文章编号：2097-5899(2025)08-0040-07　　中图分类号：U285.6;TP315　　文献标识码：A
DOI：10.16669/j.cnki.issn.2097-5899.202412040001
引用格式：李维平，苏天祺，王林涛，等. 基于大数据的铁路通信基础设备健康度分析预测[J]. 铁路物流，2025，43(8)：40-46.
LI Weiping，SU Tianqi，WANG Lintao，et al. Big Data-Based Health Analysis and Prediction of Railway Communication Infrastructure[J]. Railway Logistics，2025，43(8)：40-46.

基于大数据的铁路通信基础设备健康度分析预测

李维平[1]，苏天祺[2]，王林涛[2]，刘　杰[3]，鲁　帅[4]

(1. 陕西铁路物流集团有限公司，陕西 西安　710077；2. 陕西靖神铁路有限责任公司 运输管理部，陕西 榆林　719000；3. 陕西靖神铁路有限责任公司 孟家湾综合维修车间，陕西 榆林　719000；4. 北京全路通信信号研究设计院集团有限公司 运输指挥与信息技术研究院，北京　100070)

摘　要：通过对通信基础设备的性能指标趋势进行预测，提前发现潜在风险，构建健康度分析预测体系，协助运维人员提前识别重点关注设备，优化日常巡检和检修。研究涵盖传输网管、数据网管、LTE网管、光缆网管和视频网管等5个网管系统的基础设备，从设备状态、告警和风险等级预测3个维度进行健康度评估。通过数据采集、预处理、告警统计、性能指标预测和风险评定等环节，构建完整的铁路通信基础设备健康度评估体系。该体系可定期评估设备健康度，合理安排维护计划，降低维护成本和能源消耗，提前采取预测性维护措施，减少非计划维修时间，提高设备稳定性和可靠性。

关键词：铁路通信；趋势预测；预测算法自适应；对比学习；精确度评估；风险预测评估；健康度评估

0　引言

铁路通信系统在运输高峰期、汛期、恶劣天气等特殊时期需要加强设备的使用和维修管理，在遭受地震、洪水等突发情况可能影响铁路设备质量安全时需要加强检查、监测，并能够高效解决问题。而现有的铁路通信基础设备监测系统存在数据孤岛问题，监测不全面，综合网管系统在早期建设过程中，存在安全控制点验证对象的归属不清问题，以及系统本身的风险，都需要人员有丰富的处理经验，快速解决出现的故障问题。日常巡检、检修都是为了提前发现设备存在的潜在风险问题，这对人员维护提出了更大的挑战和更高的要求。

为了应对这些挑战，本研究主要通过对通信基础设备的性能指标进行趋势预测，提前发现可能存在的风险问题，进而搭建铁路通信基础设备健康度分析预测体系，帮助运维人员提前锁定重点关注设备，协助日常巡检、重点监测，并在数据支持下进行维修，提高设备的安全可靠性。

1　健康度分析预测

健康度分析预测[1-3]基于通信系统的设备状态、设备告警、设备风险等级预测3个维度来进行评定。

通信系统范围包含传输网管、数据网管、LTE网管、光缆网管、视频网管5个网管系统，本研究主要是基于5个网管中的基础设备进行健康度分析。例如，传输网管的基础设备包含传输设备(如SDH传输)，数据网管的基础设备包含网络交换设备（如数据网交换机）等。

1.1　设备状态统计

设备状态统计分为设备使用天数统计和设备缺陷、故障频次统计2部分。

收稿日期：2024-12-04
通信作者：鲁帅(1994—)，男，北京人，北京全路通信信号研究设计院集团有限公司运输指挥与信息技术研究院工程师。

1.1.1　设备使用天数统计

通过采集通信设备的基本信息，主要包括设备名称、设备开始使用时间、设备报废时间等。通过设备的开始使用时间和当前时间计算其使用天数。

1.1.2　设备故障频次统计

根据通信设备发生的缺陷故障次数来统计不同时间点的频次。

（1）数据采集。故障数据的采集是故障统计的基础，铁路通信系统通过多种方式实现数据的全面采集。①缺陷处理记录采集。在设备发生缺陷并进行处理时，详细记录缺陷现象、处理过程、修复时间等信息，这些数据通过维护人员的手动输入或系统自动记录的方式进行采集。②故障处理记录采集。在设备发生故障并进行处理时，详细记录故障现象、处理过程、修复时间等信息，这些数据通过维护人员的手动输入或系统自动记录的方式进行采集。

