.3.1 双向数据生成流程

LACC 框架通过 LLM 生成可逆任务对(摘要 & 扩写),解决传统数据增强的单向性局限。生成流程包含 3 个阶段。

1) 种子数据生成

首先基于领域知识设计 Prompt 模板,调用 LLM(如 GPT-4)批量生成初始数据对 $\mathcal{D}_{\text{seed}}$,并筛选满足 $\text{ROUGE-L} \geq 0.7$ 的高质量样本。

2) 对抗性噪声注入

生成数据施加受控扰动,提升模型抗噪能力,包括实体替换,即随机替换 15% 非关键实体(如“螺钉”→“螺栓”),保留

诊断核心实体(如“量子加密算法”“石墨烯复合材料比例”);句式变异,通过 LLM 改写句式(如主动→被动语态),保持语义不变性;逻辑干扰,插入无关从句(如“患者有宠物狗”),但标记为需过滤噪声。

数学描述扰动过程为:

$$\tilde{x} = x + \epsilon_{\text{LLM}}$$

$$\text{s. t. } \text{sim}_{\text{SBERT}}(x, \tilde{x}) \geq 0.85$$

其中, ϵ 为 LLM 生成的语义保留型噪声。

3) 数据平衡优化

采用动态重加权策略调整数据分布。

$$\omega_i = \frac{\text{freq}(c_i)^{-0.5}}{\sum_j \text{freq}(c_j)^{-0.5}}$$

其中, c_i 为文本所属专利类别,用于缓解长尾分布问题。

3.3.2 质量过滤机制

为确保生成数据的有效性,构建了两级过滤管道。

1) 语义相似度过滤:使用 Sentence-BERT 计算余弦相似度。其计算式如下:

$$\text{sim}(s, e) = \frac{\phi(s)^T \phi(e)}{\|\phi(s)\| \|\phi(e)\|}$$

保留 $\text{sim}(s, e) \geq 0.8$ 的样本,过滤低质量生成对。

2) LLM 逻辑验证器:设计验证 Prompt 获取结构化反馈,仅保留 $\text{is_consistent} = \text{True}$ 且 $\text{conflict_points} = \emptyset$ 的样本。

3.3.3 与传统方法对比的优势

LACC 的数据生成机制突破了传统方法的三大局限。

1) 单向性突破:传统方法(如回译^[12])仅能生成单向增强数据,而 LACC 能生成可逆任务对 (x, y) ,支撑循环训练。

2) 噪声可控性:相比随机词替换^[13],LLM 引导的扰动 ϵ_{LLM} 能保持语义完整性 ($\text{sim} \geq 0.85$)。

3) 逻辑一致性保障:基于 CoT 的验证器检测到的隐性逻辑错误是传统方法的 3.2 倍(见第 4.3 节实验)。

3.4 动态协同训练框架

3.4.1 教师-学生协同架构

LACC 框架构建了双层协同训练系统,通过 LLM(教师)与边缘模型(学生)的动态交互实现知识迁移。

1) 教师 LLM:生成推理链(CoT),并形式化为逻辑路径序列。

$$\text{CoT}_t = \{s_1 \xrightarrow{r_1} s_2 \xrightarrow{r_2} \dots \xrightarrow{r_{n-1}} y\}$$

其中, s_i 为推理状态, r_i 为推理规则。

2) 学生模型:对齐教师模型的两类知识。

(1) 表层知识:最小化任务损失。

$$\mathcal{L}_{\text{task}} = -\log p(y|x)$$

(2) 深层知识:通过 KL 散度对齐推理路径分布。

$$\mathcal{L}_{\text{cot}} = \text{KL}(p_\theta(s_{1:n}|x) \parallel p_{\text{LLM}}(s_{1:n}|x))$$

3.4.2 动态验证触发机制

训练过程中实时监测生成质量,触发动态验证的条件为通过量化指标触发。

$$\text{Trigger}_1 = \text{ROUGE-L}(y, x) < 0.6 \vee \text{Conf}(y|x) < 0.3$$

当任一触发条件满足时,启动 LLM 验证流程。

3.4.3 奖励计算与策略优化

LLM 验证器输出结构化修正建议 $\Delta = \{\text{缺失实体, 逻辑$

错误, 改进建议\}, 将其量化为多维度奖励函数。

$$r = 0.5 \cdot F1_{\text{fact}} + 0.3 \cdot \text{Coherence}_{\text{LLM}} - 0.2 \cdot \text{Redundancy}$$

