

基于XGBoost的城市轨道列车ATO运行控制方法研究

董亚琨

兰州交通大学光电技术与智能控制教育部重点实验室, 甘肃 兰州

收稿日期: 2026年7月27日; 录用日期: 2026年8月31日; 发布日期: 2026年9月10日

摘 要

针对城市轨道交通ATO运行中准点性、停车精度、舒适性与节能性难以兼顾的问题, 提出基于XGBoost的加速度指令预测控制方法。以次渠区段为主要实验场景, 建立考虑线路限速、坡度、列车动力学、执行机构动态和再生制动储能的仿真模型, 构建剩余距离、时间比例、线路状态、推荐速度及速度滑动窗口等特征, 采用XGBoost在线预测加速度指令。测试集MAE、RMSE和 R^2 分别为 0.0409 m/s^2 、 0.1463 m/s^2 和 0.9132 。次渠区段仿真结果表明, XGBoost控制器实际能耗为 41.29 kJ , 较经验规则和PID分别降低 40.89% 和 28.42% , 平均冲击率为 0.0810 m/s^3 , PID能量回收率最高, 为 79.28% ; 经验规则控制器运行时间最短, 为 115.40 s 。宋家庄补充线路实验表明, 该方法在复杂坡度和多级限速条件下仍具有一定节能潜力, 但停车精度和跨线路适应性仍需提高。结果表明, 所提方法可降低实际能耗并改善运行平稳性, 可为城市轨道交通数据驱动ATO节能控制提供参考。

关键词

城市轨道交通, 自动列车运行, XGBoost, PID控制, 经验规则控制, 节能控制

Research on Urban Rail Train ATO Operation Control Method Based on XGBoost

Yakun Dong

Key Lab of Opt-Electronic Technology and Intelligent Control of Ministry of Education, Lanzhou Jiaotong University, Lanzhou Gansu

Received: July 27, 2026; accepted: August 31, 2026; published: September 10, 2026

Abstract

An XGBoost-based acceleration command prediction method is proposed to coordinate punctuality, stopping accuracy, comfort and energy saving in urban rail ATO. A Ciqu-section simulation model is established considering speed limits, gradients, train dynamics, actuator dynamics and regenerative braking energy storage. Running-state features, including remaining distance, time ratio, line state, recommended speed and sliding-window speed, are used to train an XGBoost regression model. The test-set MAE, RMSE and R^2 are 0.0409 m/s^2 , 0.1463 m/s^2 and 0.9132 . In the Ciqu simulation, XGBoost consumes 41.29 kJ , 40.89% and 28.42% lower than the rule-based and PID controllers, with the lowest average jerk of 0.0810 m/s^3 . The PID controller has the highest energy recovery rate of 79.28% , while the rule-based controller has the shortest running time of 115.40 s . Supplementary Songjiazhuang results show that this method still has energy-saving potential under complex gradients and multiple speed limits, while stopping accuracy and cross-line adaptability need improvement. The results show that the proposed method can reduce actual energy consumption and improve running smoothness, and can provide a reference for data-driven ATO energy-saving control of urban rail transit trains.

Keywords

Urban Rail Transit, Automatic Train Operation, XGBoost, Pid Control, Rule-Based Control, Energy-Saving Control

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

城市轨道交通列车自动运行系统需要在复杂线路条件下同时满足安全、准点、平稳和节能等多重目标[1]。随着城市轨道交通运营规模不断扩大，列车牵引能耗和运行控制质量已成为智能化、绿色化发展中的重要问题[2]。传统 PID 控制方法具有结构简单、实现方便的特点，但其性能较大程度依赖目标速度曲线和参数整定结果[3]。经验规则控制方法依托经验规则实现控制决策[4]，虽然在工程应用中具有较强的可解释性，但对线路变化和工况迁移的适应能力仍然有限[5]。近年来，数据驱动方法在复杂非线性控制问题中显示出较好的建模和决策能力[6]，为 ATO 控制策略优化提供了新的研究思路[7]。

与深度神经网络、强化学习等数据驱动方法相比，XGBoost [8] 基于梯度提升树构建非线性映射关系，具有训练效率较高、对中小规模结构化样本适应性较好、参数数量相对较少和特征重要性可解释性较强等特点。城市轨道交通 ATO 控制样本通常由剩余距离、运行时间、当前速度、线路限速、坡度、推荐速度等结构化变量构成，适合采用树模型建立运行状态与控制指令之间的映射关系。因此，本文选择 XGBoost 作为加速度指令预测模型，以降低对人工规则设计和控制参数反复整定的依赖，并提高控制策略对复杂线路状态的适应能力。

现有研究主要围绕列车节能运行优化[9]、目标速度曲线设计、速度跟踪控制[10]以及智能优化算法展开[11]，在最优控制、启发式算法和强化学习等方向上[12]已取得一定成果。然而，就城市轨道交通区间运行而言，如何在统一约束条件下建立运行状态与控制输出之间的有效映射关系[13]，并在准点性、舒适性、停车精度与节能性之间取得较好平衡，仍是值得进一步研究的问题[14]。基于此，本文建立线路-列车一体化仿真环境，提出一种基于 XGBoost 的列车 ATO 运行控制方法[15]，通过构建运行状态特征与

