第 52 卷 第 7 期：3010-3021 高电压技术 Vol.52, No.7: 3010-3021
2026 年 7 月 31 日 High Voltage Engineering July 31, 2026
DOI: 10.13336/j.1003-6520.hve.20250201

大语言模型辅助的电力系统频率智能调控

李文彪[1,2]，张泽栋[1]，陶文彪[2]，刘　铖[1]，王　亮[2]，李　瑞[2]
（1. 现代电力系统仿真控制与绿色电能新技术教育部重点实验室(东北电力大学)，吉林 132012;
2. 国网山西省电力公司电力科学研究院，太原 030001）

摘　要：为了应对高比例新能源并网导致电力系统受扰后频率响应特性复杂的问题，提出了一种基于大语言模型的智能频率调控方法。首先，通过分析提示词工程、RAG、函数调用和大模型微调等关键技术，并结合自然语言处理技术形成的基于向量数据库的低频减载优化规则，构建了电力系统垂直领域大模型。然后，利用人工智能生成内容(artificial intelligence generated content，AIGC)技术的自适应能力，实现高效的频率优化控制，从而弥补了传统低频减载方法在新能源电力系统中的适配性不足。仿真结果表明，经过该方案优化后的频率调控显著提升了电力系统的稳定性，在多个脱机场景下的调控结果优于传统方法。该文研究为电力系统频率智能调控提供了新的技术路径，具有较高的应用潜力。

关键词：大语言模型；提示词工程；RAG；AIGC；低频减载

Intelligent Frequency Regulation of Power Systems Assisted by Large Language Models

LI Wenbiao[1,2], ZHANG Zedong[1], TAO Wenbiao[2], LIU Cheng[1], WANG Liang[2], LI Rui[2]
(1. Key Laboratory of Modern Power System Simulation Control and Green Energy New Technology of Ministry of Education (Northeast Electric Power University), Jilin 132012, China;
2. Electric Power Research Institute of State Grid Shanxi Electric Power Company, Taiyuan 030001, China)

Abstract: To deal with the problem of complex frequency response characteristics of power system after disturbance caused by high proportion of new energy grid connection, an intelligent frequency regulation method based on large language model is proposed. Firstly, by analyzing the key technologies such as prompt word engineering, RAG, function call and large model fine-tuning, and combining the low-frequency load shedding optimization rules based on vector database formed by natural language processing technology, a large model of vertical field of power system is constructed. Then, the adaptive ability of artificial intelligence generated content (AIGC) technology is used to achieve efficient frequency optimization control, which makes up for the lack of adaptability of traditional under-frequency load shedding methods in new energy power systems. The simulation results show that the frequency regulation optimized by this scheme significantly improves the stability of the power system, and the regulation results in multiple offline scenarios are better than those of the traditional methods. The research of this paper provides a new technical path for the intelligent control of power system frequency and has high application potentials.

Key words: large language model; prompt word project; RAG; AIGC; low frequency load shedding

0　引言

频率是电力系统运行的重要指标，历史上曾多次发生频率失稳引发的大规模停电。快速判断扰动后的稳态频率并实施自动切负荷，对于防止频率崩溃至关重要。电力系统频率控制需要综合分析频率稳定状态、动态特征和各测量点的扰动响应，提取系统安全性、故障类型及位置等信息，以支持频率调度决策和控制策略的选择[1-2]。

低频减载是电力系统安全稳定控制的重要手段，一般可分为 3 类：传统的分阶段方案、半自适应方案和自适应方案，3 种方案的主要区别在于确定切负荷量的方法。现有研究主要集中在对于不同方法的优化过程。基于随机森林的暂态稳定评估方法以及智能算法驱动的两阶段切负荷控制优化了控制决策，有效提升了系统的故障响应能力[3-5]。改进

基金资助项目：国网山西省电力公司科技项目(含高比例分布式风光储的智慧配电网适应能力评估及提升策略研究)(520530230024)。
Project supported by Science and Technology Project of State Grid Shanxi Electric Power Company(Research on Adaptability Evaluation and Promotion Strategy of Smart Distribution Network with High Proportion of Distributed Wind-Solar-Energy Storage) (520530230024).

的频率响应模型，结合旋转备用容量和负荷频率特性，减少了减载量并改善了频率恢复过程[6]。文献[7]通过功率缺额计算，推导了发电机频率偏移与系统惯性中心频率偏移的关系，为低频减载整定提供了理论依据。文献[8]同时优化负荷曲线与减载方法提高了减载执行的稳定性。为适应可再生能源整合后的电网频率控制需求，基于局部测量、同步相量测量装置的快速在线扰动估计方法以及自适应低频减载方案通过对多种不确定性因素的分析，提高了控制方案的有效性，以应对不同环境中的低频减载挑战[9-12]。此外，考虑系统拓扑以及基于频率控制的自适应低频减载方案用来实现自动低频减载[13-14]。虽然已有多项研究提出的优化方案在频率稳定性和系统响应能力方面取得了一定的进展，但在泛化能力和适应性方面仍存在不足，需要进一步改进以应对更复杂的系统环境。

在低频减载决策分析中，传统上依赖人工查找和分析数据。然而，随着电网规模的不断扩展以及负载需求的增加，人工处理的数据量呈指数增长，导致处理难度和决策时间不断加大，进而延长了故障响应时间。因此，借助计算机辅助决策已成为电力系统调度与管理的必然趋势[15]。近年来，人工智能生成内容(artificial intelligence generated content，AIGC)迅速发展，AIGC 涵盖文本、图像、音频、视频、增强训练样本等领域，可低成本、高效生成海量内容，助力元宇宙与数字孪生等新兴应用[16-17]。而大语言模型(large language model，LLM)作为其中的一项颠覆性技术，正在深刻改变人工智能的发展方向与应用模式，其性能不断提升，尤其在处理复杂决策问题中展现出显著优势。关键技术如检索增强生成(retrieval-augmented generation，RAG)、提示词工程(prompt engineering，简称 Prompt)和大语言模型微调，成为推动大模型广泛应用的核心要素。RAG 技术通过在不更新模型参数的情况下，增强信息生成的时效性与专业性，优化了决策效率；提示词工程技术则通过精心设计的短语引导，提升了大模型的推理和生成能力；微调技术则通过在特定领域的数据上进行定制化训练，使得大模型能够满足行业特定的应用需求。这些技术的融合与应用，将进一步释放大语言模型在专业领域的潜力，推动其变革性应用[18-21]。当前，电力系统中已有部分基于大语言模型的应用实例，包括园区综合能源系统集群多目标协同运行、电力系统运行状态的优化调度，以及智能决策执行过程中的辅助决策与操作执行等方面[22-24]。然而，大语言模型在提升效率的同时，也带来了数据安全的隐患，尤其是在电力系统等敏感领域的应用中，需要特别关注其安全性问题[25]。

综上所述，本文通过分析大语言模型的微调训练、提示词工程与 RAG 等技术在低频减载决策中的应用效果与发展前景，提出了一种基于大语言模型辅助的频率智能调控策略。随着未来电力系统中新能源占比的增加及可能带来的更大扰动，传统的调度与控制方法以及发电厂站的固定减载策略可能不再适用，本文通过仿真技术获得系统运行数据，结合自然语言处理技术提取“规则”，并利用大模型相关技术构建垂直领域大模型，使其能够基于模拟结果对该系统给出优化决策建议。该方法能够实现对电力系统的预先评估，为电力系统在面对更复杂的运行环境时提供更智能的决策支持。初步仿真结果表明，所提策略具有良好的应用前景，能够有效提升低频减载的智能化调控能力，为电力系统的高效稳定运行提供有力支持。