通过策略梯度算法,更新学生模型参数。

$$\nabla_\theta \mathcal{L}_{\text{RL}} = -\mathbb{E}_{(x, y) \sim \mathcal{D}} [r \cdot \nabla_\theta \log p_\theta(y|x)]$$

3.5 联合优化策略

LACC 框架通过加权融合多粒度优化目标实现联合训练,总损失函数定义为:

$$\mathcal{L}_{\text{total}} = 0.4 \cdot \mathcal{L}_{\text{cycle}} + 0.3 \cdot \mathcal{L}_{\text{task}} + 0.2 \cdot \mathcal{L}_{\text{CoT}} + 0.1 \cdot \mathcal{L}_{\text{RL}}$$

各损失项计算逻辑如下。

1) 循环一致性损失:

$$\mathcal{L}_{\text{cycle}} = \frac{1}{N} \sum_{i=1}^N (\|f_{\text{exp}}(f_{\text{sum}}(x_i)) - x_i\|_2 + \|f_{\text{sum}}(f_{\text{exp}}(y_i)) - y_i\|_2) n$$

2) 推理链对齐损失:

$$\mathcal{L}_{\text{cot}} = \text{KL-Divergence}(p_\theta(s_{1:n}|x) \parallel p_{\text{LLM}}(s_{1:n}|x))$$

3) 强化学习奖励损失:

$$\mathcal{L}_{\text{RL}} = -\mathbb{E}_{(x, y)} [r \cdot \log p_\theta(y|x)]$$

4) 基础任务损失:

$$\mathcal{L}_{\text{task}} = \text{CrossEntropy}(y_{\text{pred}}, y_{\text{true}})$$

4 实验及结果分析

4.1 实验设置

4.1.1 数据集

针对中文专利文本摘要领域高质量公开数据集匮乏的现状,本研究基于国家知识产权局主管的专利文献法定出版单位——知识产权出版社的权威数据源,构建了大规模中文专利文本摘要数据集(Chinese Patent Text Dataset, CPTD)。数据源为国家知识产权局,其专利文献的完整性和法律有效性为数据可靠性提供了根本保障。

本数据集共收录 2018—2023 年公开的发明专利与实用新型专利 160073 项,覆盖国际专利分类体系(IPC)A 部(人类生活必需)至 H 部(电学)全类别,确保技术领域的全面覆盖性。

在数据预处理阶段,本研究采用严格的质量控制标准。完整性过滤:剔除摘要文本长度小于 10 字符或权利要求书长度小于 100 字符的不完整样本。格式规范化:统一化学式、数学符号的编码格式。

经上述处理后,最终获得有效样本 159639 项,清洗保留率达 99.73%。如表 1 所列,数据集的 IPC 分类分布呈现均衡性特征,其中机械工程(B 部)占比 32.7%、电学(H 部)占比 28.4%、化学冶金(C 部)占比 19.1%,符合我国专利技术领域实际分布规律,验证了数据集的代表性与科学性。

之后,为适配不同规模的研究需求,本研究进一步从 CPTD 中采样,构建了 CPTD-Based 和 CPTD-LT 两个子数据集。

CPTD-Base:均匀采样 80000 条数据,确保各 IPC 分类均衡覆盖,适用于类别平衡场景下的模型验证。

CPTD-LT:按长尾分布^[23]采样 35500 条数据,模拟现实专利领域的长尾分布特性,用于研究数据不平衡问题下的算法鲁棒性。

表 1 CPTD 数据集信息

Table 1 CPTD dataset information

IPC 号	总数据量	CPTD-Base	CPTD-LT
A 部	19760	10000	10000
B 部	21199	10000	8000
C 部	20720	10000	6000
D 部	19508	10000	4000
E 部	21122	10000	3000
F 部	15921	10000	2000
G 部	21004	10000	1500
H 部	20405	10000	1000
总计	156439	80000	35500

4.1.2 实现细节

1) 训练配置

基础模型为 Qwen-2.5(1.5B 参数):采用官方预训练权重进行初始化;学习率为 2×10^{-5} (编码器)、 5×10^{-5} (解码器),批量大小为 16(梯度累积步数为 4),训练轮次为 50 次;优化器采用 AdamW($\beta_1=0.9, \beta_2=0.98$)。