加速度指令之间的映射模型实现在线控制，并与 PID 控制器和经验规则控制器进行对比分析[16]，以验证所提方法在节能性和平稳性方面的有效性[17]。

2. 列车运行建模与控制问题描述

2.1. 线路与列车动力学模型

本文以次渠区段为研究对象，线路起点位置为 20,103 m，终点位置为 21,569 m，总运行距离为 1466 m。线路包含多级限速区段与坡度区段，其中限速区段起点分别为 20,103、20,283、21,449 和 21,569 m，对应限速为 55、80、55 和 0 km/h。坡度起点分别为 19,950、20,295、20,970 和 21,405 m，对应坡度为 2‰、-3‰、3‰和 2‰。

列车质量取 194.5 t。运行过程中综合考虑牵引力、制动力、基本阻力与坡度附加阻力。牵引力和制动力采用分段特性曲线描述，执行机构通过延时环节与一阶惯性环节反映控制指令到动力输出之间的动态滞后。仿真步长取 0.2 s。

在仿真过程中，将列车视为沿线路纵向运行的单质点系统。设第 k 个仿真步列车位置、速度、实际加速度和控制器输出指令分别为 s_k 、 v_k 、 a_k 和 u_k 。列车纵向合力由牵引力、制动力、基本运行阻力和坡度附加阻力共同决定，可表示为：

$$F_k = F_t(v_k, u_k) - F_b(v_k, u_k) - F_r(v_k) - F_g(s_k) \quad (1)$$

$$a_k = F_k / M \quad (2)$$

$$v_{k+1} = \max(0, v_k + a_k \Delta t) \quad (3)$$

$$s_{k+1} = s_k + v_k \Delta t + 0.5 a_k \Delta t^2 \quad (4)$$

$$t_{k+1} = t_k + \Delta t \quad (5)$$

式中， F_k 为列车纵向合力， F_t 为牵引力， F_b 为制动力， F_r 为基本运行阻力， F_g 为坡度附加阻力， M 为列车质量， Δt 为仿真步长。上述离散更新方程用于描述列车在每个仿真步内的位置、速度和运行时间变化。

2.2. 再生制动与评价指标

为反映城市轨道交通列车节能运行特性，仿真模型进一步引入再生制动能量回收与储能机制[18]。再生制动能量转换效率取 0.75，储能系统容量取 1000 kJ，充放电效率均取 0.9。牵引阶段优先消耗储能系统内能量，不足部分由外部电网补充。制动阶段将可回收能量按效率转换后优先存储[19]。

本文选取总运行时间、实际能耗、能量回收量、能量回收率、舒适度和停车误差作为综合评价指标。其中，舒适度采用平均冲击率表征，停车误差采用列车最终停车位置相对于目标停车点的偏差表示。平均冲击率、停车误差和能量回收率分别定义为：

$$J = 1 / (N - 1) \sum |(a_k - a_{k-1}) / \Delta t| \quad (6)$$

$$es = \text{send} - \text{starget} \quad (7)$$

$$\eta r = Er / Ea \times 100\% \quad (8)$$

3. 基于 XGBoost 的 ATO 控制方法

3.1. 样本生成与标签构建

本文采用工况转换点驱动的仿真方式生成训练样本和测试样本[20]。首先依据牵引、巡航、惰行和制

动工况转换点生成列车运行轨迹，再将轨迹转换为监督学习样本。样本标签为加速度指令，输入特征由当前时刻状态量与滑动窗口历史状态共同构成[21]。

本文训练标签 u_n 由工况转换点驱动的仿真轨迹生成，并非人工随机给定。具体而言，首先依据牵引、巡航、惰行和制动工况转换点生成列车运行轨迹，再根据各离散时刻所处工况确定加速度指令标签。当列车处于牵引工况时，标签取牵引加速度指令，处于巡航工况时，标签由 PID 速度跟踪控制器根据当前速度与巡航速度偏差生成，处于惰行工况时，标签取 0，处于制动工况时，标签取制动加速度指令。为提高终点停车精度，在终点邻域内根据当前速度和剩余停车距离对制动指令进行修正：

$$u_n = -v^2 / (2s_r) \quad (9)$$

式中： u_n 为样本标签加速度指令， v 为列车当前速度， s_r 为剩余停车距离。由此得到的标签能够反映牵引、巡航、惰行、制动和终点停车约束共同作用下的可行控制指令，可作为 XGBoost 模型学习运行状态 - 加速度指令映射关系的监督信号。

构建的基本特征包括剩余距离 s_r 、时间比例 t_ratio 、对数时间比例 t_ratio_log 、当前限速 s_l 、坡度 g_d 、下一区段限速 n_{sl} 、距下一限速区剩余距离 n_{sld} 和推荐速度 v_{bar} 。此外，引入长度为 3 的速度滑动窗口特征，即 $w0_vbar$ 、 $w1_vbar$ 和 $w2_vbar$ 。因此，单个样本共包含 11 维输入特征。以样本文件为例，单个数据集含 502 个样本点，对应目标速度曲线文件同样包含 502 个位置 - 速度离散点，可供 PID 控制器进行目标速度插值。

