

一种智慧地铁轨道状态预测和维修决策优化系统

李茂圣¹, 王大彬²

(1. 云南南天电子信息产业股份有限公司, 昆明 650000; 2. 昆明地铁运营有限公司, 昆明 650000)

摘要: 为提高地铁轨道智能化管理水平, 设计了一种新的智慧地铁轨道管理系统; 分别设计了朴素贝叶斯分类器、Logistic 回归分类器和支持向量机分类器, 并构建了基于 Stacking 集成算法的轨道状态预测模型; 利用 XX 地铁 1 号线、2 号线和 6 号线在 2015—2021 年的设备数据、检测数据和维修数据, 验证了模型有效性; 引入自适应学习的马尔可夫决策过程 (AL-MDP), 构建了基于 Stacking-SVM 的轨道维修决策优化模型; 利用模型对地铁轨道进行运行状态感知和异常状态预测, 通过自适应学习的过程不断学习地铁轨道的劣化机理, 并且为轨道的状态预警和维修策略提供个性化、精细化的决策建议; 最后, 设计并实现了智慧地铁轨道管理系统; 引入 AL-MDP 后进一步降低地铁轨道的维修成本, 能够实时掌握地铁轨道的运作状态; 该研究给管理者和工作提供精细化、个性化、更科学的维修优化决策, 对维修成本和轨道安全实现双重精准控制。

关键词: 智慧地铁轨道管理系统; Stacking 集成算法; 轨道状态预测; 自适应学习的马尔可夫决策过程; 维修决策优化

Intelligent Subway Track State Prediction and Maintenance Decision-Making Optimization System

LI Maosheng¹, WANG Dabin²

(1. Yunnan Nantian Electronic Information Industry Co., Ltd., Kunming 650000, China;

2. Kunming Metro Operation Co., Ltd., Kunming 650000, China)

Abstract: In order to improve the intelligent management level of subway track, a new intelligent subway track management system is designed. Naive Bayes Classifier, Logistic Regression Classifier and Support Vector Machine Classifier are designed respectively, and a track state prediction model based on Stacking ensemble algorithm is constructed. The equipment data, inspection data and maintenance data of XX Metro Line 1, 2 and 6 from 2015 to 2021 are used to verify the validity of the model. Furthermore, an adaptive learning Markov decision process (AL-MDP) is introduced, and an optimization model of track maintenance decision based on Stacking-SVM is constructed. The model is used to sense the running state of the subway track and predict the abnormal state, and continuously learns the deterioration mechanism of the subway track through the process of adaptive learning, and provides the personalized and refined decision-making suggestion for the state warning and maintenance strategy of the track. Finally, the intelligent subway track management system is designed and implemented. After the introduction of the AL-MDP, the maintenance cost of the subway track is further reduced, and the operation status of the subway track can be grasped in real time. This research provides managers and workers with the refined, personalized and more scientific maintenance optimization decision, and achieves the dual precise control of maintenance cost and track safety.

Keywords: intelligent subway track management system; stacking ensemble algorithm; track state prediction; adaptive learning-Markov decision process; maintenance decision-making optimization

0 引言

随着人民生活水平提高和科技不断发展, 方便、环保的城市地铁逐渐向网络化运营阶段发展。地铁轨道是列车安全运行的基础, 需要在日常工作中保证连续平滑的轨道几何形状, 否则会导致列车振荡, 不仅降低了乘客的舒适度, 严重时甚至出现列车侧翻等危险^[1-2]。所以, 实时了解地铁轨道状态, 掌握轨道状态变化规律, 这对于提高乘客的舒适度、保障地铁列车的安全运行具有重要意义。

考虑到地铁的轨道状态具有不确定性和异质性, 常规的检测技术和量化标准很难对其进行精准描述, 这就引出了许多急需解决的难题: 如何实时精准掌握地铁轨道的运行状态, 并且形成科学合理的维修决策方案, 进一步实现轨道状态的安全预警等^[3]。目前, 类似于机器学习、深度学习等人工智能技术飞速发展, 强化学习、集成学习和神经网络预测等技术也得到了越来越多的关注, 这就为地铁轨道状态智能感知、全方面深入分析和轨道状态发展规律提供了科学合理的方法和途径^[4-6]。

收稿日期: 2022-07-04; 修回日期: 2022-07-28。

作者简介: 李茂圣(1988-), 男, 云南曲靖人, 硕士, 工程师, 主要从事智慧城市轨道交通方向的研究。

引用格式: 李茂圣, 王大彬. 一种智慧地铁轨道状态预测和维修决策优化系统[J]. 计算机测量与控制, 2023, 31(2): 48-54.