1 新能源电力系统低频减载策略制定

低频减载策略作为一种有效应对电网受扰动后频率跌落的手段，在增强系统频率稳定性方面发挥着关键作用。随着电网可再生能源的日益发展，针对可再生能源高占比条件下的低频减载方案的优化研究对电网的频率稳定具有重要意义。低频减载方案设计的目的是通过合理安排低频减载各级在各地区的频率定值、时间定值及负荷切除量，从而尽可能提高低频减载方案对系统不同运行方式、不同干扰地点及不同功率缺额的适应能力。

国标GB/T 200要求风机能在48.0~49.5 Hz频率范围内至少并网运行 30 min[26]，而当频率低于 48.0 Hz 时则根据风机允许运行的最低频率而定。此外，依据《电力系统自动低频减负荷技术规定》[27]，为有效延缓频率下降，减载首轮的动作阈值宜取高值。同时，还要考虑到旋转备用的启动时延和避免因临时性频率降低所导致的不必要动作。参考实际电网减载方式，采用中国电科院算例 CSEE-FS 进行仿真。初步方案设置 4 级基本轮，其动作的频率阈值分别为 49.2、48.8、48.4 和 48.0 Hz；每轮次的减载量 P_z 依次设为固定减载功率的 27%、27%、23%和23%。并设置一级特殊轮，由智能调控模型决定其是否动作，其减载量 P_t 的计算如式(1)所示。

$$P_t = P_s \pm P_b \tag{1}$$

式中：P_s为固定减载量；P_b为大模型输出的调整减载负荷量，默认为 0。通过设置特殊轮，能够保证系统频率在紧急控制期间有效恢复至 49.6 Hz 及以上的安全稳定水平。通过设置特殊轮和多级基本轮，可以最大程度地利用机组调频特性来补偿系统中的功率缺额，从而尽可能地减少减载总量，在保证减载措施可靠性的同时使其经济性最优。

总减载量应分配到已安装在变电站出线配电馈线上的低频减载继电器中[28]。因此原则上在确定了各轮次减载所需切除的负荷量之后，需要提出合理的选址与定容方法，以确定减载地点以及各母线所需承担的具体减载量。但智能调控模型能够通过分析不同减载地点(即切除不同负荷)的频率响应差异，优化决策过程。值得提出的是，本研究仅针对上文的减载策略进行深入分析。在实际工程应用中，减载方案通常由理论经验初步确定，然后通过智能调控模型进行调整和优化。

综上，针对低频减载的控制需求，提出了 4 项频率调控关键规则，这些规则既保障了电力系统在遭遇频率波动时的稳定性，又考虑了新能源接入后系统的特殊需求。规则如表 1 所示。

表 1 低频减载调控规则

Table 1 Low frequency load shedding control rules

规则编号	规则内容
规则 1	自动低频减负荷装置动作后，系统稳态频率应恢复到不低于 49.5 Hz
规则 2	考虑到特殊情况，增设长延时特殊动作轮，防止系统频率长期低于 49.0 Hz
规则 3	限制系统频率低于 47.0 Hz 的时间不超过 0.5 s
规则 4	负荷过切引起的频率过调，最大频率不得超过 51.0 Hz

2 大语言模型

2.1 LLM 的原理与结构

LLM的核心原理是通过神经网络进行序列建模，利用 Transformer 架构将输入文本序列映射到输出序列。Transformer 的基本原理是基于自注意力机制和位置编码，这种结构能够有效捕捉长距离的依赖关系并处理复杂的上下文信息。其内部逻辑如图 1 所示。

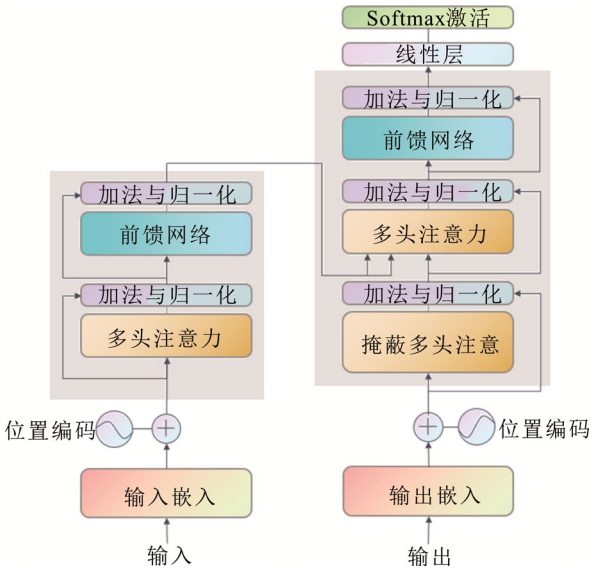


图 1 Transformer 内部结构原理图

Fig.1 Schematic of Transformer internal structure

Transformer 的结构主要由编码器和解码器组成，其中编码器将输入序列转换为高维表示，并由多层堆叠的子层(包括多头注意力和前馈神经网络)构成。多头注意力通过并行计算不同的注意力头，捕捉文本中的全局上下文信息，而前馈神经网络则进一步加强语义表达。这些层通过残差连接和标准化来优化训练过程，从而提高模型的学习效率。解码器在编码器的基础上增加了遮蔽多头注意力机制，用于在生成输出序列时结合输入序列和当前生成的输出，确保模型在生成每个词时能够合理考虑上下文。这一结构使得 Transformer 能够在处理序列时，并不依赖于顺序的输入特性，从而高效地处理长序列数据。

相较于传统的循环神经网络(recurrent neural network，RNN)和长短期记忆网络(long short-term memory，LSTM)，Transformer 的自注意力机制突破了 RNN 和 LSTM 的局限，避免了梯度消失和梯度爆炸问题，能够实现全局信息的建模，极大地提高了训练效率和精度。同时，Transformer 支持模型参数的扩展，可以在训练过程中处理千亿级别的参数，大大提升了大语言模型的表现能力。通过大规模的文本数据训练，Transformer 模型能够学习语言的深层次规律，捕捉语法、语义以及词汇间的复杂关系，使得大语言模型在自然语言生成、翻译和问答等任务中表现出色。

当前，大型语言模型(如 GPT 系列、千问、Deepseek 等)在多个领域得到广泛应用，在众多大模型中，不同产品在性能、适应性和特定任务的优化上表现各异，表 2 为常见大模型的参数性能对比。

为深入研究不同模型在特定任务中的表现并结合实际设备情况，本研究主要选取了参数量中等

表 2 大模型参数性能对比

Table 2 Performance comparison of model parameters

模型	参数量	评分/能力	响应速度/s	费用 (按千 tokens)
GPT-3.5 Trudo	200 B	强	3~5	约 0.03 美元
GPT-4	1.8 T	顶级	3~6	约 0.12 美元
千问系列	72 B	强	4~9	免费/低成本
InterLM 系列	72 B	强	4~6	约 0.02 美元
Deepseek 系列	671 B	顶级	4~6	约 0.01 美元
星火大模型	72 B	强	4~7	免费/低成本

的 GPT-3.5 Trudo 和 Deepseek-R1、参数量较高的 GPT-4 和 Deepseek-V2.5 以及参数量较低的千问 7B 系列产品为例进行对比分析和验证。

2.2 LLM 关键技术

2.2.1 提示词工程

人工智能生成模型的有效运用离不开 Prompt 的设计。Prompt 通过逐步引导大语言模型沿着一定的推理路径进行思考，有助于弥补大语言模型在某些复杂推理任务中可能存在的推理能力缺陷，从而提高其处理复杂问题的准确性和连贯性。

