

·人工智能在智能网联汽车中的应用技术专题·

基于人工智能大模型的驾乘人员行为意图识别研究

王文彬 尹佳伟 韩爽 刘航伶 何云廷

(中国第一汽车股份有限公司研发总院, 长春 130013)

【欢迎引用】王文彬, 尹佳伟, 韩爽, 等. 基于人工智能大模型的驾乘人员行为意图识别研究[J]. 汽车文摘, 2025(6): 24-29.

【Cite this paper】WANG W B, YIN J W, HAN S, et al. Research on Driver and Passenger Action Intent Recognition Based on Artificial Intelligence Models[J]. Automotive Digest (Chinese), 2025(6): 24-29.

【摘要】智能座舱的埋点数据蕴含丰富的驾乘人员行为信息, 分析和识别其中具体的行为意图有利于深入洞察用户需求。考虑到现有依赖人工标注的行为意图识别方法存在成本高、主观性强及工作重复的问题, 提出一种基于人工智能大模型的自动化标注和分类的方法。通过微调大模型 Qwen2-14B, 在多维度和多颗粒度上快速识别行为意图, 提高了云端数据分析效率, 为在车端实时响应用户需求奠定理论基础。

关键词: 人工智能大模型; 行为意图识别; 智能座舱; 埋点数据; 自动化标注

中图分类号: U495

文献标志码: A

DOI: 10.19822/j.cnki.1671-6329.20240282

Research on Driver and Passenger Action Intent Recognition Based on Artificial Intelligence Models

Wang Wenbin, Yin Jiawei, Han Shuang, Liu Hangling, He Yunting

(Global R&D Center, China FAW Corporation Limited, Changchun 130013)

【Abstract】The event-tracking data of intelligent cockpit contains rich information about driver and passenger actions. Analyzing and identifying specific action intents can benefit deeper insights into user needs. Considering the high cost, strong subjectivity, and repetitiveness of current methods that rely on manual tagging for action intent recognition, a new method based on Artificial Intelligence model for automated tagging and classification is proposed. By fine-tuning the Qwen2-14B model, this approach could rapidly identify action intents across multiple dimensions and granularities, enhance the efficiency of cloud data analysis and lay a theoretical foundation for real-time response to user needs on the vehicle side.

Key words: Artificial Intelligence models, Action intent recognition, Intelligent cockpit, Tracking data, Automated tagging

0 引言

随着汽车工业的飞速发展和用户需求的不断增长, 汽车座舱已经迈入智能化时代。智能座舱依托先进的信息技术和人机交互技术, 显著提升了车辆的操控体验。为实现精准服务推送与驾驶辅助, 理解并识别驾乘人员的行为意图至关重要。近年来, 国内外学者深入研究了驾驶员的驾驶意图识别, 如换道^[1-2]、超车^[3]、转向^[4]和制动^[5-6]意图, 有效提升了驾驶安全性。然而, 针对座舱内驾乘人员的操作行为意图识别研究仍不系统。为了提供全方位的智能化服务, 除了开展驾驶意图研究, 还应深入研究驾乘人

员的其他行为意图识别。目前, 对用户其他行为意图的分析主要依赖于人工标注埋点数据, 即人工对反映驾乘人员行为信息的埋点数据^[7]进行标记和分类, 此过程耗时且易受主观因素影响^[8-9]。人工智能大模型在文字识别、图像处理等多个领域展现了巨大潜力和应用价值^[11-14], 其强大的数据处理能力和上下文理解能力为用户行为意图识别提供了新的思路。利用人工智能大模型进行自动化标注, 不仅能有效降低人工成本, 还能从多维度更客观地观察用户行为, 更精准地判断用户行为意图, 从而提高识别效率和准确性。

本研究聚焦利用人工智能大模型分析座舱埋点

数据,提出适用于埋点数据标注和分类的大模型应用架构。通过多维度、多颗粒度层面的行为意图识别与理解,深入洞察用户需求,优化座舱服务。同时,本研究将探讨该技术在未来智能座舱中的应用前景,剖析其在提升汽车智能化水平方面的潜力与挑战,以拓展大模型在汽车领域的应用边界,为智能座舱的未来发展提供理论支持与技术保障。

1 驾乘人员行为意图识别

1.1 座舱埋点数据

座舱埋点数据是由智能座舱系统中预设的数据收集点自动采集到的用户数据,涵盖多个维度的信息,包括用户特征(如用户ID、家庭地址)、操作行为(如车控车设、多媒体)、环境状态(如车内温度、车内空气质量)等,形成全方位的驾乘人员用车数据集,为后续的行为意图分析提供了基础。

