

基于大模型上下文学习的未知意图识别方法

孙颢原¹, 刘莹君², 于莉娜², 纪涛², 张圳锡¹, 吴继冰¹

(1. 国防科技大学 大数据与决策国家级重点实验室, 湖南 长沙 410073;

2. 智能空间信息国家级重点实验室, 北京 100029)

摘要: 面对现代化战争的复杂态势, 精准的意图识别技术可实现对指挥人员需求的高效理解与精准捕捉, 提升决策准确率和敏捷性。现有意图识别方法通常需要大量人工标注的数据进行训练, 带来了高昂的成本, 并且对于新意图的识别效果较差。为此, 提出了基于大语言模型 (Large Language Models, LLMs) 上下文学习的创新解决办法, 充分利用大模型的通用语言能力和指令遵循能力, 仅需使用少量样本并无需训练, 便可完成已知意图识别与新意图发现任务, 为意图识别提供了一种新型高效的解决方案。

关键词: 大语言模型; 上下文学习; 提示词工程; 意图识别

中图分类号: TP181.132

文献标识码: A

DOI: 10.19358/j.issn.2097-1788.2025.11.007

引用格式: 孙颢原, 刘莹君, 于莉娜, 等. 基于大模型上下文学习的未知意图识别方法 [J]. 网络安全与数据治理, 2025, 44(11): 38-44.

Intent recognition method based on in-context learning of large language models

Sun Haoyuan¹, Liu Yingjun², Yu Lina², Ji Tao², Zhang Zhenxi¹, Wu Jibing¹

(1. National Key Laboratory of Big Data and Decision, National University of Defense Technology, Changsha 410073, China;

2. National Key Laboratory of Intelligent Geospatial Information, Beijing 100029, China)

Abstract: In the face of the complex situation of modern warfare, accurate intent recognition technology can achieve efficient understanding and precise capture of commanders' needs, thereby enhancing the accuracy and agility of military decision-making. Existing intent recognition methods typically require large amounts of manually annotated data for training, which incurs high costs and performs poorly in recognizing novel intents. To address these issues, this paper proposes an innovative solution based on large language models (LLMs) and their in-context learning capability. By leveraging the general language understanding and instruction-following abilities of LLMs, the proposed approach can accomplish both known intent recognition and novel intent discovery tasks using only a small number of examples without requiring additional training, thus offering a new and efficient solution for intent recognition.

Key words: large language model; in-context learning; prompt engineering; intent recognition

0 引言

自然语言处理 (Natural Language Processing, NLP) 是人工智能的重点研究方向, 其研究目标是赋予计算机理解、解析及生成人类语言的能力, 是实现人机自然交互的关键技术。早期 NLP 研究主要依赖规则系统与统计方法, 随着深度学习技术的兴起, 逐步发展为基于神经网络的表示学习范式, 而当前大规模预训练语言模型已成为该领域的主流研究方向^[1-2]。这一系列技术演进推动了智能客服、搜索引擎、智能助手等应用的广泛落地, 显著革新了人机交互模式^[3-5]。

在 NLP 的诸多任务中, 意图识别是对话系统的基础环节^[6]。意图识别旨在确定用户输入的文字中所蕴含的意图或目的, 即对用户的话语进行语义理解, 以便更好地回答用户的问题或提供相关的服务。然而, 意图识别通常面临着一系列问题的挑战, 包括用户语言表达的易混淆性、意图在不同上下文语境中的差异性以及持续出现的新意图等。

研究人员针对意图识别问题开展了大量的研究, 主要集中在传统机器学习方法^[4]、深度学习方法^[2,7]与基于大模型的意图识别方法。传统机器学习方法如支持向量

1.1.2 自动提示词生成过程

自动提示生成由上下文提示生成器驱动，其中核心是利用大模型自动创建意图发现任务的通用模型。首先上下文生成器从训练数据中提取领域的特征和少量的意图示例，并结合任务规范构建输入的提示。然后通过与 Qwen 等大模型进行交互，使其能够生成包含任务定义、分类规则以及输出正确格式的结构化提示，例如明确优先匹配已知意图，无法匹配时构建新意图的逻辑，并强制输出 JSON 格式结果。