Prompt 的优化依赖于多项参数设置，以提升自洽性和解决复杂问题的能力。首先，合理的例子和应对规范设计能够增强模型理解和响应能力；多轮对话提供了上下文捕捉的机会，促使输出更加连贯和逻辑严谨。在模型参数设置中，temperature 参数影响生成结果的多样性：较高值(如 2)促使结果多样化，较低值(如 0)则使其更具一致性。top 参数限制生成过程中的采样范围，控制输出的广度与精准度。此外，presence 和 frequency 参数调节 token 的多样性和频率，从而优化内容的合理性与新颖性。

通过优化 Prompt 设计及参数配置，可以显著提升大语言模型在特定任务中的表现，推动从大模型到高效智能系统的转变。

2.2.2 检索增强技术

检索增强技术(RAG)通过接入外部信息，无需更新大语言模型参数，即可提高模型生成信息的时效性和专业性。该方法通过文本预处理和高效检索机制，使生成模型能够精确利用大规模文档语料，从而提升特定任务的表现。RAG 系统的实现流程如图 2 所示。

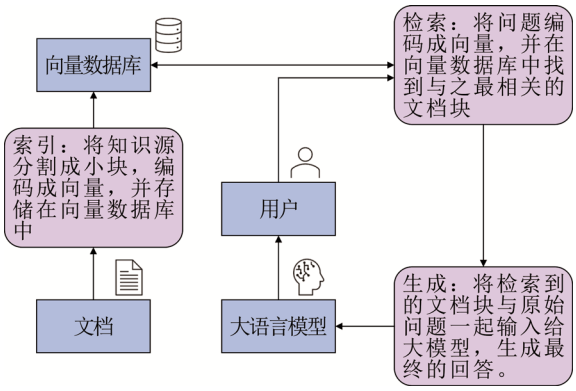


图 2 RAG 系统实现流程

Fig.2 RAG system implementation process

文档加载与处理是系统构建的基础。首先，文档根据一定规则切割成片段，以便进行后续检索。切割时需要考虑文本的上下文关系，确保信息的完整性。预处理后的文本片段通过检索引擎进行检索。传统的关键字检索效率较高，但可能无法捕捉到语义相同但用词不同的情况。为解决此问题，向量检索逐渐成为主流。向量数据库支持高效检索，且向量由嵌入(Embedding)模型生成，与传统关系型数据库形成互补，通常需要综合应用。

在 RAG 系统中，文本分割的颗粒度至关重要。颗粒度过大可能导致检索结果不精准，过小则可能使信息割裂。为此，可采用部分重叠切割策略，以保证上下文连贯性。同时，检索结果的排序也需优化。初步检索结果可能并非最优，通过排序模型对查询和文档进行打分，可以提高结果的相关性与准确性。最后，混合检索策略结合稀疏表示的关键字检索与稠密表示的向量检索，充分发挥了两者优势：关键字检索在处理长专有名词时更精准，而向量检索则有助于提供广泛的语义理解。

2.2.3 模型微调

为满足垂直领域应用需求，大型语言模型需在特定领域数据上进一步训练，将该领域知识融合至模型参数中。目前，微调方法主要分为全量微调(full fine-tuning, FFT)和参数高效微调技术(parameter-efficient fine-tuning, PEFT)。

FFT 更新预训练模型的所有参数，计算成本较高，并可能导致模型在微调过程中过度适应特定领域，进而引发灾难性遗忘问题，影响模型对先前知识的保持。与之相比，PEFT 能够有效降低微调所需的参数量和计算复杂度，同时提升模型在特定领域的性能并缩短训练时间，其中低秩适配(low-rank adaptation, LoRA)是 PEFT 中的一种重要方法。LoRA 冻结大部分参数，仅更新 Transformer 网络的偏置参数或分类层参数[29]。常见微调方案的特性和使用场景对比如表 3 所示。

模型微调、RAG 和提示词工程技术在数据透明度、实时更新、数据需求、可定制性和性能优化等方面各具优势，3 种技术的多维度对比如表 4 所示。

模型微调适用于需要大量标注数据和高训练复杂度的定制任务，但更新困难；RAG 依赖外部数据源，具有较高透明度和实时更新能力，但性能受限于检索机制，适应性较强；提示词工程数据需求低、训练复杂度极低，能灵活调整语气和话术，快速适应新任务，但缺乏长期优化能力，3 种技术可以相互结合使用。

2.2.4 函数调用

函数调用(function calling)是一个可以与大语言模型结合使用的技术，旨在增强模型的能力，尤其是在需要与外部资源或系统交互时。它允许大语言模型在特定任务中自动调用和执行函数，以获取所需的结果或进行某些操作。函数调用不仅能调用内置的函数，还能调用自定义函数或访问数据库。

函数调用为大模型提供了灵活性和实时性，能根据任务需求自动调用相关函数并获取结果，从而扩展模型的应用场景。与上文提及的微调、RAG 和提示词工程不同，函数调用更像是对大模型能力的补充和增强，而不是核心决策机制。它能在需要时有效地补充大模型的不足，使其在更复杂的任务中具备更强的适应性和功能。

3 大语言模型辅助频率智能调控研究

3.1 频率智能调控方案的设计与实现

利用现有工具并采用 Python 编程，制定一种基于大语言模型辅助的低频减载调控策略，旨在通过结合仿真数据和大模型对频率波动的实时分析，动态制定出最优的低频减载方案。在这一过程中，首先通过仿真找出低频减载方案的各参数适用的临界范围，然后分析大模型微调、Prompt 和 RAG 技术的表现，最终制定了在提示词工程基础上结合 RAG 与函数调用的优化减载策略。这一方案不仅能够满足传统的频率恢复规则，还能够应对新能源波动性带来的复杂情形，进一步提高电力系统的鲁棒性和适应性。最终方案的逻辑架构图如图 3 所示。

如图 3 所示，本策略通过自然语言处理技术提取电力系统中的低频减载信息，并将其存入知识库。随后，利用 Embedding 技术将该信息转换为向量形式并存入向量数据库中待后续检索。在此基础上，利用大模型结合提示词、RAG 与函数调用等技术，动态获取并更新电力系统的低频减载执行方案。值得提出的是，整个过程的初期阶段仍需要人工干预，

表 3 常见微调方案对比

Table 3 Comparison of common fine-tuning schemes

类别	定义	特点	适用场景
FFT	更新预训练模型所有参数，完全适配目标任务	精确性高；计算资源需求大；容易过拟合	数据量充足、资源丰富；需完全适配任务的场景
PEFT	添加少量可训练参数或高效参数策略，不改动大部分模型参数	参数量小；训练快；资源需求低；模型大小不变	资源有限、需快速适配任务，如移动端或多任务场景
LoRA	将权重分解为低秩矩阵，仅优化低秩部分参数	参数量极少；模型大小不变；计算开销低	大型模型高效适配场景；工业级模型快速部署

表 4 大模型关键技术对比

Table 4 Comparison of key technologies of big model

维度	模型微调	RAG	Prompt
数据透明度	较低，内部变更难追踪	高，基于外部数据源可视化	低，仅依赖输入文本
数据更新	更新困难，需重新训练	实时更新，动态检索新信息	实时更新，基于 Prompt 生成
数据需求	大量高质量标注数据	数据量小，依赖外部文档	数据需求低
可定制性	高，输出可定制	中等，通过检索机制优化	高，通过设计不同 Prompt 控制内容
性能优化	适用于特定任务，定制化性能好	依赖检索模块，灵活性高	快速，但无长期优化能力
更新频率	难以更新，需重新训练	高，外部数据源可随时更新	高，随时调整 Prompt
训练复杂度	高，计算资源需求大	低，依赖外部检索，负担小	极低，仅需优化 Prompt 设计
可扩展性	差，依赖大规模数据和计算资源	良好，通过增加数据源增强扩展性	极好，新 Prompt 可直接接入扩展功能

