



专题：AI赋能通信网络

云网配置稽核大模型及其在IP网中的应用

谢李沁, 林文通, 张正, 丁煜, 束栋, 朱雯慧

(中国电信股份有限公司江苏分公司, 江苏 南京 210000)

摘要: 在云网运维领域, 网络稳定性和安全性至关重要。除设备软硬件故障外, 70%的云网故障是由不规范的配置所引起的, 因此定期对设备配置进行稽核显得尤为重要。然而, 传统采用人工编写规则, 逐行校验配置文本的稽核方式效率低下, 难以满足实际需求。为此, 设计并开发了一套基于强化学习算法微调的云网配置稽核大模型, 该模型能够自动化检测并纠正网络配置中的不规范行为, 进而提升云网运维的稳定性和安全性。测试结果表明, 该模型在提高稽核效率、降低网络故障发生率、减少运维成本方面成效显著, 为云网配置稽核提供了创新性解决方案, 也为后续在模型优化、拓展应用场景及与新兴网络技术融合等方面的研究奠定了基础。

关键词: 配置稽核; 微调; 强化学习; 大语言模型; 提示词工程

中图分类号: TN915.04; TP393.0

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2025261

Large language model for cloud-network configuration audit and its application in IP network

XIE Liqin, LIN Wentong, ZHANG Zheng, DING Yu, SHU Dong, ZHU Wenhui

China Telecom Co., Ltd. Jiangsu Branch, Nanjing 210000, China

Abstract: In the field of cloud-network operation and maintenance, network stability and security are of utmost importance. Apart from software and hardware failures of equipment, 70% of cloud-network failures are caused by non-standard configurations. Therefore, it is particularly important to regularly audit the device configurations. However, the traditional auditing method of writing rules manually and checking the configuration text line by line is inefficient to meet the actual needs. For this purpose, a cloud-network configuration auditing system based on the reinforcement learning fine-tuning large language model was designed and developed. This model could automatically detect and correct non-standard behaviors in network configurations, thereby enhancing the stability and security of cloud-network operation and maintenance. The test results show that this model has achieved remarkable results in improving the auditing efficiency, reducing the occurrence rate of network failures, and cutting down the operation and maintenance costs. It provides an innovative solution for cloud-network configuration auditing and lays a foundation for subsequent research in model optimization, expanding application scenarios, and integrating with emerging network technologies.

Key words: configuration audit, fine-tuning, reinforcement learning, large language model, prompt engineering

收稿日期: 2025-06-24; 修回日期: 2025-11-05

通信作者: 谢李沁, xielq@chinatelecom.cn

0 引言

在全球数字化浪潮的推动下，网络已然成为社会运转的关键基础设施。运营商作为网络服务的核心提供者，其网络的稳定性至关重要。近年来，业务集中上云以及虚拟化进程加快，新技术的引入导致网络复杂度增加，业务范围也得以拓展。随着网络规模的扩大，互联网协议（Internet protocol, IP）网络设备数量增多，运营商网络中存在上万台路由器、交换机等设备，稍有不慎，就可能出现IP地址冲突、路由环路等问题，引发网络故障。据统计，除设备本身的软硬件故障外，约70%的云网故障是由不规范的配置所引起的。这包括但不限于错误的路由设置、不安全的访问控制策略、配置命令冗余或缺失，以及配置命令中的语法错误等^[1-4]。这些非标准配置往往源于人为操作失误或对复杂系统的理解不足。

为了避免这类问题的发生，定期对设备配置进行稽核显得尤为重要。本文创新性引入微调后的云网配置稽核大模型，解决现有技术在云网运维领域中设备配置稽核存在的稽核效率低下、适应性不足以及兼容性差等问题，同时设计一种自动化系统，通过配置文件集自动导入、配置模板自动生成、基于标准化稽核提示词框架拼接问题、利用微调后的大模型进行稽核等步骤，快速适配不同专业、不同厂商的设备配置，及时发现并修正配置中的错误，从而预防潜在的网络故障，以提升系统的整体稳定性。

1 云网配置稽核技术基础与大模型构建

1.1 云网配置稽核探索过程

在传统运维中进行配置稽核，需要人工编写规则，逐行校验配置文本，耗时半年才能使稽核率达到75%左右。这不仅导致工作量巨大，而且面对复杂多变的网络环境，规则的维护与更新成

为了一场旷日持久的挑战，严重影响了运维效率与质量。

为了解决传统配置稽核过程中由人工编写规则带来的效率低下与易错问题，本文首先尝试了基于Drain算法和句子嵌入模型（sentence-BERT, S-BERT）的小模型稽核方法。其中，Drain算法自动生成配置模板，S-BERT和编辑距离算法提供稽核能力。测试发现，通过这种小模型稽核方式，能够将稽核时长缩短至一周，但对S-BERT进行微调时，每次仅支持单专业、单厂商的场景。

目前，借助于既有的配置规范和现网配置，可通过Drain算法自动生成配置模板，并依据维护手册和配置命令手册，构建微调语料，生成云网配置稽核大模型，基于大模型实现稽核。云网配置稽核大模型不仅能够理解各类层级网络设备的标准化配置要求，还能够在检测到不合规配置时，即时提供优化建议与推荐配置，大大提升了配置的规范性和网络的稳定性。单次微调大模型，全厂商均可复用，也可推广至不同专业。