目前国内外研究团队在构建维修决策优化模型时通常只针对轨道占用时间和质量监测, 然而对于轨道异常状态的维修决策主要以维修成本为主, 所以在考虑轨道异常状态时需将维修成本作为目标函数。越来越多的人工智能技术和大数据分析技术被应用到轨道的基础设施建设和日常运行维护中。然而, 国内外研究团队在制定或优化地铁轨道的异常状态时存在较大的方法局限性, 通常只是局限于固定的模型参数, 比如, 常规 MDP 方法的规划周期内采用固定不变的状态转移概率。该方法无法实现自适应学习, 在轨道运维状态的智能感知和常规预测中很难捕捉轨道劣化机理, 最终很难实现科学、规范和完善的维修决策和规划。所以, 通过深度挖掘、分析轨道运行和维护的海量数据, 利用机器学习形成个性化和具有较强针对性的模型来更准确地预测轨道状态, 才能使得维修策略更具有针对性和科学性。

为提高地铁轨道智能化管理水平, 设计了朴素贝叶斯分类器、Logistic 回归分类器和支持向量机分类器, 并构建了基于 Stacking 集成的轨道状态预测模型。进一步, 基于 Stacking-SVM 集成模型, 引入自适应学习的马尔可夫决策过程 (AL-MDP) 构建了轨道维修决策优化模型。

1 基于 Stacking 集成学习的轨道状态预测

分别构建基于朴素贝叶斯、Logistic 回归以及支持向量机的单体学习器, 并对其进行两两组合构建集成预测模型^[7-8]。

1.1 单体学习器

1.1.1 朴素贝叶斯分类器 (NBC)

定义 A 和 B 为随机概率事件, $A = A_1 \cup A_2 \cup \dots \cup A_n$, 且 $A_i \cap A_j = \emptyset (i \neq j)$, 则 A_i 引发 B 的概率:

$$P(A_i | B) = \frac{P(B | A_i)P(A_i)}{P(B)} = \frac{P(B | A_i)P(A_i)}{\sum_{i=1}^n P(B | A_i)P(A_i)}$$

定义类标记 y , 其类先验概率为 $P(y)$, 某样本 X_i 的类条件概率为 $P(X_i | y)$, 对轨道全线划分若干单元区间 N_i , 若已知其特征属性值 $X_i = (x_{i1}, x_{i2}, \dots, x_{i18})$, 则预测下一时刻的轨道状态等级 $y (y \in Y)$ 的概率为:

$$P(y | X_i) = \frac{P(X_i | y)P(y)}{P(X_i)} = \frac{P(y)}{P(X_i)} \prod_{j=1}^{18} P(x_{ij} | y)$$

对上式计算的所有概率值对比并输出最大值作为 N_i 的最终预测结果 $\bar{y}_i$ 。鉴于任意类别的 $P(X_i)$ 均相同, 则朴素贝叶斯分类器表达式为:

$$\bar{y}_i = \operatorname{argmax}_{y \in Y} P(y) \prod_{j=1}^{18} P(x_{ij} | y)$$

1.1.2 Logistic 回归分类器 (LRC)

考虑到轨道状态预测为多分类问题, 将其划分为多个二分类问题的求解, 训练多个二分类器并通过测试输出最终预测结果, 如图 1 所示。共划分 4 个轨道状态类别 C_1, C_2, C_3, C_4 , 定义任意类别 C_i 的数据样本为正, 其他三类为负且用来训练分类器, 若测试中存在唯一预测为正的分类器, 且其余 3 个分类器预测为负, 则最终预测结果为正。




图 1 “一对其余”拆示示意图 (OvR)

若已知单元区间 N_i 的特征属性值 $X_i = (x_{i1}, x_{i2}, \dots, x_{i18})$, 由于 Logistic 回归函数只会输出 0 或 1, 因此将所有二分类器均构建为 Logistic 回归分类器, 则输出 N_i 的正概率 $P(y = 1 | X_i)$ 和负概率 $P(y = 0 | X_i)$ 分别为:

$$P(y = 1 | X_i) = \frac{e^{\beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_{18} x_{i18}}}{1 + e^{\beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_{18} x_{i18}}}$$

$$P(y = 0 | X_i) = 1 - P(y = 1 | X_i) = \frac{1}{1 + e^{\beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_{18} x_{i18}}}$$

定义正概率和负概率比值为 $odds$, 则正负概率比 $odds$ 表达式为:

$$odds = \frac{P(y = 1 | X_i)}{P(y = 0 | X_i)} = e^{\beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_{18} x_{i18}}$$

若 $odds < 1$, 则 N_i 预测结果为负; 若 $odds > 1$, 则 N_i 预测结果为正, 根据 OvR 获得所有分类器输出结果并输出最终预测结果 $\bar{y}_i$ 。

1.1.3 支持向量机分类器 (SVM)