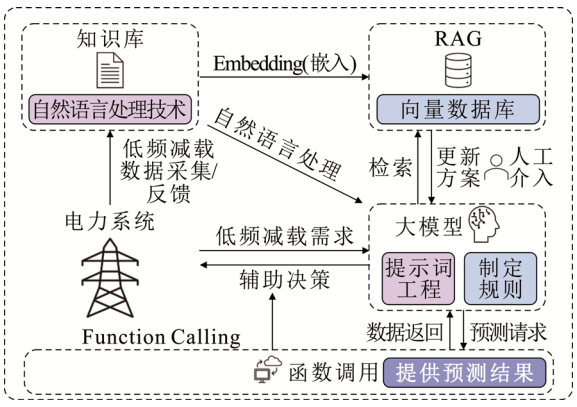


图 3 基于大模型的频率调控系统架构图

Fig.3 Architecture diagram of frequency control system based on large model

以确保规则的准确性与完整性。

检索的过程中，常用方案有向量检索、关键字检索和混合检索。关键字检索只能基于词面进行匹配，对于同义词或变体的表达能力较差，而向量检索能理解词语的相似性和语义关系。在电力领域中，一些术语可能有不同的表述方式，例如“变电站”和“电站变压器”可能指代类似的含义。通过向量检索，可以捕捉这些术语的语义相似性，得到准确结果。但对于如“故障负荷”和“非故障负荷”这类专有名词，关键字检索的准确性往往高于向量检索，而混合检索可以综合这种方法的优势给出得分，鉴于混合检索消耗资源较大，本研究采用向量检索依旧可以得到很好的效果。

此外，由于电网数据的保密性，在实际工程应用中联网调用大模型接口的方法可能存在电网数据泄露的风险，因此在电网实际应用时，该方案所使用的预测模型、向量化模型以及大语言模型均需内网通讯或本地部署。

3.2 大语言模型辅助频率智能调控的离线研究

高新能源占比下频率响应的动态过程主要受 4 个因素影响：首先，功率缺额会导致电磁转矩与机械转矩的失衡，进而引发转速变化，显著影响最低频率点的确定。其次，新能源对系统惯量的影响决定了系统对扰动的响应能力。然后，发电机组和负荷的容量反映了系统的一次调频能力，对最低频率点起到关键作用。最后，调频机制(如调速器)在惯性响应结束后发挥调节作用，进一步稳定系统频率。综上，功率缺额、新能源占比、发电机组和负荷的容量以及系统惯量是影响低频减载启动后频率响应的主要因素，考虑它们作为关键参数维度，如表 5 所示。

鉴于电力系统数据的敏感性与安全性，本研究通过仿真数据挖掘低频减载与系统参数的内在规律。根据表 5 中的参数维度，离线仿真测试利用自然语言处理技术提取并分析不符合规则的样本，揭示参数内在联系。在发动机惯性常数波动范围为 2~4，发电机及负载波动范围为 200~300 W 的条件下，当功率缺额占总功率的 7%时，除小比例样本外，仿真结果符合低频减载规则，无需启动特殊轮；当功率缺额占比增至 10%时，中比例数据无法满足规则 1，需启动特殊轮；当功率缺额占比达到 12%时，高比例数据样本无法满足规则 1，需启动特殊轮，具体仿真结果汇总如表 6 所示。

具体而言，在新能源占比为 18%~24%时，需要执行 2 轮减载；当新能源占比超过 30%时，在执行 2 轮减载后，仍需启动特殊轮。然而，这可能导致频率回升超过 51.0 Hz，违反规则 2，因此需降低特殊轮的减载量，以控制频率回升幅度。

由于惯性常数与功率缺额影响具有一致性，以功率缺额占比达到 12%时，发电机水平、负荷水平与新能源占比的三维热力散点图绘制为例，通过控制变量法定性直观分析各参数影响，见图 4。

图 4 中，横坐标为发电机水平，纵坐标为负荷水平，热力值表示新能源占比水平。根据图 4 可得，

表 5 关键参数维度

Table 5 Key parameter dimensions

参数	物理含义
维度 1	新能源占比
维度 2	功率缺额
维度 3	系统惯量
维度 4	发电机及负荷容量

表 6 仿真结果及参数范围

Table 6 Simulation results and parameter range

功率缺额占比	惯性常数及容量波动	规则满足情况	新能源占比 18%~24%	新能源占比 30%以上
7%	2~4，200~300 W	约 98%的样本满足规则	执行 1 轮减载	执行 2 轮减载
10%	2~4，200~300 W	约 45%的样本满足规则	执行 1~2 轮减载	执行 1~2 轮减载后部分样本启动特殊轮
12%	2~4，200~300 W	约 25%的样本满足规则	执行 2 轮减载	执行 2 轮减载后启动特殊轮

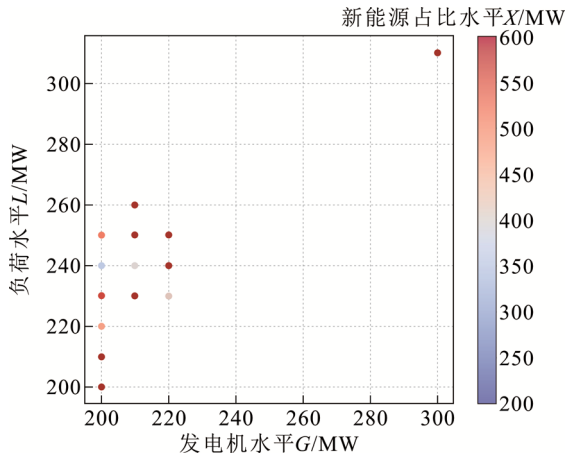


图 4 不满足规则的参数三维热力散点图

Fig.4 Three-dimensional thermal scatter diagram of parameters that do not meet the rules

在该功率缺额水平下，哪些运行参数需启动特殊轮。例如，图中最左下角的点表示在功率缺额占比 12%、发电机和负荷水平均为 200 W、且新能源占比约 30%(600 W)时，样本不满足规则 1，无法满足低频减载要求。

3.3 大语言模型辅助频率智能调控的决策实施

基于离线仿真测试形成系统运行特性的多维数据库，通过检索不满足低频减载规则的工况，将结论输入大模型进行学习，采用 RAG 结合 Prompt 技术构建频率智能调控系统，执行流程如图 5 所示。

在当前系统架构下，低频减载方案的优化与应用依赖于大量的仿真分析与数据驱动方法。首先，通过对仿真数据的深入分析，利用数据检索技术识别并定义现系统低频减载方案适用的“边界条件”，即在特定操作条件下方案的有效范围。接着，结合检索增强生成、函数调用等技术构建基于大语言模型的频率调控系统，使其能够自动学习与这些边界条件相关的规则，并对超出规则的工况采用频率预测功能(函数调用)，给出调控建议并更新数据库。

在实际应用中，当电力系统遭遇扰动时，首先会实时收集运行参数，并根据现有规则进行初步判断，若未能提供明确结论，接下来会利用预测的频率响应数据，进行进一步判断。此方案提高了低频减载的适应性和灵活性，同时增强了系统的实时决策能力，使得系统能够在复杂扰动环境中动态调整响应。值得提出的是，在仿真设置过程中特殊轮未被启动，因此频率预测模型训练数据集不包括特殊轮启动后的频率数据。但理论上当系统频率的稳态值低于 49.5 Hz 时，需启动特殊机组以维持系统稳定，而该数据集下特殊机组启动后，频率跃升未超过 51 Hz。因此，若大模型经过预测模型的输出判断需要启动特殊机组，应进一步通过大范围的验证，确保特殊机组启动后不会导致频率超出设定范围，并且最终使系统频率趋于稳定。