1.1.3 提示词设计

本文使用 Qwen-turbo 大模型来设计上下文感知提示词，并描述了使用多个上下文示例设计提示的任务。为每个已知意图注入 $x=2$ 个随机样本，为大模型提供上下文背景信息。生成的提示如图 2 所示，在对意图发现任务的大语言模型进行推理期间用作意图发现的指南。

```
请对# {domain}领域进行意图分类，AI语言模型，你的任务是将正确的意图分配给给定的文本话语。意图可以是预定义的意图之一或者你根据上下文和知识创建的一个新的问题和具体的数据域。对于每句话，分析上下文和具体要求或行动暗示。如果话语与已知意图匹配，则将其分配给这个意图。如果它不符合任何已知的意图，则创建一个新的准确表示以下内容所暗示的请求或行为的意图话语。记住，目标是准确理解用户的意图。了解已知的意图，并尽可能多地重用它们。
如果不一致请重新建立一个新意图
1. 已知意图列表
{intent_list}
2. 少样本示例(按意图分组)
{example_list}
3. 待分类语句
"{test utterance}"
4. 分类规则
• 1. 优先匹配已知意图: {'',join(sorted(known_intents))}
• 2. 新意图必须符合小写动词_名词格式(如check_balance)
• 3. 绝对禁止使用unknown,oos等模糊标签
• 4. 输出必须是合法JSON对象，包含"utterance"和"intent"字段
5. 输出格式要求
{{
  "utterance": "用户语句",
  "intent": "意图标签"
}}
```

图 2 大模型生产的提示词

1.2 少样本采集系统

图 3 为少样本采集系统的全部流程。少样本采集系统通过训练集选择少量样本池，根据已知意图结合语义检索技术选择出相似样本示例。大模型根据相似样本示例、测试样例与已知意图反馈最终生成上下文大语言模型提示词，为后续的意图识别机制提供了基础。




图 3 少样本采集系统流程图

1.2.1 候选数据池的构建与管理

少样本采集系统的核心是一个预先设定的“少样本池”，这个数据池专门为 AutoIntent 在少样本学习场景提供具有代表性的备用样本。

在本文所用方法中，少样本数据池会在训练数据的每个已知意图中选取部分样本，例如采用每个意图的样本数 (few_shot) 为 10，数据池就会从中挑选 10 条语句作为储备样本。

这种设计可以平衡计算效率与样本质量的关系，一方面，模型只需在 10 条样本范围内检索，这大大减少了实时计算量，减少了人力与物力成本；另一方面，每个意图至少保留了少量样例，确保模型在识别时能够获取必要的基础数据支撑，避免因样本不足导致的识别偏差，为少样本场景下的意图识别提供了实用的解决方案。

1.2.2 语义嵌入与向量空间构建

少样本采集系统采用预训练的句子嵌入模型 SentenceBERT 的“all-MiniLM-L6-v2 嵌入模型”^[16] 作为语义编码工具。本方案采用的语义相似性样本筛选技术，核心在于通过语义空间映射实现训练数据的高效检索，其核心机制是将自然语言语句转化为结构化语义向量，通过量化向量空间中的语义关联度，为少样本场景下的意图识别提供支撑。该技术依托深度神经网络构建语义编码模型，将输入语句映射为固定维度的高维稠密向量，使语义相近的语句在向量空间中形成局部聚类，具体通过余弦相似度指标衡量语句间的语义关联——语义越接近的语句，向量表示的余弦距离越小。通过这个高效的检索

算法来快速找到与测试语句最相似的少量样本。其次，使用 KNN 算法进行检索少量样本和已知意图，核心思想是通过计算目标样本与训练集中各样本的距离，选择距离最近的 K 个邻居。

1.3 已知意图反馈

已知意图反馈是 AutoIntent 框架中实现动态意图管理的核心机制，其设计目标是通过实时注入已知和新发现的意图信息，增强大语言模型在推理过程中对意图发现的感知能力，从而提升意图分类的准确性和新意图发现的一致性。本小节将介绍已知意图反馈的核心机制。

系统初始化时包含预设的已知意图集合 T_{known} ，这些意图通过训练数据中的标注样本构建。

在每次推理完成后，模型预测的新意图 T_{new} 会经过语义词法验证（如是否符合“动词_名词”结构）和去重处理，随后合并到 T_{known} 中，形成更新后的意图数据库。

$$T_{\text{updated}} = T_{\text{known}} \cup T_{\text{new}} \quad (1)$$

假设初始已知意图包含“book_flight”（预订航班），当模型对“安排去巴黎的航班”生成新意图“schedule_flight”时，该意图会被验证并加入数据库，后续推理中模型会优先匹配“book_flight”或“schedule_flight”，而非重复生成相似意图。