（2）数据整理与预处理。采集到的故障数据需要进行预处理。①数据清洗。去除重复数据、无效数据和错误数据，确保数据的准确性和完整性。②数据标准化。对不同来源的数据进行格式统一和标准化处理，以便进行统计。

（3）数据统计。根据设备名称和缺陷、故障类型进行分类统计，计算设备缺陷、故障的不同时间点的频次。

1.2　设备告警统计

根据通信系统设备产生的告警按照告警严重性及产生频次进行统计。

（1）数据采集。对接各子系统进行告警数据的采集。

（2）数据整理和预处理。对采集的告警数据进行设备名称、告警类型、告警时间等信息提取。

（3）设备告警统计。根据设备名称按照告警严重性及产生频次进行分组计算。

1.3　设备风险等级预测

设备风险等级预测[4-5]基于设备性能指标预测完成，具体包含性能指标预测、风险等级评定2部分。

性能指标预测[6-7]具体流程是构建时间序列预测算法模型树，接入指标数据，在预设算法模型中进行训练，选择训练效果最好的模型完成推理，得到预测结果。使用精确度评估分析辅助完成模型的对比，并参与反馈对整体预测流程及算法参数实现调优。性能指标预测流程如图1所示。

1.3.1　数据接入

构建监听服务，按照采集规范实时采集铁路设备的性能指标数据，包含错误率、丢包率等指标数据。对数据进行格式解析，提取关键信息，保存历史性能数据，为后续处理做好基础。

1.3.2　数据处理

数据处理[8]是获取监控采集的时间序列数据，根据场景需要对数据做以下处理。

（1）数据清洗。对于时间序列数据需要进行时间对齐，时间进行规范化。进而识别并处理缺失值、异常值。缺失值通过插值、删除或填充方式来处理；异常值进行重新计算填充。

（2）数据转换。采集的数据会出现量级不同的情况，须对数据进行标准化归一化处理，使其处于同一量级，消除量纲影响，提高数据稳定性。

（3）平稳性检查。检验数据的平稳性，如果数据

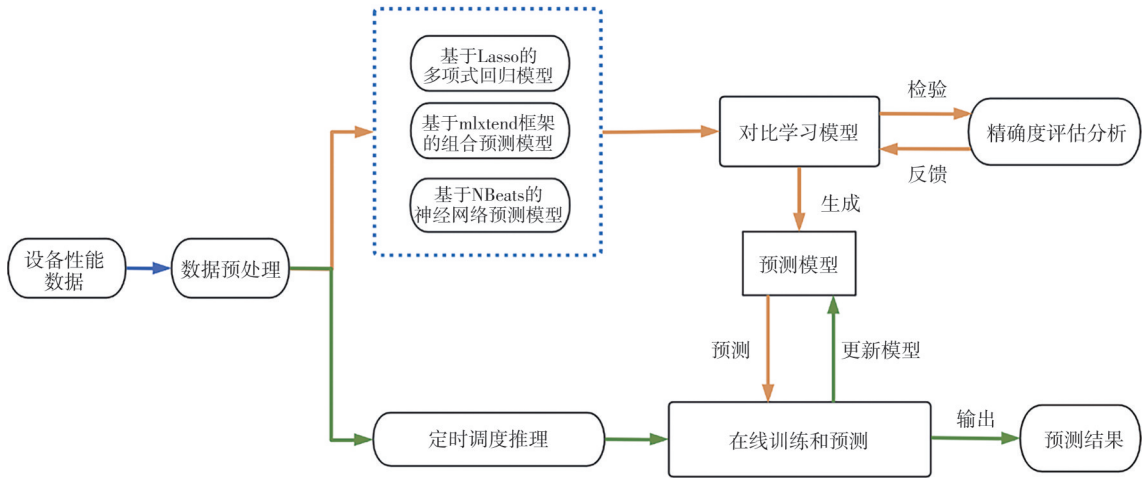


图1　性能指标预测流程

Fig.1　Performance index forecasting procedure

不是平稳的，可能需要进行取对数、差分处理。

（4）特征提取。根据场景需要的预测步长及数据周期性判断结果，对时间序列进行裁剪，选择合适的历史监控数据长度，在保证不丢失数据周期性特征的前提下简化训练数据，提升算法性能。

1.3.3　预测算法自适应框架

将预处理后的时序数据接入模型树进行训练并保存训练模型，模型树由各类预测算法组成，每个算法之间互相独立，并使用贝叶斯优化方法进行超参数优化，以较少的迭代次数得到更好的算法参数。

