

# 人工智能技术在现代通信网络优化中的应用研究

吴 恺

润建股份有限公司 广西 南宁 530000

**摘要：**随着5G大规模商用和物联网设备爆发式增长，现代通信网络呈现异构融合、动态多变、业务多样等特征，传统基于数学模型和人工经验的优化方法已难以满足复杂场景下的性能要求。本文系统分析了人工智能技术解决通信网络优化问题的技术优势，构建了包含流量预测、资源调度、故障诊断三个核心应用场景的技术框架。基于现网数据的实验验证了所提模型的有效性。本文提出的AI驱动网络优化架构为智能网络运维提供了可落地的技术方案。

**关键词：**人工智能；通信网络优化；流量预测；资源调度；故障诊断

引言：现代通信网络正经历深刻变革，传统依赖网管阈值告警和人工经验调参的运维模式面临严峻挑战。网络流量呈现突发性与周期性交织的复杂特征，频谱资源利用率普遍偏低，网络故障根因定位平均耗时过长。人工智能技术凭借其强大的特征学习与模式识别能力，为突破传统优化方法的瓶颈提供了新路径。本文聚焦流量预测、资源调度、故障诊断三大核心难题，提出AI赋能网络优化的技术框架，并通过真实数据验证其有效性，旨在为通信运营商网络智能化转型提供决策参考。

## 1 通信网络优化面临的核心挑战

### 1.1 网络流量复杂性挑战

现代通信网络的流量特征已超出传统模型的描述能力。4G时代，网络流量呈现明显的周期性规律，早晚高峰特征显著，基于时间序列的ARIMA模型预测误差可控制在10%以内。进入5G时代，增强移动宽带、超可靠低时延通信、海量机器类通信三大场景并存，流量混合度极高。以某市2024年9月的现网数据为例，工作日8时至22时流量持续高位，13时出现小波峰，23时后流量快速下降，但凌晨仍有视频监控、车联网等业务维持约峰值20%的底流量。这种非平稳、高波动、长相关的流量特性，使传统时间序列模型的预测误差升至18%以上。此外，业务突发性显著增强，重大事件、热点推送、网络攻击等异常事件可导致瞬时流量激增300%至500%，传统方法难以准确捕捉。

### 1.2 资源分配效率瓶颈

频谱资源是通信网络最宝贵的资源，但当前利用率普遍偏低。4G网络PRB利用率峰值不足50%，5G网络受终端渗透率和业务成熟度影响，初期利用率更低。造成这一问题的原因包括：基站间负载不均衡，热门商圈基站利用率超80%而相邻站点不足20%；业务类型差异化导致资源需求动态变化，视频业务消耗大、即时消息消耗

小；移动性管理复杂，用户在基站间频繁切换，资源预留机制存在效率损耗。频谱利用率低效直接影响运营商投资回报率，每提升5%的频谱效率可节省约8%的基站建设投资。资源分配问题的核心在于如何在时变信道状态、随机业务到达、异构服务质量约束下，实现频谱、功率、时隙等多维资源的最优配置，这是典型的非凸优化问题，传统启发式算法求解效率低，难以满足毫秒级调度要求<sup>[1]</sup>。

### 1.3 故障诊断与自愈能力不足

网络故障是影响用户体验的直接因素，当前运维体系的短板尤为突出。某运营商数据统计显示，年均发生接入网故障约1200起，单次故障平均影响用户数约3500户，平均故障修复时长为47分钟。造成修复缓慢的主要原因在于：故障告警数量庞大，核心网日均产生告警超过5万条，其中90%以上为衍生告警，人工从海量告警中定位根因如同大海捞针；故障类型复杂多样，覆盖硬件失效、软件异常、配置错误、传输中断等数十大类；故障影响范围评估依赖人工经验，难以快速准确预判。当前运维以“故障发生-告警触发-人工介入-逐步排查-修复验证”的后置被动模式为主，这种模式在4G尚可勉强应对，但面对5G更复杂的组网结构和更严格的服务等级协议，亟需向基于AI的预测式主动运维转变。

## 2 AI赋能网络优化的技术框架

本文提出的AI驱动网络优化框架采用分层架构，自下而上包括数据采集层、智能分析层和优化决策层。数据采集层负责从网管系统、探针设备、信令监测平台采集性能指标、告警日志、配置参数等多源数据，经清洗、对齐、标注后形成标准化数据集。智能分析层是框架的核心，部署流量预测、资源调度、故障诊断三大AI模块，分别采用长短时记忆网络、深度强化学习和图卷积神经网络等算法。优化决策层将AI分析结果转化为