4 算例分析

模型在 Windows 11 系统环境下使用 Python 编程语言编写的算法运行。PC 配置为：AMD Ryzen 9 7940H w/Radeon 780M Graphics/16.00GB RAM/无 GPU。仿真数据由基于中国电科院算例 CSEE-FS 生成，装机占比方面，新能源(2 400 MW)与常规(5 400 MW)之比为 1:2.25。新能源出力 900 MW，常规机组出力 4 100 MW。

4.1 微调技术可行性探究

本节研究旨在探索微调后的大语言模型在该任务中的表现与潜力。基于千问与 InternLM 两个大模型采用 LoRA 形式的轻量化微调，以适应任务中复杂规则的需求。首先构建了包含多种功率缺额状态及其对应标注的高质量数据集。输入数据以统一格式拼接，包括参数描述与输出标签，数据经过预处理后，转换为模型可识别的 Token ID 格式，并通过标签部分标识出输出内容，保证模型训练时仅对生成部分进行损失计算。本研究根据离线参数提取后的规则生成如图 6 所示 JSON 格式数据集共 2 000 条。

在模型加载阶段，引入了千问和 InternLM 的 7B 模型，通过 LoRA 技术在注意力层中加入额外参数，调整低秩矩阵维度与缩放因子，从而在显存占用较低的情况下实现轻量化微调。

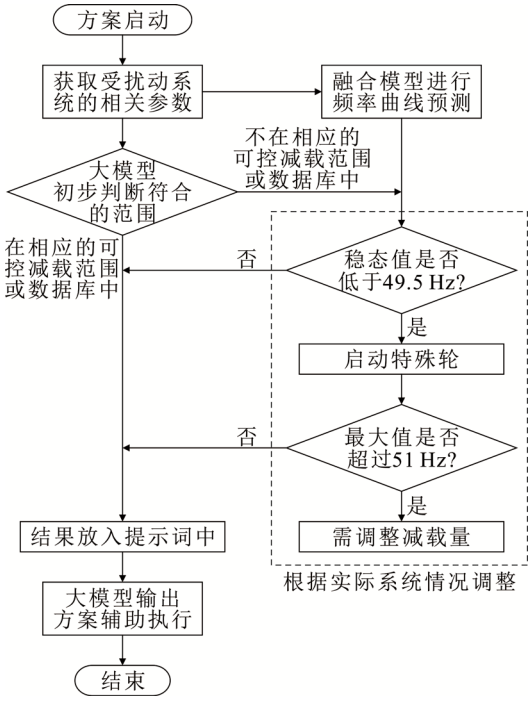
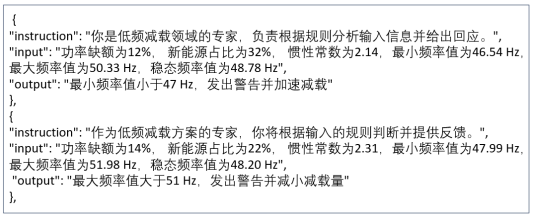


图 5 频率智能调控系统执行流程图

Fig.5 Flowchart of frequency intelligent control system execution



```
{
"instruction": "你是低频减载领域的专家，负责根据规则分析输入信息并给出回应。",
"input": "功率缺额为12%，新能源占比为32%，惯性常数为2.14，最小频率值为46.54 Hz，
最大频率值为50.33 Hz，稳态频率值为48.78 Hz",
"output": "最小频率值小于47 Hz，发出警告并加速减载"
},
{
"instruction": "作为低频减载方案的专家，你将根据输入的规则判断并提供反馈。",
"input": "功率缺额为14%，新能源占比为22%，惯性常数为2.31，最小频率值为47.99 Hz，
最大频率值为51.98 Hz，稳态频率值为48.20 Hz",
 "output": "最大频率值大于51 Hz，发出警告并减小减载量"
},
```

图 6 微调数据集样例

Fig.6 Fine-tuning the dataset sample

微调完成后，将 LoRA 生成的轻量化参数与基础模型权重合并，并进行了系统测试与验证。尽管该方法初步实现了对电力系统复杂规则的适配，但由于数据量小且模型参数庞大，再加上数据之间的关联性容易过拟合，效果并不理想。

综上所述，该方法展示了预训练模型轻量化微调在垂直领域中的潜力，但受数据和资源限制，效果仍需优化。图 7 和图 8 展示了千问 7B 模型训练 10 轮内的损失和大模型回复效果，InternLM 模型的结果和其具有一致性。

从微调后和大模型对话的结果看，由于数据丰富度的不足以及数据格式的相对单一，大模型不能很好地学习到规律，在回复过程中容易陷入过拟合且有时候会回答错误，并不能有良好的表现，因此后续仍需要结合 Prompt 使用，此处微调的意义仅是减少大模型产生“幻觉”的概率，微调方案更新难度大成本高，较为浪费资源，因此本文认为微调不适用于该频率智能调控方案。

4.2 提示词工程技术可行性探究

本节旨在研究仅通过提示词工程的方式，探索大语言模型在该任务中的表现与潜力。具体提示词设计方案如下：

第 1 步，角色定义。为确保模型准确理解任务需求，为其定义了“低频减载专家”角色。使大模型认识到该角色需要熟悉低频减载方案及其执行规则，能够分析电力系统稳态频率变化，并判断是否启动特殊轮。模型的判断需基于规则和输入数据，确保科学性和专业性。

第 2 步，规则理解与任务分解。模型任务被分解为几个步骤，以确保其高效执行。关键规则包括：稳态频率恢复需≥49.5 Hz；特定条件下，需要增设长延时特殊动作轮，确保频率≥49.0 Hz；限制频率低于 47.0 Hz 时间不超过 0.5 s；避免频率波动超过 51.0 Hz。任务分解包括检查输入数据完整性，判断是否调用预测模型，验证方案是否符合稳定运行要求，并输出是否调整方案或启动特殊轮。

第 3 步，输入与输出的设计。输入参数包括系统惯性常数、功率缺额比例和新能源占比。若数据不完整，需调用预测模型补充稳态值。输出结果简洁明确，指出是否需要调整方案或启动特殊轮，并列出原因或违反的规则。

第 4 步，推理与反思机制。为提高分析严谨性，加入反思机制。推理过程包括逐步检查规则，综合分析并输出结论；反思机制则确保输入数据和规则覆盖全面，若不足，重新评估判断。

通过 Python 编写底层代码采用 GPT-3.5 Turbo 进行 Prompt 下的多轮问答模拟(Deepseek-R1 与之效果一致)。为保证大模型严格按照低频减载规则方案给出意见，避免自行发挥，代码中 temperature 参数设为 0，效果如图 9 所示。

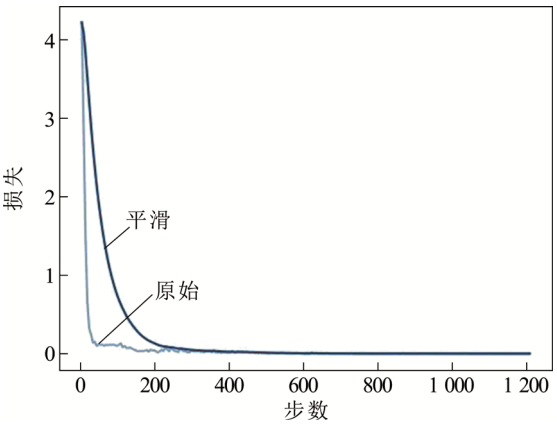


图 7 大模型微调训练损失图

Fig.7 Large model fine-tuning training loss map

GPT-3.5 Turbo :您好，我是您的低频减载专家。根据您提供的系统参数，我将进行判断。请告诉我功率缺额、新能源占比和惯性常数的数值。

User:功率缺额为8%，新能源占比为15%，惯性常数为2.5。

GPT-3.5 Turbo :根据您提供的参数，功率缺额在规定范围内，新能源占比也符合要求，惯性常数也符合要求。结合您手动输入的预测值进行频率判断。请告诉我最小频率值、最大频率值和稳态频率值。

User:最小频率值为47.5 Hz，最大频率值为50.5 Hz，稳态频率值为49 Hz。

GPT-3.5 Turbo :根据您提供的频率值，最小频率值和稳态须率值都处于合规范围内。但最大频率值超过了51Hz的上限，因此我建议减小减载量以避免频率过高。请问您同意这个操作建议吗?