1.4 意图预测器

意图预测器是 AutoIntent 方法框架的核心组件。其核心功能是基于生成的提示信息以及少量的样本，对输入语句进行语义分析，以判定其所属的意图类别，同时其具备识别潜在新意图的能力。

意图预测器首先会收到由上下文提示生成器给出的通用提示。提示里包含任务要求、分类规则以及输出格式等关键信息。同时，少样本采集系统筛选出一些与测试语句语义比较相近的样本，为模型提供多维度参考示例以辅助理解意图特征。当有需要分析的语句传进来时，意图预测器会综合通用提示和少样本示例，凭借大语言模型出色的语义理解和推理能力，将语句与已知意图进行比对，若存在语义匹配则输出对应意图类别；若判定语句与已知意图存在显著差异，则按预设格式创建新意图并同步至已知意图集合。

2 实验结果及分析

2.1 数据集介绍

本次实验共使用两种数据集评估 AutoIntent，分别是 CLINC 数据集^[17]与 BANKING 数据集。

本研究还构建了两套基于军事场景的意图识别数据集，分别为简单军事意图识别数据集与易混淆军事意图

识别数据集。其中，简单意图识别数据集以短文本为特征，语义结构清晰易理解，例如“按照计划组织两栖登陆任务”对应“两栖登陆”的意图标注；而易混淆意图识别数据集则更加复杂，数据集中的每条样本均包含易引发语义混淆的自然语言表述，其文本内容在句法结构、词汇语义、语用情境等维度呈现高度相似性，旨在模拟现实场景中因信息噪声、表述歧义、语义重叠等因素导致的意图识别挑战。

2.2 实验评估指标

本文采用 Zhang 等人提出的评估框架^[18]，采用三个聚类评估指标：聚类准确率（Accuracy，ACC）、标准化互信息（Normalized Mutual Information，NMI）和调整兰德指数（Adjusted Rand Index，ARI），分别从不同维度衡量聚类结果与真实标签的一致性。

2.3 AutoIntent 方法对比实验

本节对全文基于大语言模型的意图识别方法进行性能对比实验，以确保实验方法的有效性。

表 1 为本文基于大语言模型的意图识别方法在 0-shot、10-shot 和 50-shot 设置下的性能。对于 0-shot 设置，不使用任何的样本示例，提示词只是简单地描述一下任务并且激活已知意图反馈来重新利用意图。在 10-shot 和 50-shot 的设置中，每次迭代都使用语义小样本采样和已知意图反馈。值得注意的是 AutoIntent 模型在 0-shot、10-shot 和 50-shot 设置下均展现出了卓越的性能。在 0-shot 设置中，模型凭借其强大的语言理解和生成能力，仅依靠任务描述和已知意图反馈，无需任何样本示例，就能准确地对用户语句进行意图分类，其中在 CLINC 数据集上的准确率达到 77%。DeepSeek 在 50-shot 的情况下在 CLINC 数据集上的准确率达到了 92.16%，远远超过了其他无监督学习方法，这表明模型在数据稀缺的情况下仍具有出色的泛化能力和适应性。

2.4 已知意图比例对比实验

已知意图比例取值对比实验旨在探究训练意图数量对 AutoIntent 性能的影响，核心目标是验证模型在特定背景下对未知意图的发现能力。实验覆盖 KIR = 0.25、0.5 和 0.75 三种典型设置，分别对应低、中和高已知意图比例，模拟真实场景意图识别的不同难度等级。表 2~表 4 分别对应 KIR 为 0.25、0.5 与 0.75 情况下的数据结果。

已知意图比例对比实验表明，训练意图数量对 AutoIntent 模型的未知意图发现能力具有显著影响。在 CLINC 和 BANKING 数据集上，随着 KIR 从 0.25 逐步提升至 0.75，模型在多数场景下的聚类准确率呈现系统性上升趋势。例如在 CLINC 数据集上，当 KIR = 0.25 时最

表 1 对比实验数据 (KIR = 0. 75)