考虑到支持向量机适用于二分类问题, 因此同样根据 OvR 策略构建支持向量机分类器。在此定义任意样本 i 的特征向量为 $\mathbf{X}_i = (x_{i1}, x_{i2}, \dots, x_{i18})$, 并用 $Y_i = 0$ 或 1 分别定义正例和反例标签; C 代表样本约束常数, 若 C 有限, 则部分样本可以不满足约束条件, 若 C 无穷大, 则任意样本均满足约束条件, 任意样本 i 不满足约束条件的松弛变量为 ξ_i , SVM 表示为:

$$\min_{\omega, b, \xi} \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n \xi_i$$

$$s. t. Y_i (\omega^T x_i + b) \geq 1 - \xi_i, \xi_i \geq 0, i = 1, 2, \dots, n$$

训练 SVM 可得模型参数 ω 和 b , 若输入已知单元区间 N_i 的特征属性值 $\mathbf{X}_i = (x_{i1}, x_{i2}, \dots, x_{i18})$, 可得 $\bar{y}_i$ 。

1.2 轨道状态集成预测模型

Stacking 集成学习算法能够对单体学习器进行训练并集成。基于“1.1 单体学习器”的 3 种单体学习器, 随机选择两个构建初级学习器, 剩余一个为次级学习器, 两两组合构建 3 种基于 Stacking 集成的状态预测模型^[9-10], 如图 2 所示。在此定义, 以朴素贝叶斯分类器 (NBC) 为次级学习器的 Stacking 集成预测模型为“Stacking-NBC”, 以 Logistic 回归分类器 (LRC) 为次级学习器的 Stacking 集成预测模型为“Stacking-LRC”, 以支持向量机分类器

(SVM) 为次级学习器的 Stacking 集成预测模型为 “Stacking-SVM”。




图 2 3 种基于 Stacking 集成的状态预测模型

1.3 模型验证

1.3.1 样本数据

收集 XX 地铁 1 号线、2 号线和 6 号线的设备数据、检测数据和维修数据验证模型的有效性。共截取 XX 三条地铁线路 540 个轨道单元区段，每个区段长度为 200 m，同时收集 2015—2021 年总计 174 次检测数据（其中包括 23 050 条 TQI 数据）、8025 条设备数据和 7 年间的维修数据。设备数据包括坡度、道床类型、钢轨型号、曲线半径、加减速区段和钢轨接头数量等 11 个特征信息 $x_{i1} \sim x_{i11}$ ；维修数据决定了下次检测时的维修活动类型 $x_{i12} \sim x_{i14}$ ；轨道质量指数 (TQI, track quality index) 检测数据、TQI 管理值和 TQI 等级划分标准共同决定某一单元区段在当前时刻和下一时刻的地铁轨道状态等级 $x_{i15} \sim x_{i18}$ 和标记值 y_i 。上述 18 项特征共同构成任意单元区段 N_i 的特征向量 $\mathbf{X}_i = (x_{i1}, x_{i2}, \dots, x_{i18})$ 。数据预处理后共获得 22 128 个数据样本，训练集和测试集的划分比例为 3:1。表 1 为轨道 TQI 状态等级划分标

准和样本数量分布。

表 1 等级划分标准及样本分布

TQI 值	等级	标记值	类别代码	样本数	比例/%
$TQI \leq 14.51$	1	$y_i = 1$	C_1	18 391	83.11
$14.51 < TQI \leq 15.961$	2	$y_i = 2$	C_2	1 456	6.58
$15.961 < TQI \leq 71.412$	3	$y_i = 3$	C_3	1 071	4.84
$TQI > 17.412$	4	$y_i = 4$	C_4	1 210	5.47

1.3.2 模型的评价分析

对 3 个单体学习器和 3 个集成模型分别进行评价分析，内容包括精度 (Accuracy)、 F_1 值和 AUC 值，结果如图 3 所示。精度 (Accuracy) 方面，地铁轨道状态的预测结果为：Stacking-SVM>Stacking-LRC>Stacking-NBC>LRC>SVM>NBC，Stacking-SVM 的预测精度比单体学习器平均提高了 13.6%。 F_1 值方面，预测结果为：Stacking-SVM>Stacking-LRC>Stacking-NBC>SVM>LRC>NBC，Stacking-SVM 的 F_1 值比单体学习器平均提高了 18.5%。AUC 值方面，预测结果为：Stacking-SVM>Stacking-LRC>Stacking-NBC>SVM>LRC>NBC，Stacking-SVM 的 AUC 值比单体学习器平均提高了 13.9%。综合来看，3 个集成模型的状态预测效果均优于单体学习器，且以 SVM 为次级学习器的 Stacking 集成模型具有个性化和较高的准确性，为智慧城市轨道提供管理和维修参考。