3.2. XGBoost 基本原理

设训练样本集为 $D = \{(x_i, u_i)\}$ ，其中 x_i 为第 i 个样本的运行状态特征向量， u_i 为对应的加速度指令标签。XGBoost 采用加法模型表示预测输出：

$$\hat{u}_i = \sum f_k(x_i) \quad (10)$$

式中： $\hat{u}_i$ 为模型预测加速度， f_k 为第 k 棵回归树。模型训练目标函数由损失函数和正则化项共同组成：

$$L = \sum l(u_i, \hat{u}_i) + \sum \Omega(f_k) \quad (11)$$

$$\Omega(f) = \gamma T + 0.5\lambda \sum w_j^2 \quad (12)$$

式中： $l(u_i, \hat{u}_i)$ 为损失函数， $\Omega(f_k)$ 为正则化项， T 为回归树叶节点数， w_j 为第 j 个叶节点权重， γ 和 λ 为正则化系数。通过在目标函数中引入正则化项，XGBoost 能够在提高拟合能力的同时抑制过拟合。本文将 XGBoost 作为加速度指令回归预测模型，用于建立列车运行状态特征与控制指令之间的非线性映射关系。

3.3. XGBoost 控制器设计

XGBoost 控制器采用回归模型在线输出列车加速度指令[22]。控制过程中，首先根据最小时间分配思想结合当前位置、当前时间与阻力误差项计算推荐速度。随后构造当前状态特征和历史窗口特征，并输入训练好的 XGBoost 模型，得到当前时刻的加速度预测值[23]。为保证控制策略的安全性及可执行性，在模型输出基础上进一步设置加速度上下限约束、加速度变化率约束、安全速度保护以及终点邻域精准停车控制[24]。控制过程中，首先根据最小时间分配思想结合当前位置、当前时间与阻力误差项计算推荐速度。然后根据剩余距离与计划剩余运行时间的比值确定基准速度，在此基础上根据当前坡度和前方限速区段信息进行微调，以反映线路条件对运行速度的实际约束。随后构造当前状态特征和历史窗口特征，并输入训练好的 XGBoost 模型，得到当前时刻的加速度预测值。

XGBoost 控制器在线控制流程为：读取列车当前运行状态，计算剩余距离、时间比例、线路限速、坡度和推荐速度等特征，构造速度滑动窗口特征，调用训练好的 XGBoost 模型预测加速度指令，对预测结果进行加速度上下限、变化率和安全速度约束修正，最后将修正后的加速度指令输入列车动力学模型进行状态更新。

3.4. 对比控制器设计

为验证所提方法的有效性，本文构建 PID 控制器[25]和经验规则控制器作为对比方法。PID 控制器通过目标速度曲线插值得到当前位置的目标速度，再利用 PID 算法输出加速度指令[26]，并对前方限速变化进行预判。经验规则控制器依据经验规则确定牵引、惰行和制动工况，并根据最小时间分配结果实时计算推荐速度[27]。

4. 仿真与实验验证

4.1. 数据集构建与模型训练设置

本文采用仿真方式构建 XGBoost 控制器所需的数据集。依据工况转换点生成列车运行轨迹后，分别保存训练集、测试集和目标速度曲线数据。其中，训练样本与测试样本的标签均为加速度指令 u_n ，输入为 11 维运行状态特征。目标速度曲线数据由位置 s 与对应速度 v 组成，主要用于 PID 控制器进行位置插值和目标速度跟踪。

从数据组织方式看，训练脚本按编号顺序读取多个训练集与测试集文件并进行汇总，默认可读取 1~25 号数据集文件。单个样本文件中包含连续离散时刻的列车运行状态，能够较完整地反映列车在牵引、惰行与制动过程中的状态演化规律。以示例文件为例，单个数据集含 502 个样本点，对应目标速度曲线文件同样包含 502 个位置 - 速度离散点[28]。这样的数据组织方式一方面便于后续模型训练阶段进行批量读取与统一管理，另一方面也有利于保持训练样本与在线仿真场景之间的一致性。

在特征构建方面，本文选取剩余距离、时间比例、对数时间比例、当前限速、坡度、下一区段限速、距下一限速区剩余距离、推荐速度以及速度滑动窗口等信息作为模型输入。其考虑在于：剩余距离和时间比例能够描述列车当前所处的运行阶段，限速、坡度和相邻区段信息可以反映外部线路条件对控制决策的影响。推荐速度则综合体现了当前时间分配结果，速度滑动窗口特征则用于补充短时历史信息，使模型在预测当前加速度时能够兼顾状态演化的连续性。与仅使用当前时刻单点状态相比，这种特征构造方式更有助于表达列车运行过程中的动态变化特征。