对模型树训练的结果接入基于分段R^2和异常检测的综合预测模型精确度评估方法，计算各模型在训练中的预测精确度并给出得分，选择得分表现最高的预测算法模型，接入时序数据完成预测推理，给出时序数据的最终预测结果。

定时对模型进行训练，更新保存的训练模型，将精确度评估得分结果作为反馈，调整时序数据在预测推理时选用的算法模型。

1.3.4　模型推理

实时接入性能指标数据，进行数据处理，保证与模型训练的数据结构相同，加载已训练好的模型，将预处理后的数据输入到模型中，模型通过计算输出预测结果数据。

模型实时推理结果进行数据保存，并支持可视化展示。

1.3.5　风险预测评估

为了确保设备运行在最佳状态，为关键性能指标设定一系列的界限值。这些界限值反映了设备在正常工作条件下的参数范围，任何超出这些范围的读数都可能暗示着设备可能存在问题。根据预测结果数据通过与设定的界限值进行比较，判定未来可能发生问题的时间点，根据风险时间点与当前的时间差设定不同的等级。

根据时间差设定不同的风险等级，以便对不同程度的风险做出应对方案[9]。等级类型分为：高风险、中风险、低风险、无风险。

1.4　健康度评估

健康度评估[10-11]通过基础设备状态统计、设备告警统计进行基础分析，并结合根据趋势预测得到的未来风险等级来判定设备的健康状态。

健康度评价目标层为设备健康状态，准则层因素集包含告警、设备状态、风险等级，指标层因素集包含告警频率、严重告警、紧急告警、一般告警、缺陷频次、故障频次、使用天数、高风险、中风险、低风险、无风险。其中，告警频率根据设备一定时间范围内产生的告警数量来计算；告警严重性分为严重告警、紧急告警、一般告警、提示等不同等级的告警，严重告警、紧急告警、一般告警为重点关注告警，对此3类告警分别按照同时间间隔统计相应级别告警的数量；缺陷频次和故障频次根据一定时间范围内缺陷、故障产生的频率统计得出，其中缺陷、故障是通过日常巡检日常检修、故障诊断产生；使用天数根据设备的启用日期至今的使用时间长度计算；高风险、中风险、低风险、无风险是设备风险等级预测中输出的设备风险等级。设备健康度评价指标体系如表1所示。

表1　设备健康度评价指标体系

Tab.1　Equipment health evaluation indicator system

目标层	准则层	指标层
设备健康状态	告警	告警频率
		严重告警
		紧急告警
		一般告警
	设备状态	缺陷频次
		故障频次
		使用天数
	风险等级	高风险
		中风险
		低风险
		无风险