图 3 不同模型评价结果

2 基于 AL-MDP 的轨道维修决策优化

将马尔可夫决策过程 (MDP, markov decision process) 融合进地铁轨道的维修决策制定并进行优化，以任意轨道单元 i 在决策时刻 t 下的状态 s_k^t ，从维修活动集合 Ω 中花费一定的维修成本 C_k^t 选择当前最优的维修决策 A_k^t ，不断迭代直至获得规划周期内的最优维修决策。

2.1 马尔可夫决策 (MDP)

四元组 $\langle S, A, P, R \rangle$ 定义马尔可夫决策过程^[11]：
状态空间 S ：定义机器在空间中感知环境的所有状态 s 构成空间 S ，本文中为地铁轨道状态等级；
动作空间 A ：定义机器所有应对的动作 a 构成动作空间 A ，在本文中为地铁轨道维修活动类型；

转移概率 $\mathbf{P}$: 定义当前状态 s 通过某个动作 a 转移到另一个状态的概率矩阵 $\mathbf{P}$, 在本文中为地铁轨道状态从当前状态等级到另一状态的转移概率;

转移奖励 R : 定义系统在通过动作 a 发生状态转移时依据奖励函数 $R(s, a)$ 所获得的奖励 R , 在本文中为采用维修活动 a 对状态 s 的地铁轨道进行维修时产生的费用 $R(s, a)$ 。

MDP 的基本原理为: 若机器处于状态 $s_i \in S$ 的系统中, 对其采取维修活动 a , 机器以转移概率 $\mathbf{P}$ 由状态 s_i 转移至下一状态 s_{i+1} , 并获得奖励 $R(s, a)$ 。机器通过学习若干个状态转移过程和转移奖励, 能够自主判断系统状态并采取相应的维修活动类型以得出最优决策策略, 以获得最多的总奖励^[12]。

2.2 轨道维修决策优化模型

2.2.1 决策变量

划分了 K 个 200 m 的轨道单元, 并划分为 S 个轨道状态等级, 即 $\Omega = \{1, 2, \dots, S\}$, 等级越高, 其轨道状态越差, 当状态等级为 S 时为吸收态^[13]; 规划周期 L 共有 T 个决策时刻, 任意轨道单元 k 在任意决策时刻时的维修活动共有 M 个, 即 $\Omega = \{a_1, a_2, \dots, a_M\}$, 此时轨道单元 k 的检测成本和维修策略分别为 D_k 和 A_k^t , $A_k^t \in \Omega$, 且采取维修策略 A_k^t 时的维修成本为 $C(s_k^t, A_k^t)$ ^[14]。因此, 决策变量 A_k^t 为某决策时刻 t 下的维修活动, $A_k^t \in \Omega, k = 1, 2, \dots, K, t = 1, 2, \dots, T$ 。

2.2.2 目标函数

依据上文, D_k 和 $C(s_k^t, A_k^t)$ 分别为检测固定成本和任意决策时刻 t 时的维修成本, 定义下一个规划周期 $T+1$ 时的轨道单元状态 s_k^{T+1} 和剩余价值为 $R(s_k^{T+1})$; 同时设定折扣因子 $\gamma \in [0, 1]$, 若 $\gamma = 1$, 则代表当前检修成本与下一规划周期的检修成本同等重要; 若 $\gamma = 0$, 则代表只考虑当前检修成本^[8, 15]。因此, 目标函数为轨道单元 k 在规划周期内总成本 V_k^T :

$$\text{Min}; V_k^T = \sum_{t=1}^T \gamma^{t-1} [D_k + C(s_k^t, A_k^t)] - \gamma^T R(s_k^{T+1})$$

2.2.3 约束条件

定义轨道状态为约束条件, 下一决策时刻 $T+1$ 时不能处于吸收态 S , 并设置 S 的剩余价值^[13]为 $-\infty$:

$$s_k^{T+1} \neq S, R(s_k^{T+1} = S) = -\infty$$

2.2.4 自适应学习机制

为了提高轨道状态的智能感知和准确预测, 并且以此作为依据制定更加合理的维修优化决策, 首先要对轨道运行和维护状态进行准确预测。同时, 为了使模型能够针对海量检测数据和历史运行数据进行自适应学习, 深入挖掘轨道劣化机理, 应该基于合理准确的预测结果进行维修决策优化。因此, 本文结合“1.3 模型预测结果”, 以朴素贝叶斯分类器 (NBC) 和 Logistic 回归分类器 (LRC) 作为双单体初级学习器, 以 SVM 分类器作为次级学习器, 对三者集成并构建 Stacking-SVM 模型, 在模型引入了自适应学习机制。