1.2 云网配置稽核大模型技术及构建

本文基于Drain算法与微调大模型，实现了IP设备配置稽核。其中，Drain算法用于实现配置模板的自动生成^[5]。Drain算法能够在对多份现网配置文件的解析过程中，对每个原始配置行的固定部分和可变部分进行区分，将其中的参数与关键字区分开，针对关键字部分，以配置块作为最小单位，构建配置块模板库。首先，使用Drain算法进行初步提取，再利用统计分析对可枚举模板、高频模板进行补充；其次，以配置块为单位，构造配置块的模板库。当遇到新的配置条目时，Drain会尝试将其与已知的模板匹配。如果找不到匹配项，就创建一个新的模板。同时，它还会定期查看是否有非常相似的模板，然后合并它们，以减少重复，让分类更加清晰。现网配置的模板生成情况如图1所示。



输入配置块

```

cgn-pool pppoe-nat-public-cll-02 poolid 3 mode pat
alarm-threshold static-port-range-block 90
port-allowed-range 4096 65535
res-alloc-policy mask 26 assign forward
res-alloc-position remote ippool-name pppoe-nat-public-cll low 70 high 90
bind-pool pppoe-nat-public-cll

```

生成配置模板

```

cgn-pool <*> poolid <*> mode pat
alarm-threshold static-port-range-block 90
port-allowed-range 4096 65535
res-alloc-policy mask <*> assign forward
res-alloc-position remote ippool-name <*> low 70 high 90
bind-pool<*>

```

图1 现网配置的模板生成情况

微调是大模型学习新技能的过程。通用大模型虽然具备广泛的知识，但对特定领域的理解仍需要学习大量专业数据，以帮助模型更准确地学习到该领域的特征，提升泛化能力^[6-9]。灌入云网知识，能够让大模型会“计算机断层扫描（computed tomography, CT）”，从“大学毕业”晋级到“云网专家”，具备IP配置稽核能力。微调语料是专门用来帮助模型学习新技能的数据集，但人工编写高质量的问答对语料需要大量时间，不仅增加了人力成本，还延长了项目周期。

针对此，本文提出了一种基于随机算法的数

据增强方法，以标准化稽核提示词为框架，在框架内拼接待稽核配置、待比对模板、参数说明等，用于生成大规模高质量的微调问答对^[10-12]。该方法能够在原始数据的基础上创建出丰富多样的新样本，从而有效增加训练集的规模和复杂度。

基于实际稽核场景，本文归纳梳理出12类常见的配置错误模式，包括单行配置冗余、单行配置缺失、配置内容错误、配置行组合顺序错误、语义冲突等。在基于Drain算法提取的现网配置模板基础上，本文通过设定独立的随机生成概率，模拟上述各类错误，进而构建配置项的正样本与负样本数据集，确保对真实复杂错误具备泛化能力。随机算法生成的问答对如图2所示。其中，正样本是以配置模板A为基础，生成与之对应、没有任何错误的配置模块B。负样本是对配置模块B进行一定的修改，生成错误配置模块C，各个错误类型以独立随机概率存在。

在构建微调语料的问答对过程中，提示词框架扮演了一个至关重要的角色，它构建了问题与预期答案之间的关联框架。标准化稽核问题提示词框架如图3所示，该框架包含了以下六大要素。



图2 随机算法生成的问答对

能力与角色	你是一名网络运维专家，对网络设备的配置规范非常了解，现在请利用你的专业知识解答用户的问题。
指令	对于一个由复数行组成的配置块，以及对应的配置模板，你可以通过对比配置块和配置模板，判断配置块是否存在异常。如果存在异常，你可以说明异常原因，并给出正确配置。
待稽核配置	待稽核的配置如下所示： this is a demo hello world hello AI
待比对模板	待对比的模板如下所示： this is a <*> hello world
模板参数信息	模板的参数信息如下：这个模板中所有的<*>都是可变参数，在配置块中可以被替换成任意不含空格的数字或者字符串。模板的解释说明如下：该模板作为一个样例，用于展示。
思维链	稽核步骤如下： 步骤1：逐行对比配置块和配置模板，判断是否存在和配置模板不符的地方。逐行对比的时候严格遵循以下几点要求： 第1点：这个模板不能任意增加行或者删除行，否则视为异常。 第2点：..... 第3点：..... 第4点：..... 步骤2：根据步骤1的逐行对比结果，判断配置块是否异常。如果任意一行异常，则配置块为异常，否则为正常。 步骤3：如果步骤2判断配置块异常，请给出正确配置。

图3 标准化稽核问题提示词框架

(1) 能力与角色：指明模型扮演的身份是一名懂网络配置的网络运维专家。

(2) 指令：明确告诉模型要对网络配置进行稽核，如果发现异常，则指导大模型的行动方向。

(3) 待稽核配置：仿照待比对模板，生成不同类型的错误配置或正确配置。

(4) 待比对模板：配置模板自动生成过程中组装生成的配置模块。单个问答对中只需要一个配置模块，问答对集则需要较多配置模块，可从 Drain 算法生成的配置模板中随机组合获取。

(5) 模板参数信息：结合语句释义和参数说明，丰富该模板的相关资料。

(6) 思维链：说明稽核的步骤，引导稽核的思路，促进逻辑思考。值得注意的是，该思维链融合了实际稽核场景中的关键约束与语义特征，内嵌对配置行的可重复性、参数间关联约束（如参数 A 与参数 B 的取值依赖）、条件判断类规则以及上下文依赖关系的推理机制等，赋予大模型在多变、非线性配置环境下的上下文感知与条件推理能力，从而显著提升其对复杂语义的准确理解与综合判断水平。

标准化稽核回答提示词框架如图4所示，该框架包含了以下三大要素。

思考过程	步骤1的稽核结果： 配置的第3行存在异常。这一行的语句hello AI是冗余的，应该删除。
总结	步骤2的稽核结果： 根据以上分析，配置块是异常的。
推荐	步骤3的稽核结果： 综合以上意见，推荐将配置改为如下写法： this is a demo hello world