1.2 用户行为挖掘

为了确保埋点数据可用性,需进行数据清洗,去除无效信息,得到用户行程操作序列列表。进一步挖掘数据时发现,由于空调、多媒体等行为高频出现,不同场景下的关联行为较为相似,这些常用功能数据可能掩盖用户间的差异性行为,且单独关联行为在分析用户意图时信息量有限。因此,要深入理解用户意图,需要继续挖掘行为的关联行为,将单一行为变为有前后顺序的行为链(见图1)。通过分析这些连续行为间的逻辑关系和时间序列,可以更精确地描绘出用户的完整行为模式和背后意图。

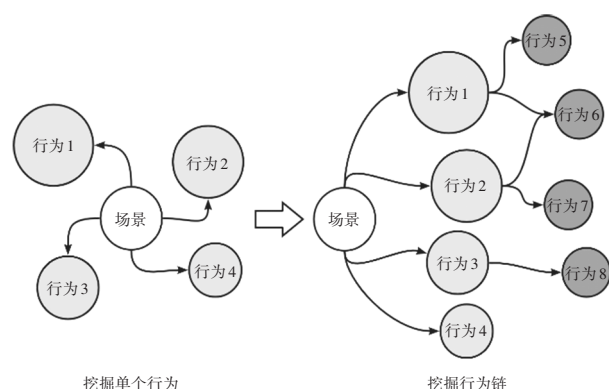


图1 用户行为挖掘示意

1.3 现有意图识别方法

在相同场景下,通常可以挖掘出多条行为链。然而,复杂的行为链不利于快速判断用户行为意图。为了从宏观角度高效识别用户行为目的,需要对行为链进行标注和分类处理,从而便于总结用户行为规律。不同业务团队的数据分析视角差异显著,因此同一行

为链可能因业务需求不同而被赋予多个分类标签。例如,表1展示了针对不同业务需求的用户行为链意图标记和分类。在“车内温度_炎热”场景下挖掘出4条行为链:行为链“车内温度_炎热→座椅调节_通风_主驾→座椅调节_通风_副驾”;在座舱座椅调节业务中标记为“主驾座椅调节,副驾座椅调节”;在座舱舒适度业务中标记为“降温,座椅调节”;行为链“车内温度_炎热→设置空调风量”不涉及座椅调节,则无需在该业务层面进行标注。

表1 用户行为链意图标记和分类

场景	关联行为	关联行为	意图分类	
			座椅调节分析	舒适度分析
车内温度_炎热	座椅调节_通风_主驾	座椅调节_通风_副驾	主驾座椅调节 副驾座椅调节	降温 座椅调节
	座椅调节_通风_主驾	设置空调风量	主驾座椅调节	降温 座椅调节
	设置空调温度	座椅调节_按摩_副驾	副驾座椅调节	降温 按摩 座椅调节
	设置空调风量			降温

当前采用人工标注分类(完整流程如图2所示),在业务和用户体验维度对行为链意图进行标注,形成行为意图分类。这些分类一方面用于生成分析报告和可视化展示,另一方面便于对关键行为和标签进行监控,从而助力业务团队洞察用户在不同维度的体验需求。

然而,人工标注存在成本高、主观性强和工作重复的问题,具体阐述如下。

(1)成本高:高质量的标注需要专业人员进行深入分析,人力和时间成本消耗大,特别是对于大规模数据集而言,成本显著增加。

(2)主观性强:受个人主观意见影响,难以保持客观性,导致数据的偏见,而且不同标注人员对同一行为的理解可能不同,导致标注结果不一致。

(3)工作重复:在对新的数据集进行分析时,如果没有自动化标注脚本或数据比较复杂,需要重新进行标注。

相较之下,经分类任务微调的人工智能大模型可有效解决上述问题。其自我学习机制能够依据人工标注标准自动化标注数据,能够高效、客观地识别行为意图。同时,该模型能从新数据集中提取新标签,扩充标签体系,满足更多业务分析需求。

2 人工智能大模型在行为意图识别的应用

目前,国内外已推出上百个开源的预训练大模

型,国外大模型大多基于英文数据训练,在中文文本理解和回答上缺乏很强的通用性^[15],而且通常会受IP属地限制。然而,国产大模型对中文词义具有更高敏感性,包括更强的语境理解能力、文化适应性、语法解析能力等,有更顺畅的交互体验^[16]。本文从中文语料中识别行为意图,选择整体性能相对均衡的国产大模型 Qwen2-14B^[17]进一步训练。整体技术路线如图3所示。