User:同意。

GPT-3.5 Turbo :好的，我将向系统发送减小减载量的指令。减载操作执行中，请稍等片刻。

图 8 大模型微调技术初步效果图

Fig.8 Preliminary effect diagram of large model fine-tuning technology

User:功率缺额为10%， 新能源占比为16%， 惯性常数为3.55，最小频率值为47.38 Hz，最大频率值为51.23 Hz，稳态频率值为48.14 Hz。

Qwen:最大频率值大于51 Hz，发出警告并减小减载量。

User:功率缺额为9%， 新能源占比为2%， 惯性常数为2.69，最小频率值为46.31 Hz，最大频率值为51.24Hz，稳态频率值为48.38 Hz。

Qwen :最小频率值小于47 Hz，发出警告并加速减载。

User:功率缺额为15%， 新能源占比为16%， 惯性常数为3.12，最小频率值为47.20 Hz，最大频率值为50.08 Hz，稳态频率值为48. 99 Hz。

Qwen :最大频率值小于51 Hz，发出警告并加速减载。

图 9 采用 GPT-3.5 多轮对话

Fig.9 Dialogue by using multiple rounds of GPT-3.5

该过程模拟了用户在电力系统扰动发生后与大模型对话的全过程，大模型首先分析参数范围是否符合当前低频减载的标准，如果不符合会继续接收频率预测模型的数值进行进一步判断。值得提出的是，大模型本身并不具备真正理解低频减载背后数学原理和规则的能力，它只是通过从文本中学习到的模式规则进行概率推断。

实验中记录了 3 次大语言模型的回复时间分别为：4.63 s、4.82 s 和 6.11 s，因此基于该设备配置的回复时间在 5 s 左右。接着，采用 GPT-4o 网站图形界面中进行 Prompt 多轮问答(Deepseek-V2.5 与之效果一致)，效果图如图 10 所示。

如图 10 所示，大模型能够根据提示词以及输入的电力系统扰动信息做出判断，如果符合会输出“符合要求”,如果不符合会获取频率预测值并执行下一步操作。

如图 11 所示,在输入预测模型传递的频率数据后，大模型根据相应的规则会告知用户需要进行的措施。尽管提示词工程表现符合预期，但后期参数规则更新需要重复修改提示词，会造成提示词过于冗长。因此接下来考虑通过 RAG 与函数调用技术并结合提示词工程，来实现频率智能调控方案。

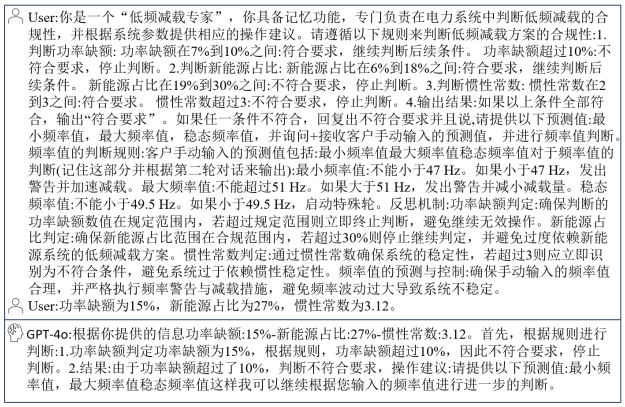


图 10 采用 GPT-4o 第 1 轮对话

Fig.10 Dialogue by using the first round of GPT-4o

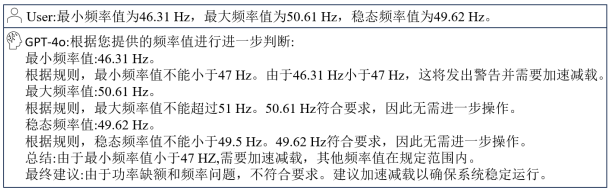


图 11 采用 GPT-4o 第 2 轮对话

Fig.11 Dialogue by using the second round of GPT-4o

4.3 频率智能调控方案验证

首先，RAG 检索文档的设计需包括以下核心内容：第一，需系统性描述低频减载规则的定义，包括低频减载规则的具体内容、违反规则的判定标准以及可能导致的后果等。第二，基于历史数据样本的处理结果，识别可能触发规则不满足的参数组合范围，包括系统惯性常数、发电机和负荷水平、功率缺额比例、新能源渗透率等关键输入参数的定义及取值范围，同时包含特殊轮启动的要求。第三，文档需补充预测模型即函数调用的辅助说明，明确模型的输出内容、调用条件以及返回数据示例，以支持低频减载规则的评估与优化。

其次，函数调用功能的启动需要在底层代码中定义相应的工具模块，并明确告知大模型可以调用该函数。由于受到预测模型应用的限制并为了确保功能演示的完整性，本研究中的函数调用功能由用户输入来代替实现。

RAG 的实现主要有底层逻辑实现和基于 LlamaIndex 框架两种实现方式。本研究中采用 GPT-3.5 Turbo 模型和 Python 代码编程，通过底层逻辑实现 RAG 与函数调用，并结合提示词工程，构建频率智能调控系统。第 1 步，读取相关知识库。系统通过递归方式读取指定目录及其子目录下的所有 Markdown 格式的文档，内容包括电力系统低频减载的规则以及函数调用启动标准等。第 2 步，文本分割与处理。在读取到的文档内容中，系统会根据预设的文本块大小和重叠部分进行文本切割，每个文本块会尽量保持一定的上下文信息，以便后续进行高效的相似度检索。第 3 步，量化处理与存储。系统使用 OpenAI 提供的嵌入模型将每个文本块转换为向量表示并存储在 FAISS 向量数据库中。FAISS 用于高效地存储和检索大规模的向量，支持通过欧氏距离或内积来计算文本之间的相似度。第 4 步，用户查询与生成回答。当收到相关信息时，系统通过向量检索找到最相关的文档片段并嵌入到预先设定的 Prompt 中，随后大语言模型做出回复。

检索过程中，若发现数据不符合现有规则，大模型会自动启动函数调用机制获取预测值，使用 GPT-3.5 Turbo 模型生成回答(Deepseek-R1 与之效果一致)，效果图如图 12 所示。

如图 12 所示，为抑制大模型产生“幻觉”，本研究设计了 1 套机制来确保大模型输出的准确性。系统首先从知识库中检索相关规则，并将这些规则

User:你是一个问答机器人。你的任务是根据下述给定的已知信息回答用户问题。已知信息:{context}。用户问:{query}。 Query=功率缺额为10%， 新能源占比为16%，惯性常数为3.55，最小频率值为48.38 Hz，最大频率值为51.23 Hz，稳态频率值为49.64 Hz。

GPT-3.5 Turbo :根据用户输入的条件进行逐条规则检查:
1.功率缺额为10% - 符合要求。
2.新能源占比为16% - 符合要求。
3.惯性常数为3.55 - 不符合要求。
结果:不符合要求。
接收用户输入频率值:
"请输入最小频率值:48.38 "
"请输入最大频率值:51.23 "
"请输入稳态频率值:49.64 "
频率值判断:
1.最小频率值为48.38 Hz - 符合要求。
2.最大频率值为51.23 Hz - 超过阀值，结果为:发出警告并减小减载量。
3.稳态频率值为49.64 Hz - 符合要求。