XGBoost 模型训练采用回归形式，以加速度指令为预测目标。训练过程中，先将训练集按 8:2 比例划分为训练子集和验证子集，再采用带早停机制[29]的梯度提升树模型进行训练。主要训练参数设置如下：最大树深为 8，学习率为 0.1，样本子采样率为 0.8，特征子采样率为 0.8，最小子节点权重为 3，L2 正则化系数为 1，L1 正则化系数为 0.001，最大迭代轮数为 1000，早停轮数为 50，随机种子为 42。之所以引入早停机机制，是因为本文样本由仿真生成，虽然数据规模较大，但样本分布仍受既定线路和控制逻辑约束，若一味增加迭代轮数，模型容易对训练样本中的局部模式拟合过强，从而削弱在测试集和在线控制阶段的泛化能力。训练完成后，将模型保存为 `xgb.model`，并在在线控制阶段直接调用该模型实现加速度预测。

4.2. 模型预测性能评价

为评价 XGBoost 模型对加速度指令的离线预测能力，本文采用平均绝对误差、均方根误差和决定系数作为测试集评价指标。平均绝对误差、均方根误差和决定系数分别定义为：

$$\text{MAE} = (1/N) \sum |u_i - \hat{u}_i| \quad (13)$$

$$RMSE = \sqrt{\frac{1}{N} \sum (u - \hat{u})^2} \tag{14}$$

$$R^2 = 1 - SSE/SST \tag{15}$$

式中， u_i 为测试集真实加速度标签， $\hat{u}_i$ 为模型预测加速度， N 为测试样本数量， SSE 为残差平方和， SST 为总平方和。测试集预测结果如表 1 所示。

Table 1. Prediction performance of the XGBoost model on test set
表 1. XGBoost 模型测试集预测性能

模型	MAE/(m·s ⁻²)	RMSE/(m·s ⁻²)	R ²
XGBoost	0.0409	0.1463	0.9132

由表 1 可知，XGBoost 模型在测试集上的 MAE 为 0.0409 m/s²，RMSE 为 0.1463 m/s²，决定系数 R^2 达到 0.9132，说明模型预测值与样本标签之间具有较高的一致性。测试集 MSE 为 0.0214，进一步表明模型整体预测误差处于较低水平。该结果说明，XGBoost 能够较好学习运行状态特征与加速度指令之间的非线性映射关系，可为后续在线闭环控制提供模型基础。

4.3. 仿真场景与控制器参数设置

本文以次渠区段为统一实验场景，对 XGBoost 控制器、PID 控制器和经验规则控制器进行对比仿真。统一控制约束包括：最大牵引加速度为 1.0 m/s²，最大制动加速度为-1.0 m/s²，最大允许运行时间按计划运行时间的 1.16 倍设置，停车误差阈值为 0.35 m。XGBoost 控制器加速度变化率取 0.2。PID 控制器加速度变化率取 0.3，参数设置为 $K_p=3.5$ 、 $K_i=0.2$ 、 $K_d=1.2$ 。经验规则控制器加速度变化率取 0.3。三类控制器均在相同线路模型、列车模型、能量回收模型和停车评价规则下运行。

4.4. 实验过程与评价指标设置

仿真过程中，每个时间步均记录列车位置、速度、加速度、牵引功率、累计能耗、能量回收量和储能

量，并输出速度 - 位置曲线、加速度 - 位置曲线、能量性能对比图和性能统计表。

因此，本文从数值指标和运行曲线两个层面对控制器性能进行分析：前者用于反映运行效率、节能性、舒适性和停车精度等总体表现，后者用于揭示控制器在限速切换、坡度变化和终点停车等关键区段的动态响应特征。

在评价指标设置上，本文从运行效率、节能效果、乘坐舒适性和停车精度 4 个方面评价控制器性能，具体指标包括：

- 1) 总运行时间，用于表征区间通过效率；
- 2) 实际能耗，用于表征列车牵引阶段从外部获取的净能量；
- 3) 能量回收量与能量回收率，其中能量回收率定义为能量回收量与实际能耗之比；
- 4) 舒适度，以平均冲击率表征；
- 5) 停车误差，以列车最终停车位置与目标停车点之间的偏差表示；
- 6) 平均速度，用于辅助分析运行效率与能耗水平之间的关系。

4.5. 综合性能比较

为直观比较三种控制策略在统一实验条件下的运行效果，本文从运行时间、实际能耗、能量回收量、

能量回收率、舒适度、停车误差和平均速度等指标对控制器性能进行综合评价，统计结果如表 2 所示。表 2 反映的是三种控制器在同一线路条件、同一列车模型和同一评价准则下的总体表现，可作为后续运行曲线分析与机理讨论的定量依据。

Table 2. Performance comparison of the three controllers

表 2. 三种控制器的性能对比

控制器	总时间/s	实际能耗/kJ	回收能量/kJ	回收率/%	舒适度	停车误差/m	平均速度/(m/s)
XGBoost	127.60	41.29	16.83	40.77	0.0810	-0.449	11.49
经验规则	115.40	69.85	32.41	46.39	0.1905	-0.125	12.70
PID	138.80	57.68	45.73	79.28	0.2888	-0.125	10.56

由表 2 可知，三种控制器在运行效率、节能性和舒适性方面呈现出较为明显的差异。经验规则控制器的总运行时间最短，为 115.40 s，说明基于经验规则的控制方式在提高区间通过效率方面具有一定优势。XGBoost 控制器的总运行时间为 127.60 s，较经验规则增加 10.57%，但仍明显短于 PID 控制器的 138.80 s，表明其在兼顾运行效率与控制平稳性方面具有一定平衡能力。