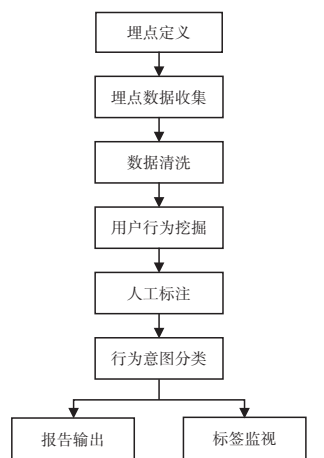


图2 人工标注行为意图分类流程

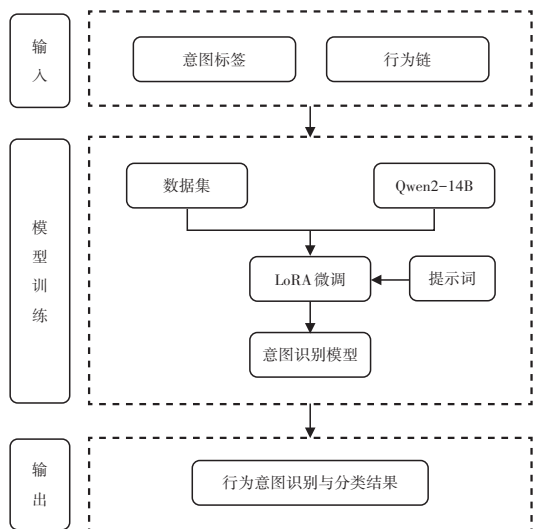


图3 大模型行为意图识别技术路线

2.1 模型训练

大模型微调是在预训练大模型的基础上,针对特定任务或领域进一步训练。相比于需要更新大模型所有参数的全量微调,参数高效微调只需调整少量或额外的参数,有效降低训练成本^[18,19]。本文采用参数高效微调中的低秩适应(Low-Rank Adaptation, LoRA)来提高 Qwen2-14B 在行为意图识别中的性能。LoRA 的核心在于向模型权重矩阵引入低秩矩阵,以此调整模型内部权重,实现参数高效更新。在保持模型原有结构的同时,它能够在小样本数据条

件下实现有效学习。Hu 等^[20]在多种模型和数据集上对比 LoRA 与全量微调及其他参数高效微调方法(Bitfit、Adapter、Prefix Tuning),试验结果表明,LoRA 在训练参数远少于全量微调的情况下,能达到相同甚至更优的性能,在任务表现上也优于其他轻量级微调方法。

2.1.1 数据集

为确保微调数据的多样性和代表性,本文采用人工标注和模型生成的方式构建数据集。将已通过人工标注的行为样本整理为 Qwen2-14B 微调数据集的目标格式,让大模型根据人工标注的样本生成相同格式的数据,对生成结果进行人工审核,筛选出符合要求的样本。构建出包含 2 000 条样本的数据集,涵盖多种驾驶场景下用户的行为,标签来自各种业务预设的行为意图类别。表2为样本示例,每条样本包含输入和输出,输入内容为主要意图标签、具体意图标签和行为链,输出内容是行为链的主要意图和具体意图。数据集分为训练集、验证集和测试集,样本数量分别为 1 600、200 和 200,样本之间相互独立。训练集用于模型训练和学习,调整权重和参数;验证集和测试集用于在训练过程中和训练完成后评估模型性能。

表2 模型微调数据集样本示例

	主要意图标签	导航,辅助驾驶
输入	具体意图标签	设置目的地,设置途径点,路线规划,路线调整,实时路况,避开拥堵,车道保持,自适应巡航,自动泊车,盲点监测,碰撞预警
	行为链	搜索面板回家入口点击,导航开始,切换导航路线
输出	主要意图	导航
	具体意图	设置目的地,路线调整

2.1.2 LoRA 微调

在 Hugging Face 平台对 Qwen2-14B 模型进行 LoRA 微调。指定模型、数据集和输出路径后,加载预训练模型权重,设置 LoRA 低秩矩阵的秩为 4,冻结模型原始参数,仅训练新增的低秩矩阵及少量适配层参数,以降低显存占用和计算成本。训练总步数为 500,训练过程中,采用 AdamW 优化器,结合余弦退火学习率调度器(初始学习率为 5×10^{-5}),动态调整学习率以平衡收敛速度与稳定性。每 8 个训练批次进行一次梯度累积,缓解显存压力。每 20 步保存一次模型权重,并同步在验证集上评估性能,避免过拟合。关键参数设置如表 3 所示,涵盖秩、训练轮数、批次大小等核心配置。