可执行策略,通过参数自动调整、资源动态分配、故障自动恢复等动作实现闭环优化。三层之间通过统一接口进行数据交互,形成“感知-分析-决策-执行”的完整闭环。以某运营商省内骨干网为例,部署该框架后,月均优化动作执行次数从人工模式下的86次提升至390次,响应时间从小时级缩短至分钟级<sup>[2]</sup>。

### 3 基于深度学习的网络流量预测

#### 3.1 预测模型设计与训练

网络流量预测是AI网络优化的基础能力,准确预测可为资源预调度、节能策略、容量规划提供依据。本文选取某市2024年9月至11月共计90天的现网数据进行实验,采集指标包括每15分钟粒度的小区级上下行PRB利用率、RRC连接数、用户面流量等5项核心指标,覆盖1683个小区,累计有效数据点超过145万条。数据按7:2:1比例划分为训练集、验证集和测试集。针对流量数据的时间依赖特性,采用两层LSTM网络结构:输入层接收过去12个时间步(3小时)的流量数据,隐含层神经元数分别设为64和32,输出层预测未来4个时间步(1小时)的流量值。训练使用Adam优化器,初始学习率0.001,损失函数为均方误差,批量大小32,训练轮次100。为防止过拟合,引入丢弃率为0.2的Dropout机制和早停策略。

#### 3.2 预测结果与分析

为验证LSTM模型的优越性,选择ARIMA模型和BP神经网络作为基线进行对比。表1展示了三种模型在测试集上的预测性能对比。

表1 不同模型网络流量预测性能对比

评价指标	ARIMA模型	BP神经网络	LSTM模型
平均绝对百分比误差	11.27%	8.46%	5.73%
均方根误差(Mbps)	18.34	13.62	8.95
决定系数	0.812	0.874	0.943
单次预测耗时(ms)	23	45	68

LSTM模型在平均绝对百分比误差、均方根误差和决定系数三项指标上均显著优于对比模型,平均绝对百分比误差较ARIMA降低5.54个百分点,较BP降低2.73个百分点,小区级流量预测准确率达94.3%。LSTM对长时依赖关系的建模能力是其主要优势,能够有效捕捉流量数据中的周期模式和趋势变化。从预测耗时看,LSTM为68ms,虽然慢于传统模型,但仍在业务可接受范围内。值得注意的是,模型在早高峰(7:30至9:00)和晚高峰(17:30至19:00)的预测误差约为7.2%,高于凌晨时段的3.8%,主要原因是高峰时段流量波动更剧烈、随机性更强。基于预测结果,运营商可提前15至30分钟调整小区参数,实测表明资源准备效率提升约22%。

### 4 基于深度强化学习的资源调度优化

#### 4.1 问题建模与算法设计

无线资源调度问题可建模为马尔可夫决策过程。状态空间定义为各小区的信道质量指示、缓存队列长度、历史资源分配记录等信息的组合,原始状态维度过高,需通过神经网络进行特征提取和降维。动作空间为各资源块的分配决策及对应的功率等级,在20MHz带宽配置下动作空间高达数百万,直接求解不可行。本文采用深度Q网络算法,利用神经网络逼近Q值函数,将高维状态映射为各动作的价值估计。奖励函数综合考虑系统吞吐量、用户公平性和服务质量满足度三个维度<sup>[3]</sup>。

模型训练采用离线学习与在线微调相结合的策略。使用一周的历史调度数据对DQN进行预训练,使模型具备基础的调度策略知识。在实际运行中,每15分钟进行一次在线微调,根据实时反馈更新网络参数,使策略逐步适应当前环境。DQN网络结构为三层全连接网络,输入层节点数256,两层隐含层分别含128和64个节点,输出层节点数与动作空间等价。经验回放池容量设为10000,目标网络更新频率为100步。仿真环境配置为3个宏基站、3个扇区共9个小区,每小区50个用户,用于验证优化效果。