基于性能最优的 Stacking-SVM 模型, 引入自适应学习机制, 流程如下: 采用轨道单元 k 在任意决策时刻 t 时的维

修数据、设备数据和检测数据训练并测试 Stacking-SVM 模型^[16], 结合决策信息确定模型输入参数 $X_k = (x_{k1}, x_{k2}, \dots, x_{k18})$, 并由模型输出状态转移概率矩阵 $\prod_k^t(a)$ 中的各个元素 $p_k^t(s|r, a), \forall s, r \in \Omega$, 进一步可得更新后的状态转移概率矩阵 $\prod_k^t = \{\prod_k^t(a_1), \prod_k^t(a_2), \dots, \prod_k^t(a_M)\}$, 至此实现自适应学习。引入自适应学习的 Stacking-SVM 模型过程如图 4 所示。




图4 Stacking-SVM模型的自适应学习过程

步骤1: 根据决策时刻 t 轨道单元 k 的状态 s_k^t 更新该时刻状态转移概率矩阵 $\prod_k^t$;

步骤2: 计算 $\tau = T+1$ 时刻轨道单元 k 的最优状态值函数 $V_*^{T+1}(s_k^{T+1}) = R(s_k^{T+1})$, 其中, 最优状态值函数表示轨道单元规划周期内所花费总成本的期望, $R(s_k^{T+1})$ 表示 $T+1$ 时刻轨道单元 k 的剩余价值^[17];

步骤3: 判断 τ 是否等于 t 。若 $\tau = t$, 输出最优维修策略 $\pi = (\pi_*^t, \pi_*^{t+1}, \dots, \pi_*^T)$ 和最优状态值函数 $V_*^T(s_k^T)$, 进入步骤7; 若 $\tau \neq t$, 令 $\tau = \tau - 1$, 进入步骤4、5、6;

步骤4: 对于 $\forall s_k^t \in \Omega$, 计算其最优状态值函数:

$$V_*^\tau(s_k^\tau) = \min_{A_k^\tau \in \Omega} [D_k + C(s_k^\tau, A_k^\tau) + \gamma \sum_{s_k^{\tau+1} \in \Omega} p_k^\tau(s_k^{\tau+1}, A_k^\tau) V_*^{\tau+1}(s_k^{\tau+1})]$$

步骤5: 计算轨道单元 k 在决策时刻 τ 的最优维修决策:

$$\pi_*^\tau = \underset{A_k^\tau \in \Omega}{\operatorname{argmin}} V_*^\tau(s_k^\tau)$$

式中, 对于 $\forall s_k^\tau \in \Omega, \pi_*^\tau(s_k^\tau) \in \pi_*^\tau$ 。

步骤6: 返回步骤3;

步骤7: 判断 t 是否等于 T 。若 $t = T$, 则算法结束; 若 $t \neq T$, 令 $t = t + 1$, 进入步骤1。

3 实验结果与分析

3.1 最优维修策略

随机选取第43号轨道单元, 采用上述方法对规划周期内30个决策时刻的状态等级和最优维修策略进行分析, 结果如图5所示^[18-19]。其中, 状态等级包括: C_1 、 C_2 、 C_3 和 C_4 , 维修策略包括: a_0 为不维修、 a_1 为经常维修和 a_2 为综合维修, 初始决策时刻为 t_1 , 周期末决策时刻为 t_{30} 。

状态等级 C_1 : 时刻 $t_1 \sim t_{24}$, 43号轨道单元的维修决策为 a_1 , 需采取经常维修活动; 时刻 $t_{25} \sim t_{31}$, 维修决策为 a_2 , 需采取综合维修活动。状态等级 C_2 : 时刻 $t_1 \sim t_9$ 、 $t_{14} \sim t_{22}$,

维修决策为 a_1 ，需采取经常维修活动；时刻 $t_{10} \sim t_{13}$ 、 $t_{23} \sim t_{30}$ ，维修决策为 a_2 ，需采取综合维修活动。状态等级 C_3 ：时刻 $t_1 \sim t_3$ 、 $t_7 \sim t_8$ 、 $t_{13} \sim t_{14}$ 、 $t_{18} \sim t_{19}$ ，维修决策为 a_1 ，需采取经常维修活动；时刻 $t_4 \sim t_6$ 、 $t_9 \sim t_{12}$ 、 $t_{15} \sim t_{17}$ 、 $t_{20} \sim t_{30}$ ，维修决策为 a_2 ，需采取综合维修活动。状态等级 C_4 ：所有时刻 $t_1 \sim t_{30}$ ，维修决策均为 a_2 ，需采取综合维修活动。




图 5 规划周期内最优维修策略

3.2 AL-MDP 与 MDP 优化结果对比分析

传统 MPD 法无法根据预测结果对状态预测的过程进行优化，也就无法完成自适应学习过程，而改进的 AL-MDP 法能够驱动模型在预测过程中不断优化，直至筛选出最优维修策略。为验证 AL-MDP 的有效性，利用蒙特卡罗 (Monte Carlo, MC) 对引入 MDP 和 AL-MDP 的 Stacking-SVM 模型分别进行 43 号轨道单元的 500 次模拟分析。考虑到 MDP 的状态转移概率矩阵 $\prod_k^t(a)$ 不变，所以 MC 模拟时需基于初始决策时刻的状态转移概率矩阵得到所有时刻的状态，并从图 5 中选择最优维修策略；AL-MDP 可根据某一时刻的状态和概率矩阵获得下一时刻的状态，最终可得最优维修策略和最优规划总成本^[20]。