表3 LoRA微调关键参数设置

参数	参数值
秩(lora_r)	4
训练轮数(num_train_epochs)	20
训练批次大小(per_device_train_batch_size)	8
验证批次大小(per_device_eval_batch_size)	8
梯度累积步数(gradient_accumulation_steps)	8
学习率(learning_rate)	5×10^{-5}
权重衰减(weight_decay)	0.1
学习率调度器(lr_scheduler_type)	cosine
保存间隔步数(save_steps)	20
验证间隔步数(eval_steps)	20

图4和图5展示了训练过程中损失值和学习率的变化情况。如图4所示,在训练初期,损失值迅速降低,表明模型在快速适应意图识别任务。随着训练步数的增加,损失值逐渐趋于平稳,表明模型接近收敛。结合图5的学习率变化曲线,学习率按照余弦退火的方式逐渐衰减至零,这种动态调整学习率的策略有助于模型在训练初期快速收敛,在后期使用较低的学习率实现参数精细调整,避免剧烈震荡导致的训练不稳定。




图4 模型训练损失值变化




图5 模型训练学习率变化

图6展示了模型在验证集上主要意图、具体意图和整体输出准确率随训练步数的变化情况。3条曲线均呈上升趋势,说明模型在训练过程中意图识别的准确率不断提高。主要意图识别准确率从42.2%上升到95.1%,提升52.9%;具体意图识别准确率从31.5%上升到91.2%,提升59.7%;整体输出准确率从25.7%上升

到89.0%,提升63.3%。可以看出模型在行为意图识别任务上取得了显著的性能提升,尤其是在整体任务中提升幅度最大,以较高的准确率同时识别主要意图和具体意图。

模型完成微调后,在独立测试集上评估其行为意图识别性能。测试结果表明,主要意图、具体意图和整体输出准确率分别为94.3%、89.8%、88.4%,与验证集的结果相比,在测试集上性能略有下降但差异较小,表明模型未对验证集过拟合,具有较强的鲁棒性。




图6 模型训练在验证集上输出结果准确率

2.2 提示词设计

在与大模型交互过程中,提示词的设计对模型识别行为意图的能力有着直接影响。提示词作为输入信息,能够引导模型执行特定的任务,还决定模型输出的准确性和相关性。为了使Qwen2-14B充分理解任务需求,本研究中的提示词结构包含角色、技能、限制、输入输出缩写解释和示例5个要素,具体内容如表4所示。设定角色、技能和限制是为了明确模型在交互中的身份和视角,聚焦于意图识别和分类任务;定义输入输出的缩写有助于模型和用户达成一致理解,准确传递信息;具体的输入输出示例提供具体的上下文和格式化的反馈,帮助模型学习和模仿期望的交互模式,要求输入业务分析预设的主要意图标签和具体意图标签,以及需识别意图的行为链,输出为识别出的主要意图和具体意图。

2.3 模型识别结果

为了验证微调后的Qwen2-14B在行为意图识别任务上的性能,对其识别结果进行验证。

首先挖掘场景“车内温度_冷”的关联行为,找出7条关联的行为链,针对座舱舒适度分析业务识别行为链的意图,预设的主要意图和具体意图标签与表4中的例1相同,将7条行为链输入到模型中,模型识别出的意图结果如表5所示,与人工标注结果基本一致。“打开空调”单个行为在不同场景下的意图差距很大,本研究中的模型能理解动作之间的逻辑关系和上下