2) 教师 LLM

基座模型为 GPT-4o-mini API;温度参数为 0.3(CoT 生成)、0.7(数据增强);最大生成长度为 512 tokens。

3) 动态验证

触发阈值为 ROUGE-L 小于 0.6 或置信度小于 0.3。

4.1.3 评估指标

本研究采用多维评估体系,结合通用文本生成指标与针对循环一致性指标,全面衡量模型在特征完整性、文本合理性、性能稳定性等方面的表现。

如表 2 所列,本文采用多项主流指标对模型性能进行评

估,包括 ROUGE-1, ROUGE-2, ROUGE-L, BERTScore, 以及基于 ROUGE-L 计算的循环一致性得分(RCS)。其中, ROUGE-1 与 ROUGE-2 分别衡量 1-gram 和 2-gram 层面的重合程度,反映基础词汇覆盖与局部搭配准确性; ROUGE-L 基于最长公共子序列进行匹配,兼顾词序信息,评估整体语义结构的一致性。BERTScore 则利用预训练语言模型对文本嵌入进行语义对齐,通过计算生成文本与参考文本之间的向量相似度,捕捉更深层次的语义等价性。

表 2 评估指标

Table 2 Evaluate metrics

指标	说明
ROUGE-1	基本词汇层面的重合程度
ROUGE-2	局部词组搭配的一致性
ROUGE-L	词序和整体结构上的匹配程度
BERTScore	计算语义向量相似度来衡量一致性
RCS	反映信息保持与语义一致性

此外,为评估模型在多步骤生成任务中的信息保持能力,本文引入循环一致性得分(RCS),通过摘要-扩写-重构的过程,计算重构文本与原始摘要之间的 ROUGE-L 得分,从而量化生成过程中语义信息的传递完整性与一致性。

4.2 实验结果

如表 3 所列, LACC 在 ROUGE-L 和循环一致性得分(RCS)上均显著优于基线模型与简化版本。同时还测试了仅保留循环一致性和数据增强两个核心模块的简化版模型的效果,结果显示,即使未集成动态验证机制, Ours-Lite 的 ROUGE-L 仍达到 55.93%, RCS 为 61.02%,较基线分别提升 17.1% 和 14.5%。

表 3 主实验结果

Table 3 Main experiment results

数据集	算法	(%)				
		ROUGE-1	ROUGE-2	ROUGE-L	BERTScore	RCS
CPTD-Base	Baseline	52.12	41.05	47.75	85.42	53.31
	LACC Lite	59.87	50.11	55.93	88.51	61.02
	LACC	61.34	51.62	56.74	89.12	62.13
CPTD-LT	Baseline	47.30	35.40	43.25	83.80	48.50
	LACC Lite	54.92	45.10	52.30	87.02	57.60
	LACC	56.45	46.73	53.48	87.80	58.70

从整体结果来看,基线模型(qwen-1.5b)在 CPTD-Base 上的 ROUGE-L 与 RCS 仅分别为 47.75% 和 53.31%,反映出其在文本生成过程中存在语序捕捉不足与多阶段信息传递失真问题。而引入循环一致性约束与数据增强策略的 LACC Lite 模型分别取得了 55.93% 和 61.02% 的指标值,表明其在生成文本与参考文本的匹配度以及信息保持稳定性方面均有显著提升。进一步完善后的完整模型 LACC 在 ROUGE-L 与 RCS 上取得了 56.74% 和 62.13% 的成绩,相较于简化版本在各项指标上均有小幅提升。

此外,将主实验扩展至长尾样本,构成更复杂的 CPTD-Longtail 数据集,以进一步验证模型在真实分布下的泛化能力。实验结果显示, LACC 在该数据集上依然有着优异表现, ROUGE-L 和 RCS 分别达到 53.48% 和 58.70%,显著优于基线模型的 43.25% 和 48.50%,提升幅度达 10.23 个百分点与 10.20 个百分点。LACC Lite 在该场景下的表现同样稳健,

取得 ROUGE-L 为 52.30%(+9.05 个百分点 vs. Baseline)、RCS 为 57.60%(+9.10 个百分点 vs. Baseline),再次证明了循环一致性约束与数据增强策略在提升生成质量和信息一致性方面的核心作用。

