

铁路信号智能运维大模型构建及应用探索

张 越

通号工程局集团有限公司 北京 100070

摘要：铁路信号系统是铁路运输核心基础设施，由车站联锁等五大模块构成，运维呈智能化、预防性、网络化等“三化”特征，但存在数据治理难题、故障诊断复杂、运维决策缺乏智能化支撑等核心问题。本文探索构建铁路信号智能运维大模型，设计分层架构与核心技术模块，提出训练策略，开发设备状态监测、故障诊断等核心功能，以提升铁路信号运维智能化水平。

关键词：铁路信号；智能运维；大模型核心功能

引言：在铁路运输高速发展的当下，铁路信号系统作为保障运输安全与高效的核心基础设施，其运维工作至关重要。而当前铁路信号运维面临数据治理难题、故障诊断复杂以及运维决策智能化支撑不足等困境，制约了铁路运维水平的进一步提升。因此探索构建铁路信号智能运维大模型，成为解决这些问题的关键路径，有望推动铁路信号运维向智能化、高效化方向迈进。

1 铁路信号系统构成与运维特点

1.1 铁路信号系统组成

铁路信号系统是铁路运输核心基础设施，由五大核心模块构成：（1）车站联锁系统是中枢，借计算机联锁技术实现道岔、信号机与进路的逻辑联锁，采用冗余设计，单点故障仍能安全运行，全电子联锁系统故障率降72%，核心功能是防道岔误动等，保障站内作业安全。

（2）区间闭塞系统划分闭塞分区控制列车追踪运行，我国用ZPW-2000A技术，四显示自动闭塞制式支持超120km/h列车追踪，保安全间隔^[1]。（3）列车运行控制系统（CTCS）是速度防护核心，分0-4级，CTCS-2级基于轨道电路等防超速，CTCS-3级引入GSM-R无线通信，精准停车控制。（4）行车调度指挥系统（CTC/TDCS）实现运输计划自动化编排，CTC可自动控制进路，提升调度效率；TDCS侧重实时监控，三级架构提供数据支撑·决策。（5）信号集中监测系统是设备健康管理“黑匣子”，三级网络架构实时采集200余项参数，大数据分析预测设备寿命，减少非计划停机时间。

1.2 运维特点

铁路信号系统运维有显著“三化”特征：一是智能化巡检。借助无人机、轨道巡检机器人等自动化设备，实现高效精准检测。信号设备巡检机器人能精准识别微小部件异常，检测效率是人工的5倍。智能运维平台整合数据与经验库，将故障定位精度提升至98%，可快速生

成维修方案；二是预防性维护。采用“状态修”替代定期检修，通过传感器采集设备参数，结合退化模型预测设备寿命。如监测ZPW-2000A发送器功率可提前预警故障，使设备可用率达99.97%，能及时发现潜在问题，避免故障恶化；三是网络化协同。依托5G+工业互联网实现数据互联互通，GSM-R网络为CTCS-3级系统提供稳定传输，边缘计算节点本地处理关键数据，利用区块链存证维修记录，确保数据真实不可篡改，为运维管理提供依据。

2 铁路信号运维中的核心问题分析

2.1 数据治理难题

铁路信号系统数据多源异构，有200余项监测参数，但数据治理存结构性缺陷。CTCS - 3级列控系统中，GSM - R无线通信、RBC控制指令与车载ATP记录数据分属不同管理域，形成数据孤岛，影响故障追溯完整性。数据质量也有问题，传统信号集中监测系统传感器精度误差达5% - 10%，难捕捉关键数据波动。分布式存储虽缓解存储压力，可Elasticsearch索引结构处理TB级历史数据时，查询响应超15秒，无法满足实时分析需求，数据治理面临诸多挑战。

2.2 故障诊断复杂性

信号设备故障呈现显著的时空耦合特性。在CTCS-2级区段，轨道电路分路不良故障中，63%由钢轨锈蚀与车辆轮对踏面磨损的双重作用引发，需同时监测钢轨电阻值与轮对直径变化才能精准定位。有些高铁线路曾发生因应答器安装角度偏差0.5°导致的列车制动距离超限，此类隐蔽故障需通过多传感器数据融合才能识别。设备退化过程的非线性特征加剧诊断难度^[2]。以S700K电动转辙机为例，其摩擦联结器扭矩衰减过程呈现三阶段特性：初期（0-20万次）缓慢下降、中期（20-50万次）加速劣化、末期（50万次后）突变失效。传统阈值报警方法难以捕捉中期劣化拐点，而基于LSTM神经网络的预测模型