设备健康度评定流程如图2所示，其中包含评估维度进行健康度评定及对应权重。定时对设备的告警、设备状态、未来风险等级进行统计，根据对应的权重计算3个维度的健康得分。

其中，告警从告警频率和告警严重性2方面进行统计；设备状态从缺陷次数、故障次数、使用年限3方面进行统计；未来风险等级只根据评定等级来进行匹配。

建立健康度评估体系，根据各层次权重系数计算各维度评分，最终求得设备的健康得分，从而进行健康等级评定，通信系统设备健康等级划分如表2所示。

通过建立的健康度评估体系，实现定期评估设备健康度，合理安排维护计划，减少维护成本和能源消耗；能够在设备异常故障之前采取预测性维护措施，减少非计划维修时间，提高设备的稳定性和可靠性。

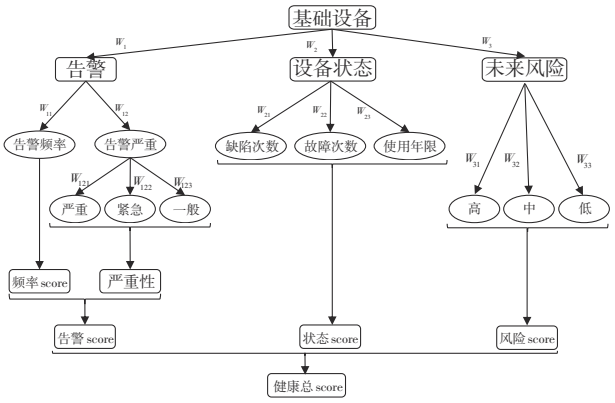


图2　健康度评定流程

Fig.2　Health assessment process

表2　通信系统设备健康等级划分

Tab.2　Classification of health levels for communication system equipment

健康等级	健康值score区间
健康	90＜score≤100
亚健康	80＜score≤90
轻度病态	60＜score≤80
中度病态	40＜score≤60
严重病态	0≤score≤40

2　性能指标预测算法自适应框架

2.1　预测算法

预测算法包含3种，分别是基于Lasso的多项式回归模型、基于MLxtend框架的组合预测模型、基于NBeats的神经网络预测模型。

（1）基于Lasso的多项式回归模型。在岭回归的代价函数上加上了一个带惩罚系数λ的w向量的L2范数的平方，基于Lasso的多项式回归代价函数如公式(1)所示。

$$Cost(w)=\sum_{i=1}^{N}(y_i-w^{\mathrm{T}}x_i)^2+\lambda\|w\|_2^2 \tag{1}$$

式中：w为权重向量；y_i为真实值；x_i为拟合值；λ为惩罚系数；$\|w\|_2^2$为权重向量的L2范数的平方。

Lasso回归算法与岭回归一样加上了正则项，不同之处在于改为加上了一个带惩罚系数λ的w向量的L1范数作为惩罚项(L1范数的含义为向量w每个元素绝对值的和)，所以这种正则化方式也被称为L1正则化，Lasso回归的代价函数如公式(2)所示。

$$Cost(w)=\sum_{i=1}^{N}(y_i-w^{\mathrm{T}}x_i)^2+\lambda\|w\|_1 \tag{2}$$

式中：$\|w\|_1$为权重向量的L1范数。

同样是求解使得代价函数最小时w的大小，如公式(3)所示。

$$w=\underset{w}{\operatorname{argmin}}\left(\sum_{i=1}^{N}(y_i-w^{\mathrm{T}}x_i)^2+\lambda\|w\|_1\right) \tag{3}$$

由于加入的是向量的L1范数，其中存在绝对值，导致其代价函数不是处处可导的，所以无法通过直接求导的方式来直接得到w的解析解。研究主要采用最小角回归法求解权重系数w。