图4 标准化稽核回答提示词框架

(1) 思考过程：根据标准化稽核问题提示词框架中提到的思维链，按照稽核步骤，回答出思考结果。

(2) 总结：根据思考过程中的结果，最终给出配置块是正常或异常的结论。

(3) 推荐：若配置块存在异常，根据问题中的待比对模板，推荐一份正确配置。

采用上述方法生成的大规模微调数据集，可以大幅缩短模型达到最优性能所需的时间，同时减少对手动标注数据的高度依赖，为实现高效、低成本的模型优化提供了新的途径。生成微调语料后，将语料“喂”给大模型，从而使微调后的大模型具备配置稽核能力。

本文将原本常见的监督微调方法，改为使用强化学习算法对大模型进行微调^[13-15]。这种转变突破了传统监督微调方法在生成质量与个性化响应方面的局限性。通过引入强化学习框架，基于



奖励反馈机制的组相对策略优化 (group relative policy optimization, GRPO), 模型能够在多轮交互中不断优化其输出策略, 以更好地对齐用户意图和行为规范。相较于仅依赖标注数据的监督微调, 强化学习微调使模型具备更强的泛化能力与可控性, 适用于复杂任务场景。

强化学习过程如图 5 所示。该过程以微调问答对作为训练语料, 将问题输入策略模型, 模型对其进行 N 次独立推理, 生成 N 个不同的预测结果。随后, 将这些预测结果分别送入奖励模型进行评分。奖励模型基于预设的评估维度, 对每个预测结果进行量化评估, 得到 N 个对应的奖励得分。为进一步提升评分结果的可比性和稳定性, 对每组候选回答的原始奖励得分进行归一化处理, 最终获得一组归一化后的奖励得分。基于归一化的奖励构建优势函数, 用于衡量某个候选输出相对于其他选项的优势程度。

本文通过优化目标函数, 调整策略模型部分参数^[16], 让策略模型生成高奖励输出的概率最大化, 倾向于生成排名靠前的回答。为防止策略更新过程中奖励模型偏差或高方差优势估计导致的梯度爆炸与训练震荡, 本文引入双重稳定机制。

(1) 库尔贝克-莱布勒 (Kullback-Leibler, KL) 散度正则化约束: 为限制新旧策略之间的偏离程度, 避免模型在早期奖励信号不稳定时发生剧烈跳变, 在目标函数中加入 KL 散度惩罚项, 用于

平衡奖励优化与策略稳定性。该机制等效于构建一个“信任域”, 确保每次更新在可控范围内进行。

(2) 早停机制与验证集监控: 每轮完整迭代后, 在独立构建的验证集上评估模型生成结果的语义准确率与格式合规性。若连续 3 轮验证性能均未提升, 则提前终止训练, 防止过拟合, 并规避因奖励模型偏差积累导致的策略退化。

上述优化策略在训练集上多轮迭代执行, 每一轮中, 使用当前策略模型对每个问答对生成新响应, 基于多维度奖励模型重新评分与排序, 计算优势函数并更新模型参数。每个问答对触发一次梯度更新, 完成全部样本即构成一轮完整的强化学习微调周期。随着迭代的进行, 策略模型逐步收敛至一个既能生成高奖励输出, 又保持语义一致性与生成稳定性的高质量生成策略。

本文采用基于 GRPO 的策略进行强化学习微调, 其中奖励模型预设了 4 个评估维度, 分别是步骤格式奖励、步骤遵循奖励、步骤重复惩罚以及 Qwen3 正确性评分。步骤格式奖励会提高满足标准格式的预测结果的评分; 步骤遵循奖励会提高按照步骤执行的预测结果的评分; 步骤重复惩罚会降低出现重复冗余步骤的预测结果的评分; Qwen3 正确性评分会用 Qwen3 大模型对预测结果和问答对中的回答进行语义识别, 提高语义与标准回答相似的预测结果的评分。在奖励建模阶

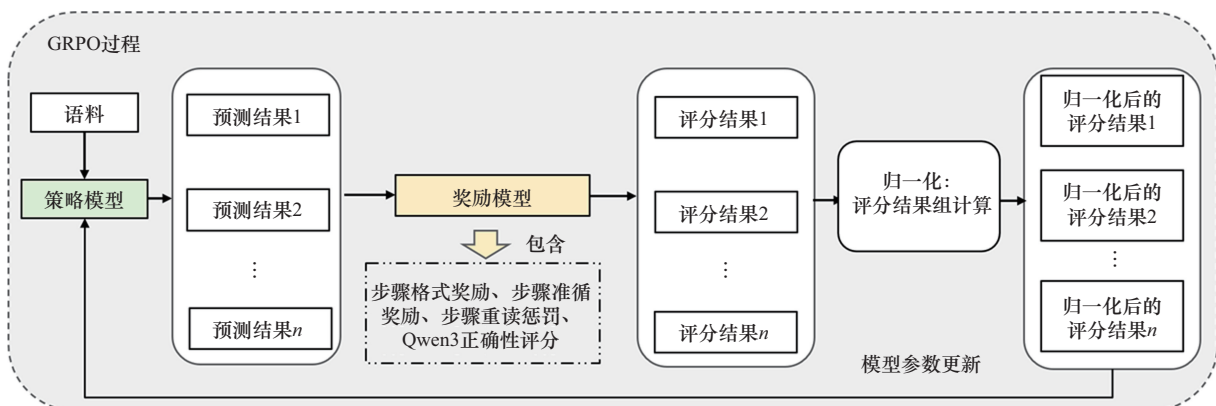


图5 强化学习过程

段, 本文设计了一个多维度、可量化的复合奖励函数 $R(y)$, 用于评估模型生成的配置响应 y 相对于标准回答 y^* 的质量。该奖励函数由 4 个正交维度构成, 表示为:

$$R(y) = w_1 R_{\text{format}}(y) + w_2 R_{\text{step}}(y) + w_3 R_{\text{rep}}(y) + w_4 R_{\text{sem}}(y, y^*) \quad (1)$$