由 XX 地铁 2015 年至 2021 年的维修数据可知，XX 地铁 1、2 和 6 号线任意轨道单元的平均维修成本为 2.25 万。基于 MDP 和 AL-MDP 对 43 号轨道单元完成 500 次 MC 模拟后的规划周期总成本如图 6 所示。分析图 6 可知，规划周期总成本方面，MDP 模拟结果的最小值和最大值分别为 1.450 万和 2.573 万，AL-MDP 模拟结果的最小值和最大值分别为 1.291 万和 1.678 万；MDP 模拟结果的四分位数分别为 2.144 万和 1.858 万，AL-MDP 模拟结果的四分位数分别为 1.946 万和 1.678 万；MDP 模拟结果的平均数和中位数分别为 2.001 万和 1.996 万，AL-MDP 模拟结果的平均数和中位数分别为 1.803 万和 1.789 万。MDP 和 AL-MDP 的平均规划周期总成本 (2.001 万、1.803 万) 均小于实际成本 2.25 万，这表明加入马尔可夫决策过程的两个模型均可降低维修成本，但 AL-MDP 在各项参数上均优于 MDP，获得最优维修策略和最优规划周期总成本。

与 MDP 模型相比，AL-MDP 模型在 Stacking-SVM 集成模型的基础上加入了自适应学习机制，能够根据当前预测结




图 6 规划周期总成本箱型图

果不断更新下一时刻的预测过程，进一步降低地铁轨道的维修成本。同时，AL-MDP 能够实时掌握地铁轨道的运作状态，给管理者和工作提供精细化、个性化、更科学的维修优化决策，对维修成本和轨道安全实现双重精准控制。

4 智慧地铁轨道管理系统设计

4.1 系统总体设计

本文所设计的“智慧地铁轨道管理系统”共包括 8 个主要功能模块，其中：轨道数据管理、状态监测管理、检查分析管理、生产运维管理、系统安全管理、设备综合管理、决策辅助管理以及系统综合管理，如图 7 所示。不同模块的功能存在相互关联，比如状态监测管理和检查分析管理协同包含病毒检测、健康评估、寿命分析、任务编制和多设备一体化等不同的子功能^[21]。




图 7 系统总体设计图

4.2 系统功能结构设计

基于上述系统的总体设计框架，本文融合利用“基于自适应学习的 Shaping-SVM 模型”，实现了两大主体功能——“轨道状态预测”和“轨道状态维修决策优化”。在地铁轨道预测中需要实现对轨道状态等级、分布、变化趋势和短期内的工作状态预测等功能，在轨道状态维修决策优化中需要制定地铁轨道的维修优化决策、预测规划周期内的状态变化趋势，并对未来某时刻的轨道状态进行安全预警^[22]。系统的功能设计如图 8 所示。

4.3 系统功能实现

4.3.1 评定轨道状态等级

基于 XX 地铁的状态等级分布标准，本文以 200 m 为一个轨道单元，按照状态等级完成对轨道路线的所有单元的评定，通过实时数据掌握当前轨道运行状态，并对未来某




图 8 系统功能结构图

时刻的轨道状态进行预测。该功能可对 XX 地铁任意线路的所有单元进行状态等级评定,使管理者实时掌握轨道单元状态等级,内容包括轨道单元序号、里程点、TQI 值及状态,如图 9 所示。

全线状态评定表			
轨道单元序号	里程点	TQI	状态等级
1	0	5.39	1
2	0.2	7.58	1
3	0.4	7.8	1
4	0.6	8.21	1
5	0.8	8.99	1
6	1	16.27	3
7	1.2	12.07	1
8	1.4	12.67	1
9	1.6	10.09	1
10	1.8	10.3	1
11	2	11.61	1
12	2.2	12.97	1
13	2.4	16.66	3
14	2.6	10.24	1
15	2.8	10.52	1

图 9 轨道状态等级评定

4.3.2 制定维修决策

为智能感知地铁轨道异常状态和精准捕捉劣化规律,进一步对轨道异常状态提供更合理、更科学的维修优化决策,结合所有单元的轨道状态数据和海量历史检测数据,本文采用第 1 章节和第 2 章节的模型,对规划周期内的任意单元状态进行预测并制定优化后的轨道维修决策策略。管理用户可得到指定规划周期的一条线路所有轨道单元的蒙特卡洛模拟下的规划周期总成本,如图 10 所示。可通过 MC 模拟出任意轨道单元在决策周期内的维修决策优化结果,经常维修 C_1 和 C_2 的轨道单元,综合维修 C_3 和 C_4 的轨道单元。分析图 10 可知,指定初始决策时刻为 2020 年 5 月,通过基于 AL-MDP 的轨道维修决策优化模型对所有轨道单元进行蒙特卡洛模拟。已知实际成本为 2.25 万元,蒙特卡洛模拟所得全线轨道的规划周期内总成本为 280.75 万元,经过 AL-MDP 的优化模型后,任意轨道单元的平均规划成本为 1.81 万元。