在节能性方面，XGBoost 控制器的实际能耗最低，仅为 41.29 kJ，分别较经验规则和 PID 控制器降低 40.89%和 28.42%，显示出较好的全过程节能能力。PID 控制器虽然实际能耗高于 XGBoost 控制器，但其能量回收量达到 45.73 kJ，能量回收率高达 79.28%，说明该控制方式在制动阶段对再生能量的利用更加充分。在舒适度和停车精度方面，XGBoost 控制器的平均冲击率仅为 0.0810 m/s³，明显低于经验规则和 PID 控制器，说明其加速度输出更加平滑，有利于提高乘坐舒适性。但其停车误差相对较大，表明终点邻域内的精细停车控制能力仍有进一步提升空间。综合来看，在统一约束条件和统一实验场景下，XGBoost 控制器在节能性与平稳性方面具有较突出的综合优势。

4.6. 运行曲线与能量特性分析

为进一步揭示不同控制策略性能差异的形成机理，本文结合速度 - 位置曲线、加速度 - 位置曲线、能量性能对比图以及 XGBoost 特征重要性排序图，对三种控制器的动态响应特征、控制平顺性、节能实现路径与模型预测依据进行分析。相较于表 2 给出的综合统计结果，图形结果能够更直观地反映控制器在区间运行过程中的状态演化规律。

首先，图 1 给出了三种控制器的速度 - 位置关系曲线。该图主要用于表征不同控制策略在限速约束下的速度组织方式及运行节奏差异，从而为分析运行时间和平均速度指标提供过程层面的依据。

由图 1 可以看出，三种控制器均能够在限速约束下完成区间运行，但其速度演化过程存在明显差异。经验规则控制器在区间中部采用了更积极的牵引策略，因此整体运行时间较短。PID 控制器更强调对目标速度曲线的跟踪，运行过程相对保守。XGBoost 控制器则在多数区段保持了较为均衡的速度变化趋势，未出现明显的过度牵引和突变式减速现象。这一结果与表 2 中三类控制器在运行时间和平均速度上的差异相一致。

在速度变化规律的基础上，图 2 进一步给出了三种控制器的加速度 - 位置关系曲线。相较于速度曲线，加速度曲线更能直接反映控制指令切换的频繁程度以及运行过程中动态响应的连续性。

由图 2 可以看出，PID 控制器和经验规则控制器在部分区段存在较明显的加速度切换，尤其在限速切换点附近和终点停车阶段，加速度变化较为集中。相比之下，XGBoost 控制器输出曲线更为连续，加速度波动幅值也相对较小。XGBoost 控制器在加速度变化率约束和回归预测机制共同作用下，能够较好

抑制控制指令突变,从而提高列车运行平稳性。该现象也从侧面解释了表2中 XGBoost 控制器舒适度指标最优的原因。




Figure 1. Comparison of speed-position curves of three controllers

图 1. 三种控制器速度 - 位置关系对比




Figure 2. Comparison of acceleration-position curves of three controllers

图 2. 三种控制器加速度 - 位置关系对比

除运行效率和平稳性外,不同控制器在能量利用方式上也存在明显差异。为展示各控制器在实际能耗、回收能量与能量利用路径上的总体表现,图3给出了不同控制器的能量性能对比结果。

由图3可以看出,XGBoost 控制器在实际能耗方面最低,说明其更倾向于通过降低牵引阶段的不必要能量消耗来实现节能。PID 控制器虽然总能耗不占优势,但在能量回收方面表现更好,体现出较强的再生制动能量利用能力。经验规则控制器则介于两者之间。这表明,三种控制策略在节能实现路径[30]上存在差异:XGBoost 控制器更偏向全过程能量优化,PID 控制器更偏向末端能量回收,经验规则则体现出时间性能与能耗性能之间的折中。

为进一步解释 XGBoost 控制器的预测依据,本文基于训练后的 XGBoost 模型计算各输入特征的重要性得分,结果如图4所示。时间比例 t_ratio 、剩余距离 s_r 和推荐速度 v_{bar} 的重要性得分较高,说明模型在预测加速度指令时主要依据列车所处运行阶段、剩余运行距离以及当前推荐速度进行判断。距下一




Figure 3. Comparison of energy performance of different controllers

图 3. 不同控制器能量性能对比




Figure 4. Feature importance ranking of XGBoost

图 4. XGBoost 特征重要性排序

限速区剩余距离 n_{sld} 和速度滑动窗口特征 $w1_vbar$ 、 $w2_vbar$ 也具有较高贡献, 表明模型能够综合考虑前方限速变化和短时速度演化信息。相比之下, 坡度 g_d 、下一区段限速 n_{sl} 和当前限速 s_l 的重要性相对较低, 这与本文测试区段坡度和限速结构变化范围有限有关。总体来看, 特征重要性结果表明 XGBoost 模型并非单纯依赖单一变量进行预测, 而是综合利用运行阶段、剩余距离、推荐速度和历史速度信息生成加速度指令, 从而为其在节能性和平稳性方面的表现提供了数据层面的解释。