最小角回归法是一种特征选择的方法，计算出每个特征的相关性，通过数学公式逐渐计算出最优解，具体步骤如下。

步骤1：初始化权重系数w，例如初始化为零向量。

步骤2：初始化残差向量residual为目标标签向量$y-Xw$，由于此时w为零向量，所以残差向量等于目标标签向量y。

步骤3：选择一个与残差向量相关性最大的特征向量x_i，沿着特征向量x_i的方向更新权重系数w，直到出现另一个与残差向量相关性最大的特征向量x_j使得新的残差向量residual与这2个特征向量的相关性相等(即残差向量落在这2个特征向量的角平分向量上)，重新计算残差向量。

步骤4：重复步骤3，继续更新权重系数w，直到出现第3个与残差向量相关性最大的特征向量x_k使得新的残差向量residual与这3个特征向量的相关性相等(即残差向量落在这3个特征向量的等角向量上)，以此类推。

步骤5：当残差向量residual足够小或者所有特征向量都已被选择，结束迭代。

（2）基于MLxtend框架的组合预测模型。堆栈是一种集成学习技术，通过结合几个更简单模型的优势，构建一个比任何一个模型更具预测性的新广义学习模型。

MLxtend实现了丰富多样的功能，重点涵盖顺序特征选择算法、用于分类和回归的堆叠泛化实现。MLxtend中的集成方法包括多数投票、堆叠和堆叠泛化。除了特征选择、分类和回归算法之外，MLxtend还实现了模型评估技术，通过McNemar's检验对比两个不同模型的性能，通过Cochran's Q检验比较多个模型的性能。交叉验证配对t检验的实现支持用户相互比较机器学习算法的性能。

在组合预测中使用到的预测方法包括KNN、线性

回归、支持向量机、简单神经网络回归，最后通过随机森林进行模型选择。

（3）基于NBeats的神经网络预测模型。NBeats开创了一个全新的时间序列预测backbone，仅通过全连接实现时间序列预测，其核心思路是通过多层全连接进行时间序列分解，每层拟合时间序列部分信息(之前层拟合的残差)。

NBeats模型结构如图3所示。整个模型包括多个stack，每个stack包括多个block，每个block是NBeats的最基础结构模块，由多个全连接层组成。每个block包含2个主要部分，第一个部分将输入的时间序列映射成expansion coefficients，第二部分将expansion coefficients映射回时间序列。

2.2　对比学习

对比学习是一种无监督的表示学习方法，其通过数据增强和负采样获得正负样本，并使用目标函数增大正样本对之间的相似度，减小负样本对之间的相似度，以获得具有判别性的表征。对比学习常用的损失函数InfoNCE如公式(4)所示。

$$\mathcal{L}=-\sum_{i=1}^{N}\log\frac{\exp\left(\frac{-\left|z_i-z_i'\right|^2}{2}\right)}{\exp\left(\frac{-\left|z_i-z_i'\right|^2}{2}\right)+\sum_{j\neq i}\exp\left(\frac{-\left|z_i-z_j\right|^2}{2}\right)} \tag{4}$$

式中：N为样本大小；z_i为样本特征向量；z_i'为正样本对的特征向量；z_j为负样本对的特征向量。

2.3　精确度评估

根据真实数据体现出的趋势，将其分为平稳型、非平稳型，使用分段R^2对预测数据和真实数据进行线性回归分析。

（1）平稳型。对于一些采集到的真实数据为定值或波动极小的情况，R^2不能很好地对这部分数据进行拟合效果的分析评估，补充一种分析方案用于评估这类真实数据方差小于真实数据均值千分之一的平稳型数据预测效果，如公式(5)所示。

$$R^2\approx 1-\frac{\sum_{n}\left(\frac{\left|pred_i-real_i\right|}{real_i}\right)}{n} \tag{5}$$