最优维修策略表			
轨道单元序号	里程点	状态等级	修理策略
1	0	1	经常保养
2	0.2	1	经常保养
3	0.4	1	经常保养
4	0.6	4	综合维修
5	0.8	2	经常保养
6	1	1	经常保养
7	1.2	1	经常保养
8	1.4	1	经常保养
9	1.6	1	经常保养
10	1.8	1	经常保养

图 10 制定维修决策

4.3.3 预警轨道安全状态

基于前文地铁轨道在规划周期内的状态变化趋势预测功能,通过指定某一决策时刻,对未来某一时刻的地铁轨道单元状态进行状态检测。通过历史数据的状态变化趋势,结合目前轨道单元的运行状态提出安全预警,保证地铁管理人员和维修人员能够及时掌握轨道运行状态,并且为未来可能存在或即将出现的危险状态提供运维保证和决策参考。管理用户可得到查询条件下的轨道单元状态安全预警表。在该系统中可获得任意轨道单元在 2 个月后的 MC 模拟结果,如图 11 所示。地铁轨道工作者或管理者能够根据预警信息对轨道单元的未来状态进行等级评定和状态预警,给管理者制定维修措施提供决策参考。

状态安全预警表			
轨道单元序号	里程点	决策前状态等级	2个月后状态等级
4	0.6	1	3
24	4.6	2	3
29	5.6	3	3
38	7.4	3	3
56	11	2	4

图 11 轨道状态安全预警

5 结束语

设计了朴素贝叶斯分类器、Logistic 回归分类器和支持向量机分类器,并构建了基于 Stacking 集成的轨道状态预测模型。综合来看,以 SVM 为次级学习器的 Stacking 集成模型具有个性化和较高的准确性,为智慧城市轨道提供管理和维修参考。

基于 Stacking-SVM 集成模型,引入自适应学习的马尔可夫决策过程 (AL-MDP) 构建了轨道维修决策优化模型。AL-MDP 能够进一步降低地铁轨道的维修成本,实时掌握地铁轨道的运作状态,给管理者和工作者提供精细化、个性化、更科学的维修优化决策,对维修成本和轨道安全实现双重精准控制。

参考文献:

[1] 梅文胜, 吕世望, 于安斌, 等. 一种地铁轨道相对变形检测与定位方法 [J]. 武汉大学学报: 信息科学版, 2022, 47 (1):

104-110.