#### 4.2 调度效果对比分析

在同等负载条件下,将DQN调度算法与轮询算法、比例公平算法进行对比。结果显示,DQN调度算法系统吞吐量达69.5Mbps,较比例公平算法(58.6Mbps)提升18.7%,较轮询算法(42.3Mbps)提升64.3%。吞吐量增益主要来源于深度学习模型对信道状态的精准预测能力,DQN能够预判哪些用户在未来时隙信道条件转好,提前预留资源。在用户公平性方面,DQN算法的Jain公平指数为0.87,略低于轮询算法(0.98)和比例公平算法(0.91),但轮询算法实际上是对信道质量的无差别处理,导致频谱效率低下。时延达标率方面,DQN算法达到92.3%,较比例公平算法的85.4%提高约7个百分点,主要依靠DQN对紧急业务的优先调度策略。实际部署中可设置公平性约束,在吞吐量和公平性之间灵活调节。资源调度模型还能预测高负载小区的溢出风险,提前触发负载均衡,实测切换成功率从98.2%提升至99.4%。

### 5 基于CNN的无线网络故障诊断

#### 5.1 故障数据特征与模型构建

网络故障诊断的难点在于故障告警之间存在复杂的时空关联和因果链条,一个硬件故障可能引发数十条衍生告警。本文采集某5G外场试验网3个月的历史告警数据,共计2.8万条记录,涉及46类故障码。对原始告警

数据进行以下预处理：以1分钟为滑动窗口、窗口大小设为5分钟，将连续告警序列离散化为事件集合；基于关联规则挖掘算法计算故障之间的时间序支持度，构建故障传播图；对告警类型、发生时间、设备位置、恢复方式等进行特征编码。采用图卷积神经网络进行故障诊断建模，其核心思想是将告警拓扑关系显式编码到图结构中，让模型学习故障传播的空间依赖。GCN模型定义了两层图卷积操作，第一层输入节点特征矩阵（维度 $46 \times 64$ ），输出到隐含层（输出维度128），第二层输出各类故障原因的概率分布。标签数据来自运维人员的故障处理记录，经专家复核确认根因。训练采用交叉熵损失函数，Adam优化器，初始学习率0.01。训练完成后，在独立的测试集上验证模型性能，并与决策树、随机森林等传统机器学习方法进行对比<sup>[4]</sup>。

### 5.2 诊断准确率与效果评估

GCN模型在根因识别方面优势显著，根因识别准确率为86.3%，较随机森林（78.5%）提升约8个百分点，较决策树（71.2%）提升约15个百分点。在Top-3识别准确率方面，GCN模型达到94.7%，表明模型能够将根因锁定在3个可能性之内，大幅缩小人工排查范围。诊断平均耗时方面，GCN模型仅需5.2秒，远快于随机森林的12.3秒和决策树的8.6秒，更远快于人工排查的30分钟以上。F1-score方面，GCN模型达到0.84，优于随机森林的0.76和决策树的0.68。从实际部署效果看，该模型自上线以来累计自动识别故障187次，正确诊断169次，成功率90.4%，误判18次，误判率9.6%。误判主要集中在硬件隐性故障和

第三方网元异常等训练样本不足的类别。对于前三位建议范围，人工确认后正确率可提升到97%以上，表明模型输出可作为运维人员的可靠决策参考，在提升效率的同时有效控制误判风险。

### 结束语

人工智能技术正在深刻改变通信网络的优化范式，从流量预测、资源调度到故障诊断，AI算法展现出超越传统方法的显著优势。本文通过真实网络数据验证，LSTM、深度强化学习、图卷积神经网络等模型分别在各自场景取得良好效果，初步证明了AI驱动网络优化的技术可行性。当前AI网络优化仍处于发展初期，面临数据质量参差不齐、模型泛化能力不足、实时响应与算力消耗平衡等诸多挑战。随着网络数字孪生、边缘智能等新兴技术的成熟，AI将在网络优化中扮演更加核心的角色，推动通信网络向“零接触运维”和“意图驱动网络”的终极目标不断迈进。

### 参考文献

- [1]刘梦旭,土伟政.利用大数据和人工智能优化电力通信网络运维管理的方法探讨[J].信息记录材料,2025,26(1):41-43.
- [2]刘元骏.人工智能在光传输网络优化应用研究[J].江苏通信,2024,40(6):95-97,115.
- [3]张宏纲,李少谦.智能通信网络：人工智能在通信网络中的应用综述[J].通信学报,2022,43(5):1-17.
- [4]王晓东,刘洋.基于深度学习的5G网络流量预测方法研究[J].电子与信息学报,2023,45(3):892-900.