其中, $R_{\text{format}}(y)$ 、 $R_{\text{step}}(y)$ 、 $R_{\text{rep}}(y)$ 、 $R_{\text{sem}}(y, y^*)$ 分别表示步骤格式奖励、步骤遵循奖励、重复惩罚项和语义正确性评分, 权重系数 $w_i > 0$, 初始设为等权分配 (即 $w_i = 1$), 后续可通过在线学习动态调整来平衡形式与语义的优化目标。

步骤格式奖励 $R_{\text{format}}(y)$ 用于衡量生成内容是否符合预定义的结构化输出格式, 如“步骤 1 的稽核结果: ……”“综合以上定义……”。步骤格式奖励采用规则匹配结合正则表达式的方法进行打分, 表示为:

$$R_{\text{format}}(y) = 1 - \frac{|N_y - N^*|}{N^*} \times 0.25 \quad (2)$$

其中, N^* 为标准步骤数, N_y 为生成回答中符合预定义格式的步数。当语句完全符合格式模板时取值为 1, 否则按照比例扣分直到为 0。

步骤遵循奖励 $R_{\text{step}}(y)$ 用于评估生成的响应是否遵循问题中指定的执行流程或逻辑顺序, 通过计算生成步骤序列与标准流程之间的最长公共子序列 (longest common subsequence, LCS) 归一化长度来量化, 表示为:

$$\begin{cases} R_{\text{step}}(y) = \frac{\text{LCS}(S_y, S^*)}{\max(S_y, S^*)} \cdot \frac{\text{LCS}(S_y, S^*)}{\max(S_y, S^*)} = 1 \\ R_{\text{step}}(y) = 0, \frac{\text{LCS}(S_y, S^*)}{\max(S_y, S^*)} \neq 1 \end{cases} \quad (3)$$

其中, S_y 和 S^* 分别为生成步骤和标准步骤的动作关键词序列。当语句完全符合格式模板时取值为 1, 否则为 0。

重复惩罚项 $R_{\text{rep}}(y)$ 用于抑制冗余或重复步骤

的生成。当生成回答重复时, 按照重复次数扣分, 表示为:

$$R_{\text{rep}}(y) = -Q_y \quad (4)$$

其中, Q_y 为生成回答中重复出现的行数。

语义正确性评分 $R_{\text{sem}}(y, y^*)$: 为增强对深层语义一致性的捕捉, 本文引入 Qwen3 作为裁判模型, 以生成回答 y 和标准回答 y^* 的语义相似度得分作为奖励信号, 输出一个 0~1 之间的归一化相似度分数, 表示为:

$$R_{\text{sem}}(y, y^*) = \text{Sim}_{\text{Qwen3}}(y, y^*) \quad (5)$$

为避免模型过度优化表面特征而忽略语义本质, 在训练后期引入动态权重机制, 根据语义奖励的稳定性逐步提升权重系数 w_4 的比重, 引导模型从“形式合规”向“语义正确”演进。

强化学习奖励模型的得分趋势如图 6 所示。由于奖励模型评分存在结果相同的情况, 此时该组的最终优势为 0, 这会抑制策略模型的更新, 因此, 本文引入动态采样机制^[17], 对相同奖励评分的结果进行采样和过滤, 使得所有结果都具有有效的梯度, 保证策略模型能够正常更新。最终, 得到基于强化学习算法微调的云网配置稽核大模型。

在实际使用过程中, 当用户输入一个现网配置块时, 系统会将配置块自动处理成与模板一致的格式。具体过程为: 先利用词频-逆文件频率 (term frequency-inverse document frequency, TF-IDF) 向量匹配方法, 找出与现网配置最相似的配置模板, 再在语句释义库和参数说明库中抓取参考内容, 如参数范围等, 基于标准化稽核提示词框架拼接问题, 最终调用大模型, 提出问题, 让大模型回答, 并生成报告。配置稽核方案流程如图 7 所示。