设置	方法	CLINC			BANKING		
		NMI	ARI	ACC	NMI	ARI	ACC
Unsupervised	KM	70. 89	26. 86	45. 06	54. 57	12. 18	29. 55
	AG	73. 07	27. 7	44. 03	57. 07	13. 31	31. 58
	SAE-KM	73. 13	29. 65	46. 75	63. 79	22. 85	38. 92
	DEC	74. 83	27. 46	46. 89	67. 78	27. 21	41. 29
	DCN	75. 66	31. 15	49. 29	67. 54	26. 81	41. 99
	DAC	78. 40	40. 49	55. 94	47. 35	14. 24	27. 41
	DeepCluster	65. 58	19. 11	35. 70	41. 77	8. 95	20. 69
	IDAS	—	—	—	80. 43	53. 31	63. 77
	AutoIntent-Qwen-turbo-0shot	88. 51	88. 50	77. 56	83. 78	58. 11	60. 23
	AutoIntent-DeepSeek-0shot	88. 50	85. 32	91. 65			
Semi-Supervised	PCK-means	68. 7	35. 4	54. 61	48. 22	16. 24	32. 66
	BERT-KCL	86. 82	58. 79	68. 86	75. 21	46. 72	60. 15
	BERT-MCL	87. 72	59. 92	69. 66	75. 68	47. 43	61. 14
	CDAC +	86. 65	54. 33	69. 89	72. 25	40. 97	53. 83
	BERT-DTC	90. 54	65. 02	74. 15	76. 55	44. 7	56. 51
	DeepAligned	93. 89	79. 75	86. 49	79. 56	53. 64	64. 9
	DSSCC	87. 91	81. 09	87. 91	81. 24	58. 09	69. 82
	SCL	94. 75	81. 64	86. 91	85. 04	65. 43	76. 55
	IDAS	93. 82	79. 02	85. 48	—	—	—
	LatentEM	95. 01	83	88. 99	84. 02	62. 92	74. 03
few-shot ICL	AutoIntent-Qwen-turbo-10shot	91. 96	75. 07	83. 40	86. 54	64. 42	59. 99
	AutoIntent-Qwen-turbo-50shot	92. 18	75. 57	84. 04	87. 09	66. 58	67. 04
	AutoIntent-DeepSeek-10shot	95. 72	85. 63	91. 72	—	—	—
	AutoIntent-DeepSeek-50shot	96. 14	86. 40	92. 16	—	—	—

表 2 KIR = 0. 25 实验数据结果表

KIR	method	shots	CLINC			BANKING		
			ACC	NMI	ARI	ACC	NMI	ARI
0. 25	AutoIntent-Qwen	10	81. 39	92. 04	74. 48	60. 39	85. 78	61. 96
		20	80. 31	91. 95	74. 58	62. 85	86. 76	64. 65
		30	82. 32	92. 12	74. 71	60. 88	86. 65	64. 74
		40	80. 18	92. 07	74. 45	63. 62	85. 31	62. 26
		50	83. 40	91. 93	74. 82	61. 86	86. 41	65. 04

表 3 KIR = 0. 5 实验数据结果表

KIR	method	shots	CLINC			BANKING		
			ACC	NMI	ARI	ACC	NMI	ARI
0. 5	AutoIntent-Qwen	10	78. 76	91. 91	73. 82	58. 59	86. 45	65. 04
		20	80. 71	91. 89	74. 42	64. 56	85. 80	63. 67
		30	80. 82	92. 44	75. 62	66. 06	85. 42	62. 46
		40	81. 63	92. 44	75. 59	65. 06	87. 96	67. 59
		50	80. 92	92. 58	75. 78	61. 31	87. 02	64. 70

表 4 KIR = 0. 75 实验数据结果表

KIR	method	shots	CLINC			BANKING		
			ACC	NMI	ARI	ACC	NMI	ARI
0. 75	AutoIntent-Qwen	10	83. 40	91. 96	75. 06	59. 98	86. 54	64. 41
		20	83. 57	92. 02	75. 10	64. 36	86. 77	64. 85
		30	83. 05	91. 92	75. 09	68. 88	87. 02	66. 40
		40	83. 22	91. 92	74. 52	69. 98	87. 54	67. 62
		50	84. 03	92. 18	75. 57	67. 04	87. 09	66. 58

高 ACC 为 83.40%，而 KIR = 0. 75 时提升至 84.03%；BANKING 数据集表现更为显著，其最优 ACC 从 KIR = 0. 25 时的 63.62% 跃升至 KIR = 0. 75 时的 69.98%。值得注意的是，标准化互信息和调整兰德系数在三个 KIR 层级下均保持 90% 以上的高位波动，说明模型在不同已知意图比例下均能有效捕获语义结构。该趋势验证了已知意图信息对未知意图发现的促进作用，同时揭示了模型在低 KIR 场景下的优化空间，为军事领域复杂意图识别