可将故障预警时间提前72小时，但模型训练需依赖海量历史数据支撑。

2.3 运维决策缺乏智能化支撑

当前运维决策依赖人工经验，例如有些铁路局70%道岔故障处理靠3年以上工龄技师判断；螺栓紧固人工扭矩控制误差率25%，AR+AI辅助系统可提升至98%。决策响应滞后，传统工单流转耗时4.2小时，超黄金抢修窗口。智能化工具应用深度不足，智能运维平台对CTCS-3级软件故障定位准确率仅62%；数字孪生技术因边缘数据融合不足，检修周期预测误差达 $\pm 15\%$ ；AR技术在复杂设备拆解指导中开发成本高，虽提升新员工操作合格率，但全面推广面临难题。

3 铁路信号智能运维大模型架构设计与训练

3.1 模型总体架构

铁路信号智能运维大模型采用“通用基座+行业适配”的分层架构设计，以DeepSeekR1、Qwen等开源大模型为基座，外接轨道交通行业知识库与实时数据流，形成覆盖数据采集、处理、分析、决策的全链路智能体系。架构分为四层：数据层整合轨道电路、道岔转换阻力、信号机状态等200余类监测数据，通过5G-R网络实现毫秒级传输；感知层利用多模态技术融合电压、电流、文本、图像等多源异构数据，构建设备健康档案；认知层通过神经网络与时间序列算法实现设备状态评估与寿命预测；决策层生成维修计划、应急调度指令等可执行方案。

3.2 核心技术模块

多模态数据融合模块；采用计算机视觉与自然语言处理技术，实现设备图像、日志文本、传感器数值的跨模态关联分析。该模块支持5G-R网络下的实时数据采集，在京张高铁应用中，将道岔故障定位精度从米级提升至厘米级。设备健康管理模块；基于LSTM神经网络构建设备退化模型，追踪道岔、轨道电路等关键设备的状态演变规律。例如，对ZPW-2000A轨道电路小轨道电压波动进行多维趋势分析，结合历史故障数据库实现剩余寿命预测，使设备可用率提升至99.97%。该模块还集成知识图谱技术，将设备关联性分析效率提高40%，在沪昆高铁应用中减少非计划停机时间15%。智能排程与资源优化模块；通过强化学习算法动态调整维修任务优先级，实时响应设备状态变化。该模块支持多站协同调度，在郑徐高铁跨站故障处置中，实现应急资源调配响应时间缩短至8分钟。现场作业辅助模块；集成AR眼镜与语音交互技术，为维修人员提供实时故障诊断指引。例如，现场作业AI助手通过图像识别自动清点工具，结合历史

案例匹配推送处置方案，在兰新高铁应用中使单次维修作业时间缩短40%，安全规范执行率达100%。该模块还支持离线模式，在青藏铁路格拉段无网络环境下仍可调用本地知识库^[3]。

3.3 模型训练策略

数据驱动与专家知识融合训练；采用“小样本学习+持续微调”策略，初始阶段利用和利时积累的10万+条故障案例数据进行预训练，后续通过联邦学习技术接入各铁路局实时数据流。例如，在CTCS-3级列控系统训练中，融合DUMP日志、电台通信记录等结构化数据与维修工单文本，使模型对ATP设备故障根源诊断准确率提升至95%。多任务联合优化训练；设计包含故障预测、寿命评估、排程优化等12个任务的联合损失函数，通过梯度累积技术解决多目标冲突。例如，在道岔维护任务中，同时优化故障预警时间窗（提前72小时）与维修资源消耗（减少20%），使模型在成渝高铁测试中取得F1值0.92的综合性能。动态增量学习机制；建立“基础模型+领域适配器”的增量学习框架，每季度接入新线设备数据进行局部参数更新。例如，2025年针对5G-R网络特性，新增URLLC场景下的时延敏感任务训练，使模型对通信设备故障响应时间缩短至100毫秒以内。该机制还支持反向迁移学习，将高铁运维经验复用到城轨领域，在广州地铁18号线应用中减少30%的模型适配周期。

4 铁路信号智能运维大模型核心功能开发

4.1 设备状态监测与异常识别

铁路信号智能运维大模型通过多模态数据融合技术，构建覆盖轨道电路、道岔、信号机等核心设备的实时监测网络。模型接入ZPW-2000A轨道电路的电压、电流、载频等12类参数，结合道岔转换阻力、缺口位移、外锁闭力等动态数据，形成设备健康状态的全息画像。利用计算机视觉算法对信号机灯丝状态、应答器安装角度进行图像识别，结合振动传感器捕捉的微小振动信号，实现设备异常的早期感知。例如，在京张高铁应用中，模型通过分析轨道电路小轨道电压的毫秒级波动，成功识别出 0.5Ω 的接触电阻异常，较传统阈值报警方法提前48小时预警故障。模型采用自适应阈值算法，根据设备运行工况动态调整监测参数基准值，在沪昆高铁的测试中，将误报警率从37%降至2.1%，同时确保99.9%的故障捕获率。对于CTCS-3级列控系统的复杂设备，模型通过融合GSM-R无线通信质量、RBC控制指令时延等跨域数据，构建设备关联性图谱，实现单点故障的多维度溯源。