1.3 云网配置稽核系统核心架构

为实现对复杂云网配置的高效、精准稽核, 本文以云网配置稽核大模型为核心, 构建了一个

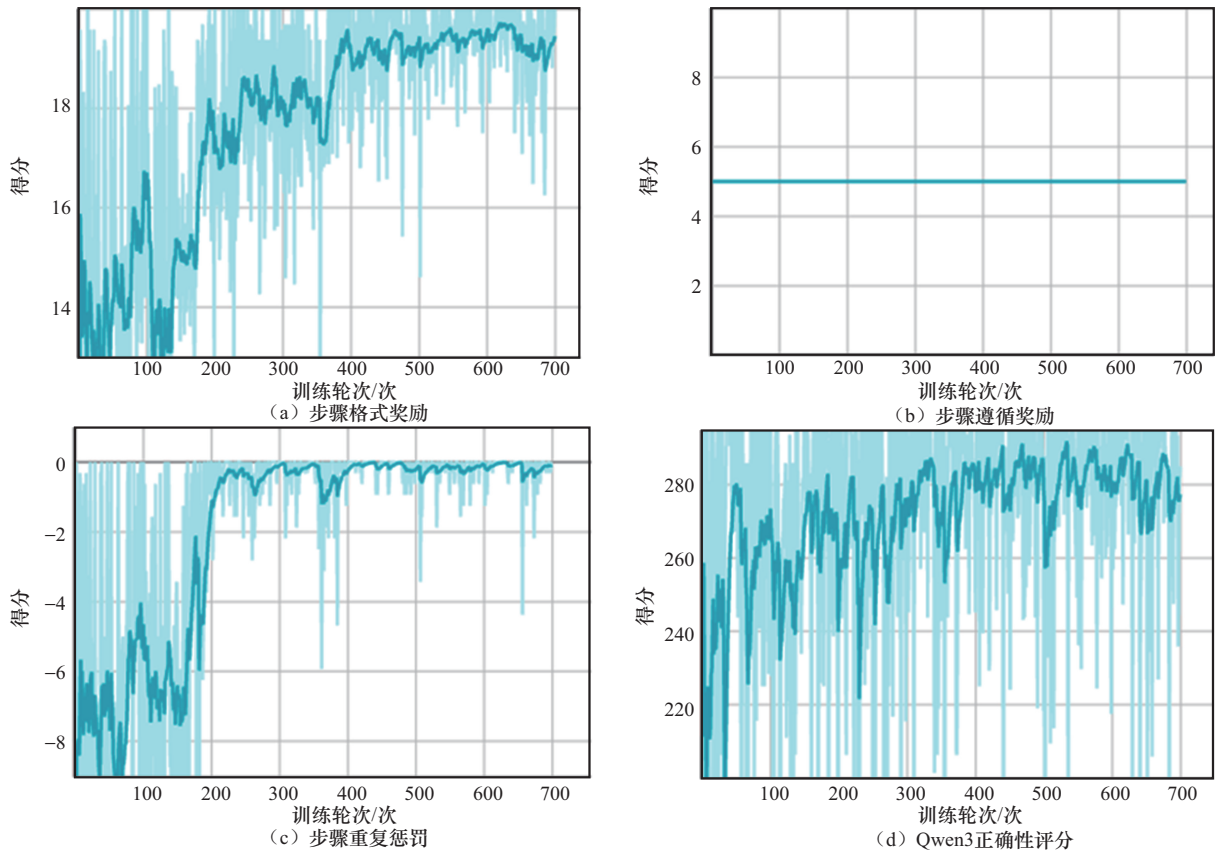


图6 强化学习奖励模型的得分趋势

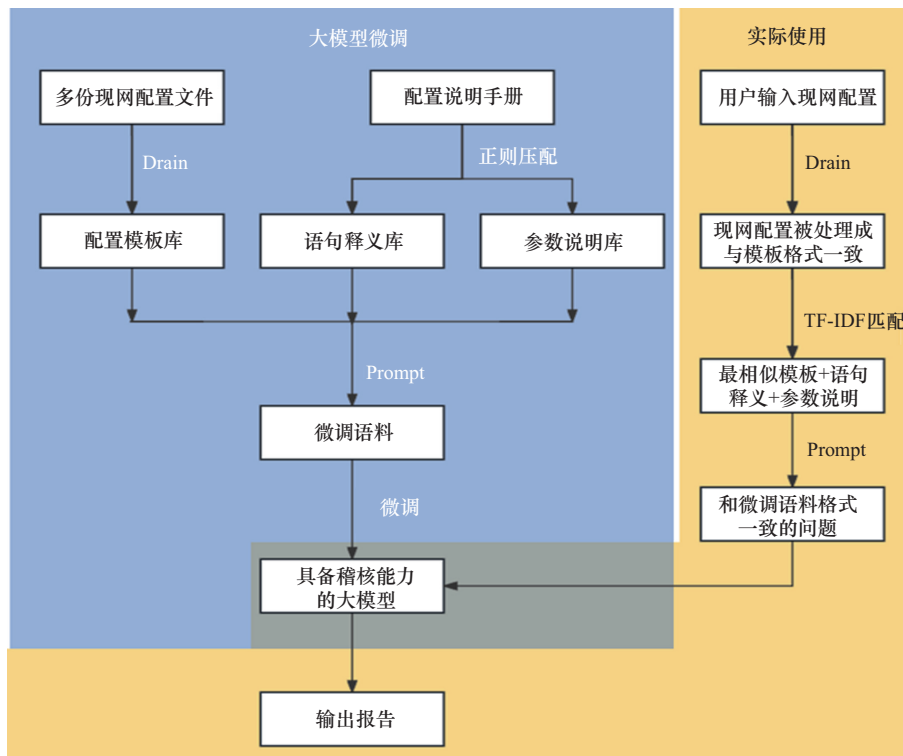


图7 配置稽核方案流程

面向多源异构配置数据的智能稽核大模型系统。该系统的核心架构由数据采集层、语义关系层、AI推理层和决策执行层4部分构成，各层协同工作，形成从原始配置解析到智能判断输出的完整闭环。

(1) 数据采集层：负责从多类云网设备（如路由器、交换机）中采集原始配置文本，支持安全外壳（secure shell, SSH）协议、简单网络管理协议（simple network management protocol, SNMP）、网络配置（network configuration, NETCONF）协议对网络设备进行配置数据采集，采集周期为24 h。数据采集层将采集的设备配置文件以JSON格式上传至指定的Ceph桶，并标注关键信息，如设备IP地址、设备类型、设备厂商、时间戳等；获取每个文件的设备配置部分作为数据集，对其中的特殊字符做清理工作，以确保后续解析过程顺利。此外，数据采集层支持配置版本历史采集，为后续变更稽核与上下文追踪提供数据基础。