综上所述,实验结果充分证明了所提出的 LACC 框架在专利摘要生成任务中具备强大的通用性与鲁棒性,能够在不同数据分布条件下有效提升文本生成的语义完整性与稳定性,从而增强生成摘要在技术特征表达与法律语言传递方面的准确性。这也为其在专利审查、知识产权管理等下游任务中的广泛应用提供了有力的理论支持与实践基础。

4.3 消融实验

为进一步探究各个组件对整体性能的贡献,本研究设计了消融实验,对比分析了不同模块移除对模型表现的影响,结果如表 4 所列。

表 4 消融实验结果

Table 4 Ablation experiment results

数据集	算法	ROUGE-1	ROUGE-2	ROUGE-L	BERTScore	RCS
CPTD-Base	LACC	61.34	51.62	56.74	89.12	62.13
	-Cycle	53.20	42.30	50.10	87.12	57.20
	-Dyn. V	59.87	50.11	55.93	88.51	61.02
	-LLM Aug	58.20	48.80	55.20	88.20	60.5
CPTD-LT	LACC	56.45	46.73	53.48	87.80	58.70
	-Cycle	48.10	37.60	46.90	85.90	53.40
	-Dyn. V	54.92	45.10	52.30	87.02	57.60
	-LLM Aug	50.70	42.30	49.20	85.90	54.10

当移除循环一致性约束(Cycle)后,模型在 Rouge-L 和 RCS上分别下降至 50.1%和 57.2%,较完整模型分别降低 6.64 个百分点和 4.93 个百分点。这表明循环一致性约束在保障生成摘要的语义与信息传递稳定性方面起到了关键作用。进一步地,分别移除动态验证策略(Dyn. V)和大语言模型增强模块(LLM Aug),模型的 Rouge-L/RCS 分别下降 0.81 个百分点/1.11 个百分点和 1.54 个百分点/1.63 个百分点。虽然这两项调整对指标影响相对较小,但仍验证了动态验证机制和数据增强策略在细化文本信息和提升整体生成质量方面的积极贡献。

此外,为验证各模块在长尾分布数据上的泛化效果,进一步在 CPTD-LT 数据集上进行了消融实验。结果显示,LACC 模型在该数据集上取得了 53.48%的 Rouge-L 和 58.70%的 RCS,明显优于基线的 43.25%和 48.50%。当移除循环一致性约束后,模型性能下降更为明显,Rouge-L 与 RCS 分别下降 6.58 个百分点和 5.30 个百分点,凸显了该机制在长尾样本处理中的重要性。同样地,移除动态验证与 LLM 增强也带来了不同程度的性能退化,进一步验证了各组件对模型稳健性和表达力的贡献。

结束语 本文提出了一种融合循环一致性约束与大语言模型增强的端到端训练框架(LACC),针对专利摘要生成任务中的语义完整性、表述一致性与部署效率等难题,构建了摘要生成与权利要求扩写之间的双向闭环机制,并引入受控数据增强与动态验证模块,以系统化方式缓解数据稀缺与泛化能力不足的问题。实验结果表明,LACC 在 ROUGE-L 与循环一致性等关键指标上显著优于基线与简化模型,具备较强的语义对齐能力、生成稳定性与工业部署潜力。

未来可从 3 个方向进行拓展:1)引入图文联合建模机制,以提升模型在多模态专利场景中的表达理解与生成能力;2)发展更具控制性与安全性的自监督增强策略,以增强生成质量的一致性与可解释性;3)优化轻量化验证模块的推理性能,进一步推动模型在高频边缘计算与智能法务系统中的实用部署。

参考文献

[1] SEMERIKOV S O, VAKALIUK T A, KANEVSKA O B, et al. LLM on the edge: the new frontier[C]//Proceedings of the 5th Edge Computing Workshop(doors 2025), 2025: 137-161.

[2] FRIHA O, FERRAG M A, KANTARCI B, et al. LLM-based

edge intelligence: A comprehensive survey on architectures, applications, security and trustworthiness[J]. IEEE Open Journal of the Communications Society, 2024, 5: 5799-5856.