式中：$pred_i$为预测值；$real_i$为真实值；n为预测长度。

非平稳型。对于其他不是平稳型的数据，使用传统的R^2进行拟合效果分析，如公式(6)所示。

$$R^2=\frac{SSR}{SST}=1-\frac{SSE}{SST} \tag{6}$$

式中：SSR为回归平方和，$SST=SSR+SSE$；SST为总平方和，表示真实值与真实值均值之间差的平方和；SSE为残差平方和，表示真实值与预测值之间差的平方和。

$$SST=\sum_{i=1}^{n}(y_i-\bar{y})^2 \tag{7}$$

式中：$\bar{y}$为真实值的均值。

$$SSE=\sum_{i=1}^{n}(\hat{y}_i-y_i)^2 \tag{8}$$

式中：$\hat{y}_i$为预测值。

计算得到的R^2位于区间$(-\infty,1]$，为方便后续计

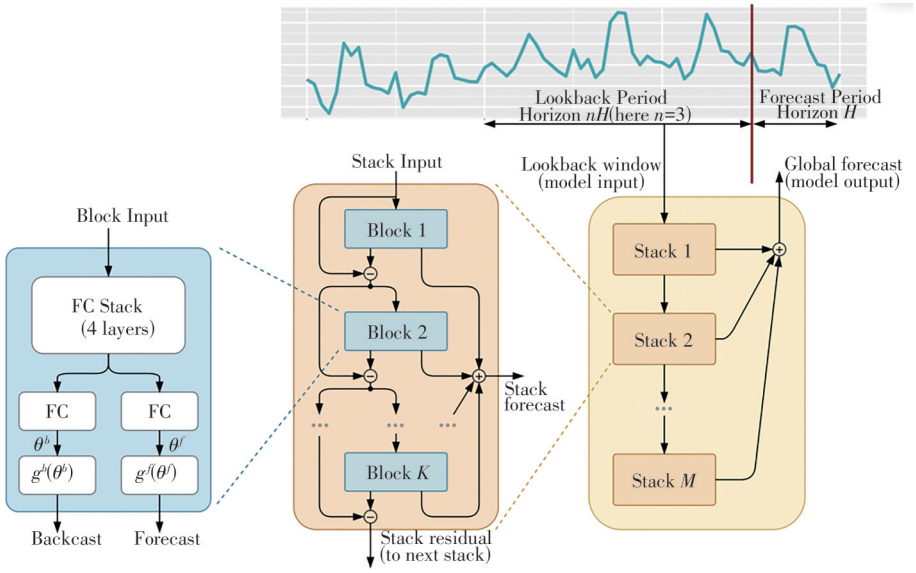


图3　NBeats模型结构

Fig.3　NBeats model structure

算，将得分进行归一化，根据一般经验，将位于[−5,1]区间的分数归一化至区间[0,100]上，而位于(−∞,−5)区间的分数均以0分计算，最终得到数据在R^2拟合度上的百分制得分。

使用$value_{真实}\pm\sigma_{真实}$作为可接受的误差范围，统计预测数据落在误差范围外的数量占比，其中σ公式如公式(9)所示。

$$\sigma=\sqrt{\frac{1}{n}\sum_{i=1}^{n}(x_i-\mu)^2} \tag{9}$$

式中：σ为真实值的标准差；x_i为第i个真实值；μ为真实值的算术平均值。

分别计算预测数据在$value_{真实}\pm1\sigma_{真实}$、$value_{真实}\pm2\sigma_{真实}$、$value_{真实}\pm3\sigma_{真实}$3个区间内的占比，并根据20%，30%，50%的权重对3个值进行加权计算，得到数据在σ异常检测上的百分制得分。

综合上述2项得分计算均值，得到预测数据的精确度评估分数。

2.4　模型训练

模型训练基于大量的训练数据来识别数据中的模式、趋势和关系，并匹配确定模型参数的最佳值，从而来保证模型的泛化能力和准确性。

对于算法参数的选择，是针对每一个独立的预测算法均采用贝叶斯优化方法进行超参数优化。

贝叶斯优化用于机器学习调参，主要思想是给定优化的目标函数(广义的函数，只需指定输入和输出即可，无须知道内部结构以及数学性质)，通过不断地添加样本点来更新目标函数的后验分布(高斯过程，直到后验分布基本贴合于真实分布)。简单地说，就是考虑了上一次参数的信息，从而更好地调整当前的参数。