- [2] 王志鹏, 刘仍奎, 邱荣华, 等. 基于机器学习的地铁轨道几何劣化规律个性化建模研究 [J]. 都市快轨交通, 2020, 33 (4): 54-60.
- [3] 涂勤明. 地铁常用减振轨道振动特性及减振效果对比研究 [J]. 铁道建筑, 2020, 60 (5): 135-138.
- [4] ODOLINSKI K, BOYSEN H E. Railway line capacity utilisation and its impact on maintenance costs [J]. Journal of Rail Transport Planning & Man, 2019, 9 (MAY): 22-33.
- [5] 康海涛. 基于无线通讯列车控制系统的全自动无人驾驶地铁系统研究 [J]. 计算机测量与控制, 2019, 27 (5): 127-130, 154.
- [6] 王伟铭, 沈 钢, 毛 鑫. 不同轨道结构对地铁车辆轮周多边形不圆顺发展的影响 [J]. 城市轨道交通研究, 2022, 25 (1): 80-85.
- [7] 张鹏飞, 姚 典, 冯青松, 等. 地铁波磨对轮轨动力特性影响及其安全阈值分析 [J]. 振动与冲击, 2022, 41 (5): 123-130, 150.
- [8] 李东帅, 黄靖宇. 基于深度学习的高速磁浮轨道不平顺预估 [J]. 华东交通大学学报, 2020, 37 (3): 44-51.
- [9] QUIRCHMAIR M, FROHBERG E, LOY H. Insulated rail joints-a solution to improve lifetime and performance at high maintenance track sections [J]. Global Railway Review, 2019, 25 (1): 58-61.
- [10] 陆万荣, 许江淳, 李玉惠. 面向 Stacking 集成的改进分类算法及其应用 [J]. 计算机应用与软件, 2022, 39 (2): 281-286.
- [11] YI J, ZHANG H, LIU H, et al. Flight delay classification prediction based on stacking algorithm [J]. Journal of Advanced Transportation, 2021, 8 (4292778): 1-10.
- [12] 周志军, 刘玉涛, 李 伟, 等. 地铁钢弹簧浮置板轨道振动特性和减振效果研究 [J]. 铁道标准设计, 2022, 66 (5): 57-63.
- [13] 徐 博, 韩 斌, 穆广友. 断裂力学在轨道车辆结构寿命预测中的应用 [J]. 铁道车辆, 2022, 60 (1): 73-78.
- [14] XU W, WANG J, FU T, et al. Aggressive driving behavior prediction considering driver's intention based on multivariate-temporal feature data [J]. Accident Analysis & Prevention, 2022, 164 (106477): 1-14.
- [15] 赵 刚. 基于“智慧地铁”的城市轨道交通资产管理系统研究 [J]. 城市轨道交通研究, 2022, 25 (1): 166-169, 175.
- [16] 姜俊鹏, 贾 坤, 管 善, 等. 基于 LSTM 神经网络的铁路制动系统故障预测方法 [J]. 变频器世界, 2022 (3): 54-59.
- [17] WUEST R, BIITIKOFER S, ESS S, et al. Maintenance timetable planning based on mesoscopic infrastructure and the transport service intention [J]. Journal of Rail Transport Planning & Man, 2019, 11: 100146.1-100146.19.
- [18] 王维华. 地铁车辆障碍物检测技术应用研究 [J]. 计算机测量与控制, 2022, 30 (2): 110-116.
- [19] WANG Y, WANG P, WANG X, et al. Position synchronization for track geometry inspection data via big-data fusion and incremental learning [J]. Transportation Research, 2018, 93: 544-565.
- [20] LV X, LI M. Application and research of the intelligent management system based on internet of things technology in the era of big data [J]. Mobile Information Systems, 2021 (16): 1-6.
- [21] 林 军, 袁 浩, 刘 悦, 等. 基于轻量级卷积神经网络的地铁轨道线路状态检测系统 [J]. 机车电传动, 2022 (2): 97-104.
- [22] 李 运. 基于深度学习的城市轨道交通客流预测实训基地培训系统设计及实现 [J]. 计算技术与自动化, 2022, 41 (2): 173-177.
- [22] 刘 鑫. 无监督异常检测方法研究及其应用 [D]. 成都: 电子科技大学, 2018.
- [23] 郭建华, 白俊峰, 马静坡. 关于飞参数据的自动分析研究 [J]. 中国新通信, 2019, 21 (7): 224.
- [24] GANGULI R C I H D J. Detection of helicopter rotor system simulated faults using neural networks [J]. Journal of The American Helicopter Society, 1997, 42 (2): 161-171.
- [25] 廖文峰. 基于模糊神经网络的旋翼不平衡故障诊断 [D]. 南京: 南京航空航天大学, 2014.
- [26] 徐腊梅, 易春菊. 灰色系统理论在图像边缘检测中的应用研究 [J]. 武汉大学学报 (信息科学版), 2012, 37 (8): 929-931.
- [27] 姚飞虎. 基于盲源分离和人工免疫的旋翼故障诊断 [D]. 南京: 南京航空航天大学, 2012.
- [28] 高亚东, 邓升平. 基于支持向量机的直升机旋翼不平衡故障分类研究 [J]. 南京航空航天大学学报, 2011, 43 (3): 435-438.
- [29] 邓升平. 旋翼不平衡故障试验及诊断方法研究 [D]. 南京: 南京航空航天大学, 2010.

(上接第 47 页)

- [15] 龚成清, 何文华. 面向校园人脸识别的数据投毒攻击检测算法研究 [J]. 菏泽学院学报, 2022, 44 (2): 15-20.
- [16] JEON H K, YANG C S. Enhancement of ship type classification from a combination of CNN and KNN [J]. Electronics, 2021, 10 (10): 1169-1169.
- [17] 胡 珉, 白 雪, 徐 伟, 等. 多维时间序列异常检测算法综述 [J]. 计算机应用, 2020, 40 (6): 1553-1564.
- [18] AZIEZ S A, NAWAR A, HAMEED R A, et al. Using KNN algorithm predictor for data synchronization of ultra-tight GNSS/INS integration [J]. Electronics, 2021, 10 (13): 1513-1513.
- [19] 陈炜军, 崔德平, 张 斌. 飞参数据在航空飞行器状态监控检测中的应用 [J]. 直升机技术, 2021 (3): 45-48.
- [20] 彭 宇, 何永福, 王少军, 等. 飞行数据异常检测技术综述 [J]. 仪器仪表学报, 2019, 40 (3): 1-13.
- [21] 韩东明, 郭方舟, 潘嘉铨, 等. 面向时序数据异常检测的可视分析综述 [J]. 计算机研究与发展, 2018, 55 (9): 1843-1852.