[3] LASKAR M T R, ALQAHTANI S, BARI M S, et al. A systematic survey and critical review on evaluating large language models: Challenges, limitations, and recommendations[C]//Proceedings of the 2024 Conference on Empirical Methods in Natural Language Processing, 2024: 13785-13816.

[4] ZHU J Y, PARK T, ISOLA P, et al. Unpaired Image-to-Image Translation Using Cycle-Consistent Adversarial Networks[C]//2017 IEEE International Conference on Computer Vision (ICCV), IEEE, 2017: 2242-2251.

[5] KIM B, KIM J, LEE J G, et al. Unsupervised Deformable Image Registration Using Cycle-Consistent CNN[C]//Medical Image Computing and Computer Assisted Intervention-MICCAI 2019, 2019.

[6] SHEN T X, LEI T, BARZILAY R, et al. Style Transfer from Non-Parallel Text by Cross-Alignment[C]//31st Conference on Neural Information Processing Systems(NIPS 2017), 2017.

[7] LIAN C, LI X, KONG L, et al. CoCycleReg: Collaborative Cycle-Consistency Method for Multi-Modal Medical Image Registration[J]. Neurocomputing, 2022, 500: 799-808.

[8] LI C Y, LI X M, KONG L K, et al. CoCycleReg: Collaborative Cycle-Consistency Method for Multi-Modal Medical Image Registration[J]. Neurocomputing, 2022, 500: 799-808.

[9] MA C, ZHANG W E, GUO M Y, et al. Multi-document Summarization Via Deep Learning Techniques: A Survey[J]. ACM Computing Surveys, 2023, 55(5): 1-37.

[10] WANG Z, WANG P, LIU K, et al. A comprehensive survey on data augmentation[J]. arXiv: 2405.09591, 2024.

[11] ZHOU Y, GUO C, WANG X, et al. A survey on data augmentation in large model era[J]. arXiv: 2401.15422, 2024.

[12] SCHICK T, SCHÜTZE H. Few-Shot Text Generation with Pattern-Exploiting Training[J]. arXiv: 2012.11926, 2020.

[13] WEI J, ZOU K. EDA: Easy Data Augmentation Techniques for Boosting Performance on Text Classification Tasks[C]//Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing, 2019: 6382-6388.

[14] DING B, QIN C, ZHAO R, et al. Data augmentation using LLMs: Data perspectives, learning paradigms and challenges [C]//Findings of the Association for Computational Linguistics

ACL 2024, 2024:1679-1705.

- [15] ZELIKMAN E, WU Y H, MU J, et al. STaR: Bootstrapping Reasoning with Reasoning[C]//NEURIPS 2022. 2022.
- [16] LOUIS D, VAN H, JAAP S, et al. Robust Deformable Image Registration Using Cycle-Consistent Implicit Representations [J]. IEEE Transactions on Medical Imaging, 2024, 43(2): 784-793.
- [17] RAMAKANTH P, ASLI C, MICHEL G, et al. Data Augmentation for Abstractive Query-Focused Multi-Document Summarization [J]. Computing Research Repository, 2021, 35(15): 13666-13674.
- [18] GOU J, YU B, MAYBANK S J, et al. Knowledge distillation: A survey[J]. International Journal of Computer Vision, 2021, 129(6): 1789-1819.
- [19] GEOFFREY H, ORIOL V, JEFF D. Distilling the Knowledge in a Neural Network[J]. arXiv:1503.02531, 2015.
- [20] KUMAR S, ALESSANDRO S, MRINMAYA S. Distilling Reasoning Capabilities into Smaller Language Models [J]. arXiv: 2212.00193, 2022.
- [21] LIU Z Y, SOUMYA S, ISABELLE L, et al. Self-Contradictory Reasoning Evaluation and Detection[J]. Association for Compu-

tational Linguistics, 2024(11): 3725-3742.

- [22] XU X, LI M, TAO C, et al. A survey on knowledge distillation of large language models[J]. arXiv:2402.13116, 2024.
- [23] ZHANG Y, KANG B, HOUI B, et al. Deep long-tailed learning: A survey[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(9): 10795-10816.



WU Qiaorui, born in 2001, postgraduate. His main research interests include large language models and model self-optimization.



ZHAO Cairong, born in 1981, Ph.D, professor, Ph.D supervisor, is a member of CCF(No. 24551D). His main research interests include artificial intelligence and computer vision.

(责任编辑:何杨)