图 12 RAG 结合函数调用方案效果图

Fig.12 RAG combined with function call scheme effect diagram

嵌入到提示词中，输入给大模型进行判断。如果大模型判断输入的参数不符合实际要求，它将启动函数调用机制，从预测模型中获取关键的频率响应值，并进行进一步的调整。这一过程中，系统规则与频率预测模型共同作用，通过多层次的验证与校正，有效避免了大模型产生偏离实际规则的错误推测。对比未经调整的通用大模型的回答，此机制下的大模型通过规则的约束和实时反馈，显著降低了“幻觉”产生的风险。

实验中，记录了 2 次实验的大模型各部分工作时间如表 7 所示，其中 embedding 模型采用了 text-embedding-ada-002。此外，该次实验中未触发函数调用机制，因此单独进行了预测模型的时间评估综合约为 1 s。

该实验设计不仅测试了大模型的响应速度，也验证了在没有数学模型的严格推理情况下，如何通过外部函数调用和规则检索来确保输出的有效性和准确性。图 13 展示了 RAG 结合函数调用方案下大模型参与前后在某工况下的频率仿真结果。

由图 13 可知，通过大模型的输出结果辅助调控，离线更新后的策略启动特殊轮使频率曲线避免了悬停现象。综上，本文基于大模型技术构建了电力垂直领域大模型，成功实现了通用大模型无法完成的任务，并证实了其在频率调控领域的应用前景。值得提出的是，本文旨在探讨大语言模型在电力系统低频减载方案制定与频率调控中的应用，因此，未来的研究工作可以进一步深入探索如何优化减载

表 7 各部分时间指标

Table 7 Time indicators of each part

实验编号	向量化时间/s	检索时间/s	大模型回复时间/s
1	1.73	0.77	2.28
2	1.53	0.72	2.15

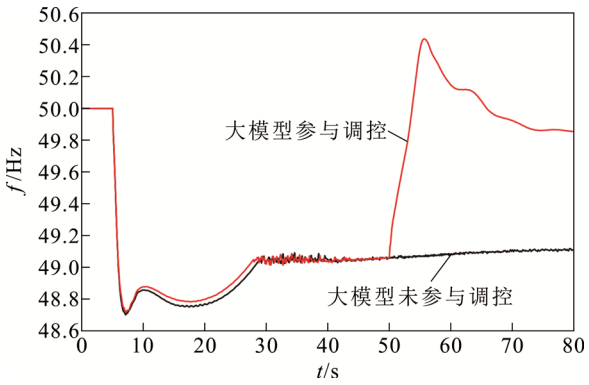


图 13 大模型参与调控前后频率曲线对比

Fig.13 Comparison of frequency curves before and after large model participation in regulation

策略，并提升大模型在实际电力系统中的适应性与准确性。

4.4 大语言模型在电力系统稳定领域的应用潜力

大语言模型在电力系统稳定性分析中具有广泛应用潜力，尤其在处理大规模、多源和多维度数据时展现出明显优势。通过自然语言处理技术，大语言模型能够对电力系统的稳定性进行智能分析，辅助实现系统的稳定性预测与实时监控。同时为应对负荷波动、突发故障等情况提供了有效的预警机制，并通过模型对历史数据的智能解读，帮助电力系统决策者做出更为精准的判断。

尽管大语言模型在电力系统稳定性分析中前景广阔，但实施过程中仍面临一定挑战。例如：如何处理不同来源和格式的数据，以及确保在数据质量不稳定时保持预测准确性；如何解决模型的“黑盒”特性，以满足电力系统对决策透明性和可追溯性的要求；如何平衡模型对计算资源的高需求与实时性要求，以及如何确保在复杂动态环境下，模型能够保持足够的鲁棒性和可靠性，以应对突发故障和异常情况。

总之，无论是离线优化还是在线应用，大语言模型在电力系统稳定性分析中均展现出巨大的潜力。然而，数据质量、模型可解释性、计算资源需求及鲁棒性等问题仍然是制约其广泛应用的关键挑

战。未来的研究需要在数据融合、模型透明度提升、计算优化等方面进行深入探索，以进一步推动大语言模型在电力系统稳定性领域的应用和发展。

5 结论

本文提出了一种基于大语言模型辅助的频率智能调控方案，经过算例分析，得到如下结论：

1）该方案通过构建高质量低频减载样本数据集，利用自然语言处理技术提取参数内在关系形成规则，并运用提示词工程、RAG 与函数调用技术成功实现电力系统垂直领域大语言模型的初步构建。

2）基于大模型技术构建的电力系统垂直领域大模型，成功实现了通用大模型无法完成的频率调控任务，并且通过仿真验证得到，经过该方案初步优化后的频率调控策略优于原低频减载策略。

3）该方案通过多层次的规则验证与实时反馈，有效避免了大模型产生偏离实际的错误推测，显著降低了“幻觉”产生风险。与未经调整的通用大模型相比，该方法提高了频率调控的准确性和可靠性。

本文研究展示出从离线优化到在线辅助生成低频减载策略的全过程，验证了所提出的智能决策方法在电力系统复杂规则适配中的可行性和有效性。尽管本研究在数据规模与资源条件上有所限制，但随着新能源渗透率的增加及系统扰动范围的扩大，基于仿真技术与大语言模型的智能决策支持方法具有广阔的应用前景。

参考文献 References

[1] 张怡，张恒旭，李常刚，等. 深度学习在电力系统频率分析与控制中的应用综述[J]. 中国电机工程学报，2021，41(10)：3392-3406.
ZHANG Yi, ZHANG Hengxu, LI Changgang, et al. Review on deep learning applications in power system frequency analysis and control[J]. Proceedings of the CSEE, 2021, 41(10): 3392-3406.

[2] MACARIO M, ARROYO-SERRANO A, CASTRO L M, et al. Under-frequency load shedding scheme in power grids with renewable generation[C]//2023 IEEE International Autumn Meeting on Power, Electronics and Computing. Ixtapa, Mexico: IEEE, 2023: 1-6.

[3] 胡泽，曾令康，姚伟，等. 电力系统两阶段紧急切负荷控制智能预决策[J]. 中国电机工程学报，2024，44(4)：1260-1271.
HU Ze, ZENG Lingkang, YAO Wei, et al. Intelligent pre-decision of two-stage emergency load shedding control in power systems[J]. Proceedings of the CSEE, 2024, 44(4): 1260-1271.

[4] 赵熙临，龚楚峰，付波. 一种风电场经 VSC-HVDC 并网的 VSG 变参数负荷频率控制策略[J]. 高电压技术，2024，50(1)：117-126.
ZHAO Xilin, GONG Chufeng, FU Bo. A VSG variable parameter load frequency control strategy for wind farms connected to the grid by VSC-HVDC[J]. High Voltage Engineering, 2024, 50(1): 117-126.

[5] 王彤，刘九良，朱劭璇，等. 基于随机森林的电力系统暂态稳定评估与紧急控制策略[J]. 电网技术，2020，44(12)：4694-4701.
WANG Tong, LIU Jiuliang, ZHU Shaoxuan, et al. Transient stability assessment and emergency control strategy based on random forest in power system[J]. Power System Technology, 2020, 44(12): 4694-4701.

[6] 蔡国伟，孙正龙，王雨薇，等. 基于改进频率响应模型的低频减载方案优化[J]. 电网技术，2013，37(11)：3131-3136.
CAI Guowei, SUN Zhenglong, WANG Yuwei, et al. Optimization of under frequency load shedding scheme based on improved system frequency response model[J]. Power System Technology, 2013, 37(11): 3131-3136.