综合图 1~4 以及表 2 的分析结果可以认为, XGBoost 控制器在统一约束条件和统一实验场景下表现出较好的综合性能与工程适应性。该方法不仅能够在全过程运行中维持较平稳的速度和加速度变化, 还能够通过减少不必要的牵引能量消耗获得较好的节能效果。因此, 相较于单纯依赖参数整定或经验规则的控制策略, 基于运行状态特征映射的数据驱动控制方法在城市轨道交通 ATO 控制中具有较好的应用潜力。

4.7. 补充线路场景验证

为考察所提方法在不同线路条件下的适应性, 本文在次渠区段实验基础上补充设置宋家庄线路场景进行验证。宋家庄场景区间起点为 173.7 m, 终点为 2806 m, 区间长度约为 2632.3 m, 线路限速结构为

50、80、65、80、55 km/h，坡度组合为-2‰、-3‰、12‰、3.15‰、-8‰、3‰、4.25‰和-2‰。与次渠区段相比，该场景具有更长的站间距离、更复杂的坡度组合和多级限速切换特征。为保证对比条件一致，宋家庄场景沿用相同列车动力学参数、能量回收参数和控制约束，XGBoost 控制器仍调用原训练得到的 xgb.model，未针对宋家庄线路重新训练。计划运行时间根据宋家庄最小运行时间曲线并加入一定缓冲时间估算得到。

由表 3 可知，在宋家庄复杂线路场景下，XGBoost 控制器的实际能耗为 91.93 kJ，低于经验规则控制器的 97.95 kJ 和 PID 控制器的 106.77 kJ，说明所提方法在未重新训练模型的条件下仍保持了一定节能优势。从运行平稳性看，XGBoost 控制器的平均冲击率为 0.1888，明显低于经验规则控制器的 0.9146，但高于 PID 控制器的 0.0823，表明其在复杂线路下仍能一定程度上抑制控制指令突变，但平稳性表现受线路条件和速度组织方式影响。停车精度方面，三种控制器在宋家庄场景下的停车误差均较次渠场景有所增大，其中 XGBoost 控制器停车误差为 1.799 m，说明复杂坡度组合和多级限速切换会对终点精细停车产生更大影响，后续仍需进一步结合终点邻域修正控制和多线路样本训练机制提高停车精度。

Table 3. Key performance comparison of the three controllers on Songjiazhuang section

表 3. 宋家庄线路场景下三种控制器关键性能对比

控制器	总时间/s	实际能耗/kJ	舒适度	停车误差/m
XGBoost	181.60	91.93	0.1888	1.799
经验规则	180.00	97.95	0.9146	2.516
PID	188.60	106.77	0.0823	3.138

图 5 给出了宋家庄场景下三种控制器的速度 - 位置关系曲线。由图 5 可知，三种控制器均能够在限速约束下完成区间运行，但速度组织方式存在差异。XGBoost 控制器在多数区段保持了相对平缓的速度变化趋势，经验规则控制器运行时间略短但速度波动较明显，PID 控制器在部分区段速度调整较为保守。结合表 3 结果可知，补充线路实验表明，XGBoost 控制器在复杂线路条件下仍具有一定节能潜力，但其停车精度和跨线路适应性仍存在进一步优化空间[31]。




Figure 5. Comparison of speed-position curves of three controllers on Songjiazhuang section

图 5. 宋家庄场景下三种控制器速度 - 位置关系对比

综上, 宋家庄补充实验在一定程度上扩展了本文仿真验证场景。结果表明, 所提 XGBoost 控制器在复杂线路条件下仍能够保持较低实际能耗, 但在终点停车精度和复杂线路自适应方面仍需进一步改进。因此, 本文结论更适宜理解为在既有仿真模型和有限线路场景下的初步验证结果, 后续仍需结合更多线路数据和实测运行数据开展进一步验证。

5. 结论

本文针对城市轨道交通 ATO 区间运行控制问题, 建立了包含线路条件、列车动力学和再生制动储能机制的仿真环境, 提出了基于 XGBoost 的 ATO 运行控制方法, 并与 PID 控制器和经验规则控制器进行了对比分析, 主要结论如下:

- 1) 构建了基于运行状态特征的 XGBoost 列车控制模型, 输入特征由剩余距离、时间比例、线路限速、坡度、推荐速度及速度滑动窗口等信息组成, 能够较好表征列车运行状态并支撑加速度指令在线预测。
- 2) 在 1466 m 测试区段内, XGBoost 控制器的实际能耗最低, 仅为 41.29 kJ, 表明该方法在降低列车牵引能耗方面具有明显优势。
- 3) XGBoost 控制器平均冲击率最低, 为 0.0810 m/s^3 , 运行平稳性优于 PID 控制器和经验规则控制器, 并在运行时间、停车精度和舒适度约束下取得了较好的节能效果。
- 4) 经验规则控制器运行时间最短, 为 115.40 s, PID 控制器能量回收率最高, 达到 79.28%, XGBoost 控制器在停车精度方面仍有进一步提升空间。
- 5) 综合来看, 在统一约束条件和有限线路仿真场景下, XGBoost 控制器相较于传统反馈控制和经验规则控制表现出较好的节能性和平稳性, 能够在一定程度上减弱对人工规则设计和控制参数反复整定的依赖。宋家庄补充场景结果进一步表明, 该方法在复杂线路条件下仍具有一定节能潜力, 但终点停车精度和跨线路适应性仍需进一步提升。后续将结合更多线路场景、不同站间距条件和实测运行数据, 对所提方法的泛化能力和工程适用性进行进一步验证。