贝叶斯优化与常规的网格搜索或者随机搜索的区别如下。①贝叶斯调参采用高斯过程，考虑之前的参数信息，不断地更新先验；网格搜索未考虑之前的参数信息。②贝叶斯调参迭代次数少，速度快；网格搜索速度慢,参数多时易导致维度爆炸。③贝叶斯调参针对非凸问题依然稳健；网格搜索针对非凸问题易得到局部最优。④贝叶斯优化提供了一个优雅的框架在尽可能少的步骤中找到全局最小值。

3　整体架构

基于大数据的铁路通信基础设备健康度分析预测设计分为5层，分别为数据接入层、数据处理层、能力层、应用层、展示层。系统架构图如图4所示。

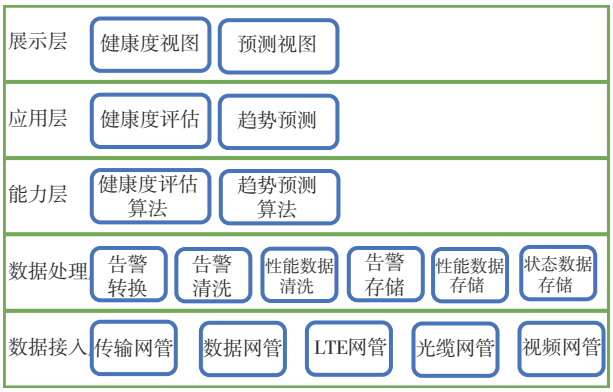


图4　系统架构图

Fig.4　System architecture diagram

（1）数据接入层。通过北向接口从各个通信专业系统完成数据的采集，将原始数据进行存储，并将数据放入消息队列中。

（2）数据处理层。对原始数据进行清洗、转换等预处理操作，将转换后的数据进行统一存储，用于能力层。

（3）能力层。根据健康度评估和趋势预测需求实现对初始数据的分析、预测的算法能力，根据数据层数据进行状态统计、告警统计，用于支持应用层。

（4）应用层。健康度评估实现对设备健康状态进行评分，趋势预测是根据设备的性能数据进行趋势预测，为未来潜在风险的发现提供依据。

（5）展示层。展示层展现分析得到的结果数据，以便结果数据清晰地呈现，方便运维人员明确重点关注设备及快速了解设备健康状态，以及可能存在的风险设备。

4　结束语

研究提出的铁路通信系统设备健康度分析预测体系，基于大数据和先进的预测算法，能够有效提升设备的维护效率和可靠性。通过对设备状态的全面监测和数据分析，该体系能够提前发现潜在故障风险，为运维人员提供科学的决策支持。健康度评估体系的建立，不仅有助于优化维护资源配置，降低维护成本，还能提高设备的稳定性和运行效率，保障铁路运输的安全可靠。未来随着技术的不断进步和数据采集的进一步完善，该健康度分析预测体系有望在铁路通信系统中得到更广泛的应用和推广。通过持续优化算法和模型，结合更多维度的数据分析，可以进一步提升设备健康度评估的准确性和可靠性。此外，该体系还可以与其他智能运维技术相结合，实现铁路通信系统的智能化管理和维护，为铁路行业的可持续发展提供有力支持。

参考文献：

[1] 常　飞. 基于信号特征提取的设备健康状态预测与评估[D]. 徐州：中国矿业大学，2015.

[2] 赵丽琴，刘　昶，曹明生，等. 复杂装备健康度评估方法研究综述[J]. 计算机测量与控制, 2021，29(11)：1-7.

[3] 程　逸. 基于监测数据的风电机组运行健康度分析研究[D]. 北京：华北电力大学,2021.

[4] 吕克洪，程先哲，李华康，等. 电子设备故障预测与健康管理技术发展新动态[J]. 航空学报，2019，40(11)：13-24.
LYU Kehong，CHENG Xianzhe，LI Huakang，et al. New Developments of Prognostic and Health Management Technology for Electronic Equipment[J]. Acta Aeronautica et Astronautica Sinica，2019，40(11)：13-24.