表4 大模型识别用户意图提示词内容

组成要素	内容
角色	你是一位驾乘行为分析师,专注于解读座舱内驾乘人员的行为模式,以识别其背后的意图并进行分类。
技能	1. 意图解析:基于行为链,你需要深入分析驾乘人员的根本需求与期望,从而识别出他们行为背后的主要意图与具体意图。 2. 标签匹配:你需要优先从预设的主要意图与具体意图标签中对识别出来的意图进行分类,确保分类准确无误;如果识别出来的意图不在标签中,可以根据你的理解新增标签。 3. 结构化输出:将分析结果结构化呈现,便于后续理解和应用,输出为标准正确的JSON格式字符串。
限制	1. 分析范围限定于座舱内行为,不得扩展至外部或非相关场景。 2. 输出意图需严格基于输入标签进行匹配,若标签不全则需自行扩充,但必须保持标签的一致性和逻辑性。 3. 分析过程需充分考虑行为间的上下文依赖关系,确保意图识别的准确性与全面性。
输入输出缩写解释	MIT:Main Intent Tag,主要意图标签 SIT:Specific Intent Tag,具体意图标签 MI:Main Intent,主要意图 SI:Specific Intent,具体意图 AC:Action Chain,行为链
示例	例1 输入:{"MIT":["提高舒适度"],"SIT":["升温","降温","噪声控制","改善空气质量","座椅调节","休息","按摩"], "AC":["车内温度_炎热","座椅调节_通风_主驾","座椅调节_按摩_主驾"]} 输出:{"MI":["提高舒适度"],"SI":["降温","按摩","座椅调节"]} 例2 输入:{"MIT":["座椅调节","车窗调节"],"SIT":["主驾座椅调节","副驾座椅调节","后排座椅调节","主驾开窗"," 主驾关窗","副驾开窗","副驾关窗","后排开窗","后排关窗"],"AC":["座椅调节_通风_主驾","座椅调节_通风_副 驾"]} 输出:{"MI":["座椅调节"],"SI":["主驾座椅调节","副驾座椅调节"]}

文依赖,根据车内温度为冷的场景信息,准确识别出具体意图为升温;在“车内温度_冷,打开空调,音乐卡片_播放”行为意图识别中,未在预设标签匹配到“音乐卡片_播放”的意图,模型自主新增主要意图标签“休闲娱乐”和具体意图标签“播放音乐”,体现了模型的泛化能力。

表5 模型行为意图识别示例

场景	行为1	行为2	主要意图	具体意图
车内温度_冷	打开空调	-	提高舒适度	升温
车内温度_冷	打开转向盘加热	-	提高舒适度	升温
车内温度_冷	座椅调节_加热_主驾	打开转向盘加热	提高舒适度	升温 座椅调节
车内温度_冷	关闭所有车窗	打开空调	提高舒适度	升温
车内温度_冷	设置空调温度	设置空调风量	提高舒适度	升温
车内温度_冷	座椅调节_加热_主驾	座椅调节_加热_副驾	提高舒适度	升温 座椅调节
车内温度_冷	打开空调	音乐卡片_播放	提高舒适度 休闲娱乐	升温 播放音乐

基于模型识别,可以实现行为链在具体和主要意图的快速分类,便于从微观到宏观观察用户行为,图7为上述行为链意图识别由小到大颗粒度的分类展示。对“车内温度_冷”场景关联的7条行为链按照意图归类,可以用3个标签(升温,座椅调节,播放音乐)概括

用户操作行为的具体意图,进一步总结具体意图,得到用户的主要意图为提高舒适度和休闲娱乐。

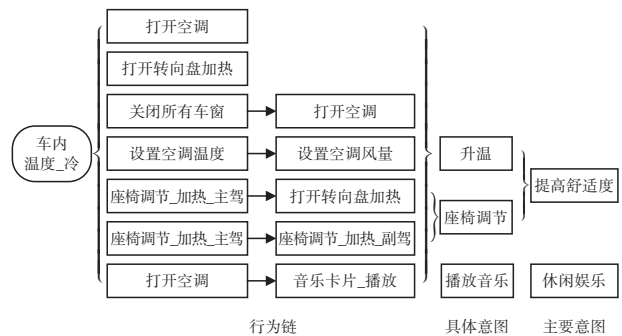


图7 行为链意图识别分类展示

微调后 Qwen2-14B 大模型的识别结果证明其在行为意图识别任务上具有较高的准确性和泛化能力,能够有效识别和分类复杂驾驶场景下的行为模式,为未来智能座舱设计和优化提供有力支持。

3 结束语

在本文通过 LoRA 微调国产大模型 Qwen2-14B,并设计提示词,构建了自动标注和分类驾乘人员行为意图的技术框架。试验结果表明,该技术显著提高了数据分析效率,能够准确识别用户行为模式和意图,并在多维度、多颗粒度上提供分类展示,为深入洞察座舱内用户需求提供了有力支持。然而,当前模型仍处于开发阶段,识别精度在某些特定场景下有待提