参考文献

- [1] 余祖俊, 王洪伟, 王悉, 等. 轨道交通自主运行控制技术综述[J]. 北京交通大学学报, 2025, 49(5): 6-33.
- [2] 高豪, 张亚东, 郭进, 李科宏. 基于动态规划的列车节能运行两阶段优化方法[J]. 西南交通大学学报, 2020, 55(5): 946-954.
- [3] 冉昕晨, 陈绍宽, 柏赞, 等. 应对潮汐客流的城市轨道交通列车节能和乘客节时运行图优化模型[J]. 中国铁道科学, 2022, 43(1): 171-181.
- [4] De Martinis, V. and Corman, F. (2018) Data-Driven Perspectives for Energy Efficient Operations in Railway Systems: Current Practices and Future Opportunities. *Transportation Research Part C: Emerging Technologies*, **95**, 679-697. <https://doi.org/10.1016/j.trc.2018.08.008>
- [5] Wang, P. and Goverde, R.M.P. (2019) Multi-Train Trajectory Optimization for Energy-Efficient Timetabling. *European Journal of Operational Research*, **272**, 621-635. <https://doi.org/10.1016/j.ejor.2018.06.034>
- [6] Zhang, H., Jia, L., Wang, L. and Xu, X. (2019) Energy Consumption Optimization of Train Operation for Railway Systems: Algorithm Development and Real-World Case Study. *Journal of Cleaner Production*, **214**, 1024-1037. <https://doi.org/10.1016/j.jclepro.2019.01.023>
- [7] Huang, K., Wu, J., Yang, X., Gao, Z., Liu, F. and Zhu, Y. (2019) Discrete Train Speed Profile Optimization for Urban Rail Transit: A Data-Driven Model and Integrated Algorithms Based on Machine Learning. *Journal of Advanced Transportation*, **2019**, Article ID: 7258986. <https://doi.org/10.1155/2019/7258986>
- [8] Chen, T. and Guestrin, C. (2016) XGBoost: A Scalable Tree Boosting System. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, San Francisco, 13-17 August 2016, 785-794. <https://doi.org/10.1145/2939672.2939785>
- [9] Wang, X., Li, S., Su, S. and Tang, T. (2019) Robust Fuzzy Predictive Control for Automatic Train Regulation in High-Frequency Metro Lines. *IEEE Transactions on Fuzzy Systems*, **27**, 1295-1308.