(2) 语义关系层：在配置文本基础上，构建面向稽核任务的语义理解与关系建模能力。该层通过提取关键配置项（如IP地址、端口、协议、访问控制列表（access control list, ACL）规则等），显式建模参数间的语义关系，具体包括取值依赖（如要启用IPSec则必须配置安全参数索引（security parameter index, SPI）和密钥）、互斥约束（如网络地址转换（network address translation, NAT）与直通模式不可共存）、上下文继承（如父接口配置对子接口的默认影响）、重复配置语义（判断重复语句是冗余还是正常叠加）。该层输出结构化的语义关系，为AI推理层提供富含逻辑上下文的“思维链”。

(3) AI推理层：作为系统核心，该层基于云网配置稽核大模型实现智能稽核判断，采用“能力与角色+指令+待比对模板+待稽核配置+模板参数信息+思维链”的标准化稽核问题提示词框架，

引导模型进行多步逻辑推理。

(4) 决策执行层：对AI推理层输出的稽核结果进行后处理，生成可执行的决策建议，具体包括风险等级分类、稽核问题归因、修复建议生成、可视化报告输出与人工复核接口。该层支持与运维流程系统对接，实现从“发现问题”到“闭环处置”的自动化联动。

2 模型在IP网中的应用与效果评估

2.1 云网配置稽核大模型的特点

云网配置稽核大模型具备以下3个特点。

(1) 不发散：推荐配置准确，不再发散。这是因为预训练提供了良好的初始化，可以视为一个更靠近最优解的起始点，降低了发散的风险。

微调大模型不发散示例如图8所示。未微调时，将问题直接输入开源大模型中，大模型的回答会将不应存在的错误配置放入推荐配置中，但将问题输入微调后大模型中，由于微调后大模型的回答不再发散，因此，能够准确地反馈配置的错误原因，并给出准确的推荐配置。

(2) 适应性强：微调语料格式统一，模型仅需要单次微调，即可适应各厂商、各层级设备。



图8 微调大模型不发散示例



稽核能力适应异厂商示例如图9所示。在云网配置稽核大模型的训练过程中，训练语料均来源于华为设备的配置文本，图9的示例中，模型即使在未见中兴设备配置的情况下，仍能取得与华为配置相当的准确稽核效果。考虑实际稽核场景的复杂性，网络设备涵盖华为、中兴、华三、思科等多个厂商，且在脊（spine）、叶（leaf）等不同网络层级间配置模式存在显著差异。为全面评估模型的泛化能力，本文在测试阶段构建了一个包含多厂商、多层级的异构配置语料测试集，覆盖主流设备厂商及典型网络架构。实验结果显示，尽管模型仅以华为配置进行训练，仍能在该多源异构测试集上保持稳定的稽核性能，充分体

现了其对不同厂商和网络层级配置模式的良好适应性与强鲁棒性，具备在多样化真实场景中推广应用的潜力。

（3）拓展性强：针对未考虑的异常类型，更新微调语料，在问答对中写出详细原因，增强稽核能力。

模型运行初期，本文总结了4类错误——配置冗余、配置缺失、固定参数错误、可变参数超出范围，并以此生成微调语料。模型运行过程中，发现了大模型对于模板中通配符<*>的理解较差。若配置末尾存在多个通配符，大模型对于此类配置稽核能力不佳，需要再通过更多语料来提高学习能力。针对该异常类型，本文通过更新

配置稽核测试问题（中兴）

成的配置块，以及对应的配置稽核原因，并给出正确配置。待校验的配置如下所示：

```

cgn-pool pppoe-nat-public-cll-02 poolid 3 mode pat
alarm-threshold static-port-range-block 90
port-range enable 4096
port-allowed-range 4096 65535
res-alloc-policy mask 26 assign forward
res-alloc-position remote ippool-name pppoe-nat-public-cll low 70 high 90
bind-pool pppoe-nat-public-cll

```

待对比的模板如下所示：

```

cgn-pool <*> poolid <*> mode pat
alarm-threshold static-port-range-block 90
port-range enable 4096
port-allowed-range 4096 65535
res-alloc-policy mask <*> assign forward
res-alloc-position remote ippool-name <*> low 70 high 90

```

模板的结构信息如下：
这个模板的格式是固定的，不能任意增加行或者删除行。
模板的参数信息如下：
这个模板中所有的<*>都是可变参数，在配置块中可以被替换成任意不含空格的数字或者字符串。
此外，如果上文提到的可连续重复的行中含有可变参数，那么在每一个连续重复行中，这些可变参数可以分别取不同的值，只要它们的范围是符合规范的。
模板的解释说明如下：
该模板暂时没有解释。

如果存在异常，你可以说明异常

微调后大模型的回答（中兴）

这个配置是正常的。
配置的第6行存在异常。这一行的语句bind-pool pppoe-nat-public-cll是冗余的，应该删除。
配置缺少语句port-range enable 4096。
配置的第5行存在异常。这一行的语句res-alloc-position remote ippool-name pppoe-nat-public-cll low 70 high 100存在错误。这一行中100与模板要求的写法不一致，建议改成90。
 综合以上意见，推荐将配置改为如下写法：

```

cgn-pool pppoe-nat-public-cll-02 poolid 3 mode pat
alarm-threshold static-port-range-block 90
port-range enable 4096
port-allowed-range 4096 65535
res-alloc-policy mask 26 assign forward
res-alloc-position remote ippool-name <*> low 70 high 90

```

图9 稽核能力适应异厂商示例

语料，在问答对中写出详细原因，再次进行微调，使得召回率提高至 94%。针对通配符问题的微调语料如图 10 所示。

微调语料-问题

- 待校验的配置如下所示:
- user-profile CWWFVOHG COFCJWNUV B4MDGDGV6RO.R 98JPTDA164CKZ
- qos car Y0Z5 any cir XTZ4 cbs HL47ZJFNHNVBIMN1X ebs 0
- 待对比的模板如下所示:
- user-profile <*>
- qos car <*> any cir <*> cbs <*> ebs 0