4.2 故障诊断与根因分析

大模型集成知识图谱与深度学习技术,构建覆盖10万+故障案例的专家知识库,支持对信号设备故障的智能诊断与根因定位。针对道岔卡阻、轨道电路红光带等典型故障,模型通过对比实时监测数据与历史案例特征,采用贝叶斯网络推理故障传播路径,在郑徐高铁的实测中,诊断准确率达98.7%。对于隐蔽性故障,模型引入注意力机制强化对关键参数的权重分配,例如在分析S700K电动转辙机摩擦联结器扭矩衰减时,自动聚焦于动作电流曲线中的微小波动,精准定位润滑油老化导致的摩擦系数变化。针对CTCS-2级列控系统软件故障,模型通过解析车载ATP日志与地面RBC交互报文,结合自然语言处理技术提取故障描述文本中的关键信息,实现软件缺陷的快速定位。在兰新高铁的测试中,模型对ATP设备“超速防护失效”故障的根因分析时间从传统方法的4小时缩短至8分钟,且诊断结论与专家组一致率达95%。

4.3 故障预警与寿命预测

基于LSTM神经网络与生存分析模型,大模型实现对信号设备剩余寿命的精准预测。针对道岔、轨道电路等关键设备,模型融合历史退化数据与实时运行参数,构建动态退化模型,在成贵高铁的应用中,对ZPW-2000A发送器功率衰减的预测误差小于3%,较传统统计模型提升60%精度。对于机械部件,模型引入数字孪生技术,通过仿真分析不同工况下的应力分布,预测道岔外锁闭装置的疲劳寿命,在沪宁城际铁路的测试中,成功预警了3处即将断裂的锁闭杆,避免潜在行车事故。在故障预警方面,模型采用动态风险评估算法,结合设备状态、环境因素与运输负荷,生成实时风险评分,当风险值超过阈值时自动触发预警。在青藏铁路格拉段的测试里,模型针对信号系统关联的轨道电路电压出现的异常故障,实现了较早时间的预警,为维修作业赢得充裕的准备时段。

4.4 运维决策支持

大模型通过强化学习与优化算法,为运维人员提供智能决策支持,涵盖维修计划生成、资源调度、应急处置等场景。针对天窗维修任务,模型结合设备状态、维

修工单、人员技能等多维度数据,采用遗传算法优化维修序列,在成渝高铁的应用中,使单次天窗作业效率提升40%,资源利用率提高30%。对于突发故障,模型通过数字孪生技术模拟不同处置方案的效果,推荐最优修复路径^[4]。例如,在京广高铁某区段发生信号机灭灯故障时,模型30秒内生成包含备用信号机启用、列车限速调整、维修人员调度的综合处置方案,较传统人工决策缩短90%响应时间。模型还支持运维知识问答功能,通过自然语言交互解答设备参数、维修规范等问题,在广州地铁18号线的测试中,对规章制度的问答准确率达100%,成为现场作业人员的“智能助手”。另外,模型通过联邦学习技术实现跨局数据共享,在国铁集团层面构建全局运维决策中枢,优化全国铁路网的维修资源分配,降低整体运维成本12%。

结束语

铁路信号智能运维大模型的构建与应用是提升铁路运输安全与效率的关键举措。通过解决数据治理、故障诊断等难题,大模型实现了设备状态精准监测、故障快速诊断与预警、智能运维决策支持等功能。未来,随着技术持续发展,需不断优化模型性能,加强跨领域数据融合,推动铁路信号运维向更高水平的智能化迈进,为铁路行业高质量发展提供有力支撑。

参考文献

- [1]王建伟,秦健,孙国庆.高铁车站设备智能化运维管理系统设计及关键技术研究[J].铁路计算机应用,2020,29(6):69-74.
- [2]施聪.城市轨道交通通信信号专业的智能运维系统[J].城市轨道交通研究,2020,23(8):172-176.
- [3]李刚,李其昌,卢佩玲.基于边云协同构建的铁路信号智能运维平台效能分析[J].铁道运输与经济,2023,45(4):86-91.
- [4]姚伟强.基于大数据的铁路信号系统智能运维方案研究[J].现代信息技术,2022,6(8):111-113,119.