[7] 刘克天，张钧，李军，等. 基于频率偏移面积的功率缺额计算及低频减载整定[J]. 电工技术学报，2021，36(5)：1040-1051.
LIU Ketian, ZHANG Jun, LI Jun, et al. Power deficit calculation and under frequency load shedding strategy based on the frequency deviation area[J]. Transactions of China Electrotechnical Society, 2021, 36(5): 1040-1051.

[8] 高剑，朱童，罗异，等. 考虑配网负荷曲线特性的低频减载执行方案调整方法[J]. 电力系统保护与控制，2021，49(24)：159-167.
GAO Jian, ZHU Tong, LUO Yi, et al. Adjustment method for a low frequency load shedding implementation scheme considering load curve characteristics of a distribution network[J]. Power System Protection and Control, 2021, 49(24): 159-167.

[9] SUN M Y, LIU G Y, POPOV M, et al. Underfrequency load shedding using locally estimated RoCoF of the center of inertia[J]. IEEE Transactions on Power Systems, 2021, 36(5): 4212-4222.

[10] LEKSHMI J D, RATHER Z H, PAL B C, Online estimation of disturbance size and frequency nadir prediction in renewable energy integrated power systems[J]. IEEE Transactions on Power Systems, 2024, 39(1): 1126-1137.

[11] GOLPÎRA H, BEVRANI H, ROMÁN MESSINA A, et al. A Data-driven under frequency load shedding scheme in power systems[J]. IEEE Transactions on Power Systems, 2023, 38(2): 1138-1150.

[12] 王怀远，何培灿，温步瀛. 基于响应信息的分散式低频减载方案[J]. 电网技术，2019，43(8)：2976-2982.
WANG Huaiyuan, HE Peican, WEN Buying. Decentralized under-frequency load shedding scheme based on response information[J]. Power System Technology, 2019, 43(8): 2976-2982.

[13] LYTVYNCHUK V A, KAPLIN M I, BOLOTNYI N P. The method of design an optimal under-frequency load shedding scheme[C]//2019 IEEE 6th International Conference on Energy Smart Systems. Kyiv, Ukraine: IEEE, 2019: 14-17.

[14] LI C G, WU Y, SUN Y L, et al. Continuous under-frequency load shedding scheme for power system adaptive frequency control[J]. IEEE Transactions on Power Systems, 2020, 35(2): 950-961.

[15] WANG D, YIN C, LIU L Y, et al. Research on intelligent matching technology of power grid dispatching automation emergency plan based on large model and small sample LoRA fine-tuning algorithm[C]//2024 9th Asia Conference on Power and Electrical Engineering. Shanghai, China: IEEE, 2024: 1390-1396.

[16] 赵振兵，冯烁，席悦，等. 大模型时代：电力视觉技术新起点[J]. 高电压技术，2024，50(5)：1813-1825.
ZHAO Zhenbing, FENG Shuo, XI Yue, et al. The era of large models: a new starting point for electric power vision technology[J]. High Voltage Engineering, 2024, 50(5): 1813-1825.

[17] DU H Y, LI Z H, NIYATO D, et al. Enabling AI-generated content services in wireless edge networks[J]. IEEE Wireless Communications, 2024, 31(3): 226-234.

[18] 张俊，徐箭，许沛东，等. 人工智能大模型在电力系统运行控制中的应用综述及展望[J]. 武汉大学学报(工学版)，2023，56(11)：

1368-1379.
ZHANG Jun, XU Jian, XU Peidong, et al. Overview and prospect of application of artificial intelligence large model in power system operation control[J]. Engineering Journal of Wuhan University, 2023, 56(11): 1368-1379.

[19] 李刚，方鸿，刘云鹏，等. 新型电力系统中的大模型驱动技术：现状、机遇与挑战[J]. 高电压技术，2024，50(7)：2864-2878.
LI Gang, FANG Hong, LIU Yunpeng, et al. Large-model drive technology in new power system: status, challenges and prospects[J]. High Voltage Engineering, 2024, 50(7): 2864-2878.

[20] NI M J, ZHANG J, FU C, et al. ChatGrid: intelligent knowledge Q&A for power dispatching control based on large language models and retrieval-augmented generation[C]//2024 IEEE 7th Information Technology, Networking, Electronic and Automation Control Conference. Chongqing, China: IEEE, 2024: 921-925.

[21] 张孝顺，李锦诚，郭正勋. 大模型辅助的大型海上风电场集电系统拓扑优化[J]. 高电压技术，2024，50(7)：2894-2905.
ZHANG Xiaoshun, LI Jincheng, GUO Zhengxun. Topology optimization of large-scale offshore wind farm collector systems based on large language models[J]. High Voltage Engineering, 2024, 50(7): 2894-2905.

[22] 陈艳波，方哲，张宁，等. 基于大语言模型绿电预测和绿电交易的园区综合能源系统集群多目标协同运行方法[J]. 高电压技术，2024，50(7)：2849-2863.
CHEN Yanbo, FANG Zhe, ZHANG Ning, et al. Multi-objective collaborative operation method for park-level integrated energy system cluster based on large language model for green electricity prediction and trading[J]. High Voltage Engineering, 2024, 50(7): 2849-2863.

[23] TAN L, XIANG Y, TANG B H, et al. Large language model based framework for secure operation of power systems[C]//2024 3rd International Conference on Power Systems and Electrical Technology. Tokyo, Japan: IEEE, 2024: 695-699.

[24] 赵俊华，文福拴，黄建伟，等. 基于大语言模型的电力系统通用人工智能展望：理论与应用[J]. 电力系统自动化，2024，48(6)：13-28.
ZHAO Junhua, WEN Fushuan, HUANG Jianwei, et al. Prospect of artificial general intelligence for power systems based on large language model: theory and applications[J]. Automation of Electric Power Systems, 2024, 48(6): 13-28.

[25] RUAN J Q, LIANG G Q, ZHAO H, et al. Applying large language models to power systems: potential security threats[J]. IEEE Transactions on Smart Grid, 2024, 15(3): 3333-3336.

[26] 中华人民共和国国家质量监督检验检疫总局，中国国家标准化管理委员会. 风电场接入电力系统技术规定：GB/T 200[S]. 北京：中国电力出版社，2011.
General Administration of Quality Supervision, Inspection and Quarantine of the People's Republic of China, Standardization Administration of the People's Republic of China. Technical rule for connecting wind farm to power system: GB/T 200[S]. Beijing, China: China Electric Power Press, 2011.

[27] 国家能源局. 电力系统自动低频减负荷技术规定：DL/T 428—2010[S]. 北京：中国电力出版社，2011.
National Energy Administration. Technical rules for power system automatic under-frequency load shedding: DL/T 428—2010[S]. Beijing, China: China Electric Power Press, 2011.

[28] ELYASICHAMAZKOTI F, TEIMOURZADEH S, AMINIFAR F. Optimal distribution of power grid under-frequency load shedding with security considerations[J]. IEEE Transactions on Power Systems, 2022, 37(5): 4110-4112.

[29] 丁俐夫，陈颖，肖谭南，等. 基于大语言模型的新型电力系统生成式智能应用模式初探[J]. 电力系统自动化，2024，48(19)：1-13.
DING Lifu, CHEN Ying, XIAO Tannan, et al. Exploration of generative intelligent application mode for new power systems based on large language models[J]. Automation of Electric Power Systems, 2024, 48(19): 1-13.



李文彪
1987—，男，博士，教授
主要从事电力系统频率稳定以及人工智能方向的研究工作
E-mail: hlbhl@163.com

LI Wenbiao
Ph.D., Professor



张泽栋(通信作者)
2000—，男，硕士生
主要从事电力系统频率稳定以及人工智能方向的研究工作
E-mail: 18943520501@163.com

ZHANG Zedong
Corresponding author

收稿日期 2025-02-18 修回日期 2025-04-09 编辑 卫李静