微调语料-回答

- 这个配置是正常的。
- 配置的第 1 行存在异常。
- 这一行中CWWFVOHG COFCJWNUV B4MDGDGV6RO.R 98JPTDA164CKZ与模板要求的写法不一致，模板中的<*>只能被替换成一个不含空格的数字或字符串，但是该行配置却替换成了4个用空格隔开的字符串，不符合模板规定，建议改成<*>。
- 综合以上意见，推荐将配置改为如下写法:
- user-profile <*>
- qos car Y0Z5 any cir XTZ4 cbs HL47ZJFNHNVBIMN1X ebs 0

图 10 针对通配符问题的微调语料

2.2 云网配置稽核大模型在 IP 网中的应用

在实际稽核场景中，模型依托云网配置稽核系统，实现对网络设备配置项的全面审查与潜在风险识别。

系统支持定时采集网络设备的原始配置文件，并将其解析为多个逻辑独立的配置块，以实现细粒度稽核。针对每个配置块，系统通过调用云网配置稽核大模型进行自动化审查。模型输入采用与训练数据一致的问答对格式，问题构造过程包含 3 个关键步骤：模板匹配、信息提取与提示词拼接。首先，基于 TF-IDF 向量化方法，计算待稽核配置与语句释义库中标准模板的语义相似度，自动选取最匹配的配置模板；其次，从参数说明库与语句释义库中提取相关信息，补充其语义解释与约束条件，形成思维链；最终，依据标准化稽核提示词框架，动态生成结构化提问。大模型返回稽核判断结果，输出内容包括配置正确性判定、错误归因分析及推荐修正方案。系统进一步对模型输出进行结构化解析，并通过可视化模块呈现稽核结果，结果以 Excel、TXT 等通用格式导出，便于归档与共享。展示界面中清晰列出原始配置与模型

反馈，针对不同错误类型（如配置冗余、配置缺失、参数异常、逻辑冲突等）进行分类标注，辅助运维人员快速定位问题、理解成因并制订优化策略，显著提升了网络配置管理的效率与可靠性。

在运营商 IP 网络复杂的运行环境下，云网配置稽核大模型发挥了关键作用，成功定位并解决了一系列棘手问题。其中，Bras VM DHCP 进程重启以及由此引发的用户域名系统（domain-name system, DNS）分配地址错误问题备受关注。当用户正常下线后，其动态主机配置协议（dynamic host configuration protocol, DHCP）租约状态转变为超期租约。若此时 DHCP 进程异常重启，就会触发 DHCP 租约从数据管理（database management, DBM）系统中恢复，进而导致用户获取到错误的 DNS 地址。针对此问题，网络地址转换（network address translation, NAT）私网地址池中应增加 allocate-newip enable 配置，确保用户重新上线后能够拿到不同的私网 IP 地址，规避超期租约，从而解决用户上线获取错误 DNS 地址的问题。云网配置稽核大模型在 IP 网中的应用如图 11 所示。图 11 中，云网配置稽核大模型凭借其强大的分析推理能力，敏锐捕捉到该配置异常的情况，迅速锁定问题根源，发现异常原因并给出推荐配置。

云网配置稽核大模型的核心功能涵盖异常配置识别与智能修复建议生成，旨在实现配置风险的早发现、准定位与快处置。在实际生产环境的持续运行中，系统对典型配置异常（如路由环路、策略冲突、配置缺失等）展现出优异的检测能力，异常配置识别的召回率达到 94%，精确率达到 89%，有效保障了问题发现的全面性与准确性。系统在检测到异常后，模型可精准定位问题至具体配置语句或逻辑冲突点，故障界定准确率达到 86.5%，显著降低了人工排查的认知负荷与时间成本。运维人员可在系统



生成的修复建议基础上进行人工确认，并选择性下发修正配置，形成“检测—定位—建议—执行”的闭环管理流程。该机制将平均异常修复时间从原有的2 h大幅缩短至10 min，处理效率提升约92%。

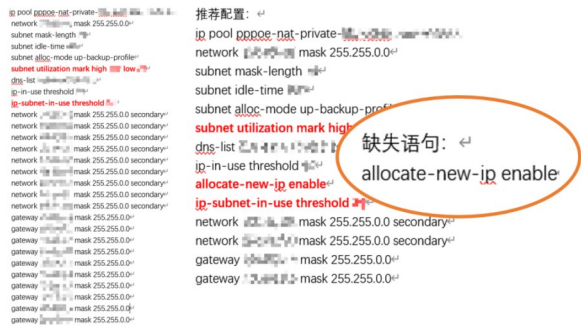


图 11 云网配置稽核大模型在IP网中的应用

项目实施以来，整体配置错误检出率提升30%，在多个重大网络变更窗口中成功提前识别潜在安全隐患，半年内避免了8起可能导致业务中断的重大故障。通过构建自动化稽核与智能决策的协同闭环，系统显著减少了运维团队在例行巡检与故障排查中的重复性工作负担，经测算，年均可节约运维成本约27%，具备良好的经济效益与推广价值。

3 结束语

在云网运维领域，网络稳定性与安全性不容小觑，超70%的故障源于不规范配置，传统人工稽核方式效率低下。针对此，本文开发了一套基于Drain算法与微调大模型的云网配置稽核系统。该系统具备配置文件集自动导入功能，能快速收集配置数据；自动生成配置模板，简化流程；通过标准化稽核提示词框架拼接问题，使问题表述更精准；利用微调大模型进行稽核，极大提升了稽核的智能化程度。本文创新性引入了微调云网配置稽核大模型，有效克服了现有技术稽核效率低、适应性与兼容性差的难题。该模型可快速适配不同专业、不同厂商设备，