高。未来,随着人工智能大模型的持续进步,驾乘人员行为意图识别技术在智能座舱中的应用前景将更为广阔。下一步的研究将重点关注两个方向:一是融合座舱内的多模态数据,如文本、视觉(面部表情、手势)、听觉(语音指令、语音情绪)和生理信号(心率、体温)等,以提升复杂环境下的识别精度;二是利用端云协同技术优化意图识别模型,实现模型轻量化并部署于车端设备,使其在算力有限的环境中仍能高效运行,实现实时意图识别与服务响应。后续工作将继续优化调试模型,以进一步提升其识别速度和准确性。

参 考 文 献

- [1] GRIESBACH K, HOFFMANN K H, BEGGIATO M. Prediction of Lane Change by Echo State Networks[J]. Transportation Research Part C, 2020, 121: 102841.
- [2] 苑仁腾,王晨竹,项乔君,等. 轨迹数据驱动的车辆换道意图识别模型[J]. 华南理工大学学报(自然科学版), 2024, 52(6): 34-44.
- [3] 李君羨,王浩,沈宙彪,等. 城市道路超车特征分析与高风险超车识别[J]. 同济大学学报(自然科学版), 2022, 50(9): 1312-1320+1346.
- [4] PHILLIPS D J, WHEELER T A, KOCHENDERFER M J. Generalizable Intention Prediction of Human Drivers at Intersections[C]// 2017 IEEE Intelligent Vehicles Symposium (IV). Los Angeles, CA: IEEE, 2017: 1665-1670.
- [5] LI X, MA J, ZHAO X, et al. Research on Characteristic Parameter Selection and Attention-GRU-Based Model for Braking Intention Identification[C]// Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering, 2024, 238(6): 1654-1669.
- [6] 潘宁,于良耀,宋健. 考虑舒适性的电动汽车制动意图分类与识别方法[J]. 清华大学学报(自然科学版), 2016, 56(10): 1097-1103.
- [7] 韦保俊,陈长健,黄桂容. 车联网埋点设计流程问题及其优化方法[J]. 时代汽车, 2021(24): 15-16.
- [8] WALL E, DAS S, CHAWLA R, et al. Podium: Ranking Data Using Mixed-Initiative Visual Analytics[J]. IEEE Transactions on Visualization and Computer Graphics, 2017, 24(1): 288-297.
- [9] 孙嘉顺,翁罗轩,刘实,等. 基于成对关系的埋点数据可视化标注系统[J]. 浙江大学学报(理学版), 2024, 51(4): 472-482.
- [10] 周涛,李鑫,周俊临,等. 大模型智能体:概念、前沿和工业实践[J]. 电子科技大学学报(社科版), 2024, 26(4): 57-62.
- [11] 温馨,张超,郭锐,等. 推动我国大模型开源创新生态建设的挑战与建议[J]. 中国科学院院刊, 2024, 39(8): 1313-1326.
- [12] ZHU Z, LIN K, JAIN A K, et al. Transfer Learning in Deep Reinforcement Learning: A Survey[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(11): 13344-13362.
- [13] VASWANI A, SHAZEER N, PARMAR N, et al. Attention Is All You Need[EB/OL]. (2017-06-12) [2024-09-19]. <https://doi.org/10.48550/arXiv.1706.03762>.
- [14] 秦龙,武万森,刘丹,等. 基于大语言模型的复杂任务自主规划处理框架[J]. 自动化学报, 2024, 50(4): 862-872.
- [15] 李莉,时榕良,郭旭,等. 融合大模型与图神经网络的电力设备缺陷诊断[J]. 计算机科学与探索, 2024, 18(10): 2643-2655.
- [16] 夏丽云,岳于佳,徐敏赞,等. 生成式人工智能应用于编校工作的探索与分析—基于 ChatGPT 和 150 余款国产大模型的实测[J]. 中国科技期刊研究, 2024, 35(7): 948-956.
- [17] BAI J, BAI S, CHU Y, et al. Qwen Technical Report[EB/OL]. (2023-09-28) [2024-09-19]. <https://doi.org/10.48550/arXiv.2309.16609>.
- [18] 谢思静,文鼎柱. 基于联邦分割学习与低秩适应的 RoBERTa 预训练模型微调方法[J]. 数据采集与处理, 2024, 39(3): 577-587.
- [19] 张钦彤,王昱超,王鹤羲,等. 大语言模型微调技术的研究综述[J]. 计算机工程与应用, 2024, 60(17): 17-33.
- [20] HU E, SHEN Y, WALLIS P, et al. LoRA: Low-Rank Adaptation of Large Language Models[EB/OL]. (2021-06-17) [2024-09-19]. <https://doi.org/10.48550/arXiv.2106.09685>.

(责任编辑 明慧)