系统设计提供了关键数据支撑。

2.5 基于大模型在军事背景下的应用

2.5.1 简单军事意图数据集应用

将 KIR 设置为 0.25, few_shot 设置为 10, 以模拟情报匮乏情况下的意图检索功能, 表 5 为生成的 3 条示例。

表 5 普通军事数据集前 5 条生成内容

Utterance	预测语句	生成语句
Boxer 多用途装甲车在城市环境下行驶 2 000 公里燃油需求	fuel_consumption	fuel_consumption
LAV-25 轮式装甲车在山地环境下 12 小时连续作战的燃油消耗评估	fuel_consumption	fuel_consumption
ASCOD 装甲车在城市环境下 1 周连续作战的燃油消耗评估	fuel_consumption	fuel_consumption

方法预测数据集的意图准确率约为 0.860 9, NMI 约为 0.947 1, ARI 约为 0.866 2。整体而言, 本文所构建的军事意图识别数据集具有较高的准确率。

2.5.2 易混淆军事意图数据集应用

为进一步验证 AutoIntent 的能力, 本文构建了一个共有 20 种意图, 每个意图都是容易混淆辨认出错语句的数据集, 来模拟未来军事应用的真实场景, 图 4 为输出结果。

在针对军事数据集的实验验证中, 当已知意图比例设定为 0.25 时, 模型的评估指标呈现出较低的正确率水平, 其中聚类准确率为 0.227 1, 调整兰德指数为 0.256 0, 标准化互信息为 0.448 7。深入剖析这一结果, 主要存在两方面原因。

一方面, 军事数据集的意图识别任务存在较大难度。




图 4 AutoIntent 在易混淆意图数据集下的测试结果

以“单兵电台电池在低温环境下的有效续航时间缩短至标称值的 62%”为例, 从军事领域专业角度来看, 单兵电台作为战场通信的关键装备, 其电池续航时间的大幅缩短, 极有可能导致战斗过程中通信中断, 进而影响作战行动的持续性。为保障战斗准备的完备性, 部队需要评估此情况对作战的影响, 并提前规划应对策略, 如增加备用电池储备、调整通信策略等, 这些行为均属于“combat_readiness”(战斗准备)的范畴。然而, 由于该类语句的意图识别难度较大, 大模型在处理时生成了较为直接的“equipment_performance_degradation”, 未能准确识别出其背后真正的“combat_readiness”意图。

另一方面, 生成的意图在语义上虽与正确意图相近, 但仍存在不完全匹配的情况, 从而导致判断错误。例如“军用卡车空气滤清器在沙尘环境中的堵塞速率达平原地区的 4.8 倍”这一语句, 其真实意图为“equipment_maintenance”, 而模型预测意图为“Truck_maintenance”。尽管二者语义相似, 但从严格的意图识别标准来看, 这属于判断失误。

综上所述, 这些实验结果为 AutoIntent 模型的后续改进指明了方向。同时, 虽然模型在当前阶段存在一定不足, 但在验证军事数据集的过程中, 其展现出了一定的效果, 为进一步优化和完善该方法提供了重要的实践依据。

3 结论

本文针对上下文数据意图识别问题, 系统地开展了大语言模型应用研究。在意图表示层面, 本文提出了一种契合上下文数据特征的意图表征模型。该模型通过充分发挥大语言模型在语义特征提取与理解方面的优势, 显著改进了传统意图识别方法的性能。在少样本及零样本意图识别场景下, 深入剖析大语言模型的泛化与元学习能力, 基于知识驱动的动态适配策略, 有效提升了模型在稀缺数据条件下的意图识别准确率。本文创新性地融合领域知识图谱, 构建了层次化的大语言模型微调框架, 并设计了基于逻辑推理和语义映射的意图解析系统, 实现了多轮对话中意图的精确推断与连贯理解。在模型可解释性方面, 借助注意力可视化与反事实推理等技术, 构建了大语言模型意图识别的可解释性增强方案, 增强了模型决策的透明度与可信度。针对意图识别中的概念漂移与泛化难题, 本文提出了一种将在线学习与主动学习相融合的意图发现机制, 拓展了模型的意图识别范围。本文将上述研究成果应用于军事领域高动态、强约束的对话数据集, 为构建具备实时响应和智能决策能力的军事对话系统提供了重要的理论依据与技术支持, 对推动