[5] 窦钰哲，甘　俊. 通信基站关键指标数据异常检测与趋势预测的研究[J]. 计算机科学与应用，2024，14(3)：20-30.

[6] 乔文文，陈晓庆，黄　伟. 省级气象通信系统监控指标的异常与趋势分析[J]. 广东气象，2024，46(5)：65-68.

[7] 张勉知，叶晓斌，程亚锋，等. 机器学习在网络性能预测中的应用[J]. 邮电设计技术，2021(8)：25-28.
ZHANG Mianzhi，YE Xiaobin，CHENG Yafeng，et al. Application of Machine Learning in Network Performance Prediction[J]. Designing Techniques of Posts and Telecommunications，2021(8)：25-28.

[8] RASCHKA S. MLxtend: Providing Machine Learning and Data Science Utilities and Extensions to Python's Scientific Computing Stack[J]. Journal of Open Source Software，2018，3：638.

[9] 张铁钢. 铁路货运安全风险管理体系优化探讨[J]. 铁道货运，2021，39(3)：1-6.
ZHANG Tiegang. Discussion on Optimization of Risk Management System for Railway Freight Safety[J]. Railway Freight Transport，2021，39 (3)：1-6.

[10] 赵丽琴，刘　昶，易发胜. 基于动态权重的设备健康状态评估方法[J]. 计算机系统应用，2020，29(9)：198-204.
ZHAO Liqin，LIU Chang，YI Fasheng. Assessment Method of Equipment Health State Based on Dynamic Weight[J]. Computer Systems & Applications，2020，29(9)：198-204.

[11] 曾　进，戚芳榕，郭少媛，等. 基于改进灰色关联度的铁路大宗货运运价风险评估研究[J]. 铁道货运，2020，38(6)：46-51.
ZENG Jin，QI Fangrong，GUO Shaoyuan，et al. A Study on the Railway Freight Rates Risk Assessment System based on Improved Grey Relational Analysis[J]. Railway Freight Transport，2020，38(6)：46-51.

（责任编辑：吴文娟）

Big Data-Based Health Analysis and Prediction of Railway Communication Infrastructure

LI Weiping[1]，SU Tianqi[2]，WANG Lintao[2]，LIU Jie[3]，LU Shuai[4]

(1. Shaanxi Railway and Logistics Industry Group Co，Ltd.，Xi'an 710077，Shaanxi，China；2. Transportation Management Department，Shaanxi Jingshen Railway Co.，Ltd.，Yulin 719000，Shaanxi，China；3. Mengjiawan Comprehensive Maintenance Workshop，Shaanxi Jingshen Railway Co.，Ltd.，Yulin 719000，Shaanxi，China；4. Transport Command and Information Technology Research Institute，CRSC Research & Design Institute Group Co.，Ltd.，Beijing 100070，China)

Abstract: This study predicted trends in the performance index of railway communication infrastructure to identify latent risks and constructed a health analysis and prediction system to support operation and maintenance staff in highlighting critical equipment and optimizing routine inspection and maintenance. The study covered the infrastructure of five network management systems, including transmission network management, data network management, LTE network management, optical cable network management, and video network management. It conducted a health evaluation from three dimensions: equipment status, alarms, and risk level prediction. Data acquisition, preprocessing, alarm summarization, performance index prediction, and risk grading were executed to establish a complete health evaluation system for railway communication infrastructure. The system periodically evaluated equipment health, scheduled maintenance rationally, reduced maintenance cost and energy consumption, enabled predictive measures, shortened unplanned downtime, and improved equipment stability and reliability.

Keywords: Railway Communication; Trend Prediction; Adaptive Prediction Algorithm; Contrastive Learning; Precision Evaluation; Risk Prediction Evaluation; Health Evaluation