精准检测并纠正配置错误。本文以IP网场景为例，成功定位Bras VM DHCP进程重启及用户DNS分配错误问题，助力运维人员解决故障。云网配置稽核大模型显著提高了稽核效率，大幅降低了网络故障发生率，降低了运维成本，为云网配置稽核提供了创新解决方案，有力保障了云网运维的稳定与安全，还为后续模型优化、应用场景拓展及与新兴网络技术融合研究筑牢根基。应用前景方面，该模型的应用不仅局限于配置稽核，这是因为大模型学会了各类配置的含义，后续还能进一步发展为用于配置脚本自动生成与优化的高级工具。通过深度理解各类配置的语义和上下文，系统能根据特定需求或场景自动编写配置脚本，极大地简化了运维人员的工作流程，提高了效率。云网配置稽核大模型作为下一代运维工具的核心，其复制推广与应用前景不可估量，将成为推动企业数字化转型与提升竞争力的重要力量。

参考文献：

- [1] YAN X, HUANG H P, ZOU Z L. Distribution communication configuration audit method based on deep learning technology[C]// Proceedings of the 2024 IEEE 7th International Conference on Information Systems and Computer Aided Education (ICISCAE). Piscataway: IEEE Press, 2024: 989-994.
- [2] LI Y L, ZOU Z L, HUANG H P. Multi-protocol distribution network configuration audit and modeling method[C]// Proceedings of the 2024 International Conference on Electronics and Devices, Computational Science (ICEDCS). Piscataway: IEEE Press, 2025: 956-960.
- [3] KIM S, LEE S, BAIK D K, et al. Configuration management based configuration file version integrity auditing framework[C]// Proceedings of the Annual Conference of KIPS. Piscataway: IEEE Press, 2012: 1511-1514.
- [4] CALDWELL D, LEE S, SEN S, et al. Gold standard auditing for router configurations[C]// Proceedings of the 2010 17th IEEE Workshop on Local & Metropolitan Area Networks (LANMAN). Piscataway: IEEE Press, 2010: 1-6.
- [5] HE P J, ZHU J M, ZHENG Z B, et al. Drain: an online log parsing approach with fixed depth tree[C]// Proceedings of the 2017

- IEEE International Conference on Web Services (ICWS). Piscataway: IEEE Press, 2017: 33-40.
- [6] HU E J, SHEN Y L, WALLIS P, et al. LoRa: low-rank adaptation of large language models[J]. arXiv preprint, 2021: 2106.09685.
- [7] TINN R, CHENG H, GU Y, et al. Fine-tuning large neural language models for biomedical natural language processing[J]. Patterns, 2023, 4(4): 100729.
- [8] DONG G T, YUAN H Y, LU K M, et al. How abilities in large language models are affected by supervised fine-tuning data composition[J]. arXiv preprint, 2023: 2310.05492.
- [9] CHEN T L, LIU S J, CHANG S Y, et al. Adversarial robustness: from self-supervised pre-training to fine-tuning[C]//Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2020: 696-705.
- [10] SU D, XU Y, WINATA G I, et al. Generalizing question answering system with pre-trained language model fine-tuning[C]//Proceedings of the 2nd Workshop on Machine Reading for Question Answering. Piscataway: IEEE Press, 2019: 203-211.
- [11] SHAO Z W, YU Z, WANG M, et al. Prompting large language models with answer heuristics for knowledge-based visual question answering[C]//Proceedings of the 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2023: 14974-14983.
- [12] ZHOU Y C, MURESANU A I, HAN Z W, et al. Large language models are human-level prompt engineers[J]. arXiv preprint, 2022: 2211.01910.
- [13] ZHANG J Y, HUANG J X, YAO H J, et al. R1-VL: learning to reason with multimodal large language models via step-wise group relative policy optimization[J]. arXiv preprint, 2025: 2503.12937.
- [14] DU Y Q, WATKINS O, WANG Z H, et al. Guiding pretraining in reinforcement learning with large language models[J]. arXiv preprint, 2023: 2302.06692.
- [15] CARTA T, ROMAC C, WOLF T, et al. Grounding large language models in interactive environments with online reinforcement learning[J]. arXiv preprint, 2023: 2302.02662.
- [16] DING N, QIN Y J, YANG G, et al. Parameter-efficient fine-tuning of large-scale pre-trained language models[J]. Nature Machine Intelligence, 2023, 5(3): 220-235.
- [17] YU Q Y, ZHANG Z, ZHU R F, et al. DAPO: an open-source LLM reinforcement learning system at scale[J]. arXiv preprint, 2025: 2503.14476.

[作者简介]



谢李沁（1996-），女，现就职于中国电信股份有限公司江苏分公司，主要研究方向为云网运维与AI技术结合。



林文通（1992-），男，现就职于中国电信股份有限公司江苏分公司，主要研究方向为云网运维。



张正（1989-），男，现就职于中国电信股份有限公司江苏分公司，主要研究方向为云网运维与AI技术结合。



丁煜（1994-），男，现就职于中国电信股份有限公司江苏分公司，主要研究方向为云网运维与AI技术结合。



束栋（1978-），男，中国电信股份有限公司江苏分公司高级工程师，主要研究方向为云网运维。



朱雯慧（1994-），女，现就职于中国电信股份有限公司江苏分公司，主要研究方向为云网运维与AI技术结合。