自然语言处理技术在复杂应用场景中的发展具有重要意义。

参考文献

- [1] 付煜文, 马志柔, 刘杰, 等. 面向问题意图识别的深度主动学习方法 [J]. 中文信息学报, 2021, 35 (4): 92–99.
- [2] 郑新月, 任俊超. 基于 BERT-FNN 的意图识别分类 [J]. 计算机与现代化, 2021 (7): 71–76, 88.
- [3] ANGELINO E, LARUS-STONE N, ALABI D, et al. Learning certifiably optimal rule lists for categorical data [J]. Journal of Machine Learning Research, 2018, 18 (234): 1–78.
- [4] 陈浩辰. 基于微博的消费意图挖掘 [D]. 哈尔滨: 哈尔滨工业大学, 2014.
- [5] 廖胜兰, 殷实, 陈小平, 等. 面向电力业务对话系统的意图识别数据集 [J]. 计算机应用, 2020, 40 (9): 2549–2554.
- [6] 许坤, 冯岩松, 赵东岩, 等. 面向知识库的中文自然语言问句的语义理解 [J]. 北京大学学报 (自然科学版), 2014, 50 (1): 85–92.
- [7] 李超, 柴玉梅, 南晓斐, 等. 基于深度学习的问题分类方法研究 [J]. 计算机科学, 2016, 43 (12): 115–119.
- [8] HOU Y T, CHE W X, LAI Y K, et al. Few-shot slot tagging with collapsed dependency transfer and label-enhanced task-adaptive projection network [C]//Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics, 2020: 1381–1393.
- [9] DAI Z, YANG Z L, YANG Y M, et al. Transformer-XL: attentive language models beyond a fixed-length context [C]//Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics, 2019: 2978–2988.
- [10] ZHANG J G, HASHIMOTO K, LIU W H, et al. Discriminative nearest neighbor few-shot intent detection by transferring natural language inference [C]//Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP). Stroudsburg, PA: Association for Computational Linguistics, 2020: 5064–5082.
- [11] VERBERNE S. Pretrained transformers for text ranking: BERT and beyond [J]. Computational Linguistics, 2023, 49 (1): 253–255.
- [12] ZHANG H, XU H, LIN T E. Deep open intent classification with adaptive decision boundary [C]//Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35 (16): 14374–14382.
- [13] CASTELLUCCI G, BELLOMARIA V, FAVALLI A. Multi-lingual intent detection and slot filling in a joint bert-based model [J]. arXiv preprint arXiv: 1907.02884, 2019.
- [14] WANG L, CHEN Y, LIU Z. PromptAgent: adaptive prompting for dynamic intent discovery with large language models [J]. IEEE Transactions on Artificial Intelligence, 2025, 6 (2): 145–158.
- [15] CHENG Q, HE B X, ZHUANG Z, et al. Tell me more! Towards implicit user intention understanding of language model driven agents [C]//Proceedings of the 62nd Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers). Bangkok, Thailand: Association for Computational Linguistics, 2024: 1088–1113.
- [16] REIMERS N, GUREVYCH L. Sentence-BERT: sentence embeddings using siamese BERT-networks [J]. arXiv preprint arXiv: 1908.10084, 2019.
- [17] LARSON S, MAHENDRAN A, PEPER J, et al. An evaluation dataset for intent classification and out-of-scope prediction [C]//Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP), 2019: 1311–1316.
- [18] ZHANG H, XU H, LIN T E, et al. Discovering new intents with deep aligned clustering [C]//Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35 (16): 14365–14373.

(收稿日期: 2025-07-23)

作者简介:

孙颢原 (2002–), 男, 硕士研究生, 主要研究方向: 数据驱动智能决策、大语言模型。

刘莹君 (1987–), 女, 助理工程师, 主要研究方向: 大数据分析 & 决策。

吴继冰 (1987–), 通信作者, 男, 博士, 副研究员, 硕士生导师, 主要研究方向: 数据治理、大数据分析与决策。E-mail: wujibing@nudt.edu.cn。

版权声明

凡《网络安全与数据治理》录用的文章，如作者没有关于汇编权、翻译权、印刷权及电子版的复制权、信息网络传播权与发行权等版权的特殊声明，即视作该文章署名作者同意将该文章的汇编权、翻译权、印刷权及电子版的复制权、信息网络传播权与发行权授予本刊，本刊有权授权本刊合作数据库、合作媒体等合作伙伴使用。同时，本刊支付的稿酬已包含上述使用的费用，特此声明。

《网络安全与数据治理》编辑部

www.pcachina.com