- <https://doi.org/10.1109/tfuzz.2018.2877593>
- [10] Xun, J., Yin, J., Liu, R., Liu, F., Zhou, Y. and Tang, T. (2019) Cooperative Control of High-Speed Trains for Headway Regulation: A Self-Triggered Model Predictive Control Based Approach. *Transportation Research Part C: Emerging Technologies*, **102**, 106-120. <https://doi.org/10.1016/j.trc.2019.02.023>
 - [11] Su, S., Wang, X., Tang, T., Wang, G. and Cao, Y. (2021) Energy-Efficient Operation by Cooperative Control among Trains: A Multi-Agent Reinforcement Learning Approach. *Control Engineering Practice*, **116**, Article ID: 104901. <https://doi.org/10.1016/j.conengprac.2021.104901>
 - [12] Li, S., Liu, R., Gao, Z. and Yang, L. (2021) Integrated Train Dwell Time Regulation and Train Speed Profile Generation for Automatic Train Operations on High-Density Metro Lines: A Distributed Optimal Control Method. *Transportation Research Part B: Methodological*, **148**, 82-105. <https://doi.org/10.1016/j.trb.2021.04.009>
 - [13] Cheng, Y., Yin, J. and Yang, L. (2021) Robust Energy-Efficient Train Speed Profile Optimization in a Scenario-Based Position-Time-Speed Network. *Frontiers of Engineering Management*, **8**, 595-614. <https://doi.org/10.1007/s42524-021-0173-1>
 - [14] Shang, M., Zhou, Y. and Fujita, H. (2021) Deep Reinforcement Learning with Reference System to Handle Constraints for Energy-Efficient Train Control. *Information Sciences*, **570**, 708-721. <https://doi.org/10.1016/j.ins.2021.04.088>
 - [15] He, D., Zhang, L., Guo, S., Chen, Y., Shan, S. and Jian, H. (2021) Energy-Efficient Train Trajectory Optimization Based on Improved Differential Evolution Algorithm and Multi-Particle Model. *Journal of Cleaner Production*, **304**, Article ID: 127163. <https://doi.org/10.1016/j.jclepro.2021.127163>
 - [16] Li, J., Pan, F., Tang, H., Tong, S., Zhang, L., Li, X., *et al.* (2022) Energy-Saving Metro Train Timetable Optimization Method Based on a Dynamic Passenger Flow Distribution. *Journal of Advanced Transportation*, **2022**, Article ID: 9776845. <https://doi.org/10.1155/2022/9776845>
 - [17] Zhang, L., He, D., He, Y., Liu, B., Chen, Y. and Shan, S. (2022) Real-Time Energy Saving Optimization Method for Urban Rail Transit Train Timetable under Delay Condition. *Energy*, **258**, Article ID: 124853. <https://doi.org/10.1016/j.energy.2022.124853>
 - [18] Li, G., Or, S.W. and Chan, K.W. (2023) Intelligent Energy-Efficient Train Trajectory Optimization Approach Based on Supervised Reinforcement Learning for Urban Rail Transits. *IEEE Access*, **11**, 31508-31521. <https://doi.org/10.1109/access.2023.3261900>
 - [19] Xing, Z., Zhang, Z., Guo, J., Qin, Y. and Jia, L. (2023) Rail Train Operation Energy-Saving Optimization Based on Improved Brute-Force Search. *Applied Energy*, **330**, Article ID: 120345. <https://doi.org/10.1016/j.apenergy.2022.120345>
 - [20] Chen, Z., Li, S. and Yang, L. (2023) Hierarchical Optimal Control Framework to Automatic Train Regulation Combined with Energy-Efficient Speed Trajectory Calculation in Metro Lines. *Transportation Research Part C: Emerging Technologies*, **149**, Article ID: 104059. <https://doi.org/10.1016/j.trc.2023.104059>
 - [21] Yue, L., Liu, L., Li, M., Xiao, B. and Wu, X. (2023) Research on Text Fault Recognition for On-Board Equipment of a C3 Train Control System Based on an Integrated XGBoost Algorithm. *Transportation Safety and Environment*, **5**, tdac066. <https://doi.org/10.1093/tse/tdac066>
 - [22] Zhou, M., Hou, Z., Wu, X., Dong, H. and Wang, F. (2024) Integration of Train Regulation and Speed Profile Optimization Based on Feature Learning and Hybrid Search Algorithm. *IEEE Transactions on Computational Social Systems*, **11**, 2535-2544. <https://doi.org/10.1109/tcss.2023.3303473>
 - [23] Yuan, Y., Li, S., Yang, L. and Gao, Z. (2024) Nonlinear Model Predictive Control to Automatic Train Regulation of Metro System: An Exact Solution for Embedded Applications. *Automatica*, **162**, Article ID: 111533. <https://doi.org/10.1016/j.automatica.2024.111533>
 - [24] Li, S., Yuan, Y., Chen, Z., Yang, L. and Yu, C. (2024) Real-Time Train Regulation in the Metro System with Energy Storage Devices: An Efficient Decomposition Algorithm with Bound Contraction. *Transportation Research Part C: Emerging Technologies*, **159**, Article ID: 104493. <https://doi.org/10.1016/j.trc.2024.104493>
 - [25] Sun, Z., He, D., He, Y., Shan, S. and Zhou, J. (2024) A Bi-Objective Optimization Model of Metro Trains Considering Energy Conservation and Passenger Waiting Time. *Journal of Cleaner Production*, **437**, Article ID: 140427. <https://doi.org/10.1016/j.jclepro.2023.140427>
 - [26] Zhong, L., Xu, G. and Liu, W. (2024) Energy-Efficient and Demand-Driven Train Timetable Optimization with a Flexible Train Composition Mode. *Energy*, **305**, Article ID: 132183. <https://doi.org/10.1016/j.energy.2024.132183>
 - [27] Wang, Z., Quaglietta, E., Bartholomeus, M.G.P., Cunillera, A. and Goverde, R.M.P. (2025) Optimising Timing Points for Effective Automatic Train Operation. *Computers & Industrial Engineering*, **206**, Article ID: 111237. <https://doi.org/10.1016/j.cie.2025.111237>
 - [28] Lian, D., Chen, Z., Mo, P., Gao, Z., D'Ariano, A. and Yang, L. (2025) Energy-Efficient Multi-Curve Optimization in Urban Rail Transit: Stability Enhancement under Operational Uncertainties and Curve Adjustments. *Transportation Research Part C: Emerging Technologies*, **176**, Article ID: 105148. <https://doi.org/10.1016/j.trc.2025.105148>

-
- [29] Wang, D., Wu, J., Chang, X. and Yin, H. (2025) Distributed Multi-Agent Reinforcement Learning Approach for Energy-Saving Optimization under Disturbance Conditions. *Transportation Research Part E: Logistics and Transportation Review*, **200**, Article ID: 104180. <https://doi.org/10.1016/j.tre.2025.104180>
 - [30] Wang, D., Wu, J., Wei, Y., *et al.* (2024) Energy-Saving Operation in Urban Rail Transit: A Deep Reinforcement Learning Approach with Speed Optimization. *Travel Behaviour and Society*, **35**, Article ID: 100796.
 - [31] Wang, X., D'Ariano, A., Su, S. and Tang, T. (2023) Cooperative Train Control during the Power Supply Shortage in Metro System: A Multi-Agent Reinforcement Learning Approach. *Transportation Research Part B: Methodological*, **170**, 244-278. <https://doi.org/10.1016/j.trb.2023.02.015>