基于车辆和道路交通信息融合的电动重型载货汽车车速预测方法研究*

王朋[1] 雷雨龙[2] 阴晓峰[1] 卿辉红[3]

（1.西华大学汽车工程研究所，成都 610039；2.吉林大学汽车底盘集成与仿真全国重点实验室，长春 130000；3.四川英杰电气股份有限公司，德阳 618030）

【摘要】为了提高电动重型载货汽车的车速预测精度和工况适应性，提出了一种基于车辆和道路交通信息融合的车速预测方法。使用SUMO建立实际道路交通仿真模型获取车辆及道路交通信息，应用主成分分析法进行数据降维处理，根据贡献率选择车速预测模型的输入信息；设计基于径向基函数-线性回归融合的车速预测算法，利用滑动时间窗口更新预测模型。MATLAB和SUMO联合仿真验证结果表明：相较于单一车速信息，提出方法预测车速的平均均方根误差和平均绝对误差平均降低39.86%、40.48%，相较于反向传播神经网络（BPNN）平均降低40.30%、41.84%，相较于广义回归神经网络（GRNN）平均降低31.78 %、35.28%。最后，通过硬件在环仿真进一步验证了该方法的可部署性和实时性。

主题词：车速预测 神经网络算法 电动重型载货汽车 多源信息融合 硬件在环

中图分类号：U469.4 **文献标志码：**A **DOI:** 10.19620/j.cnki.1000-3703.20250787

Research on Speed Prediction Method for Electric Heavy-Duty Trucks Based on Vehicle-Road-Traffic Information Fusion

Wang Peng[1], Lei Yulong[2], Yin Xiaofeng[1], Qing Huihong[3]

（1. Institute of Automotive Engineering, Xihua University, Chengdu 610039; 2. National Key Laboratory of Automotive Chassis Integration and Simulation, Jilin University, Changchun 130000; 3. Sichuan Yingjie Electric Co., Ltd., Deyang 618030）

【Abstract】 To enhance the accuracy and adaptability of electric heavy-duty truck speed prediction under various operating conditions, a speed prediction method based on information fusion from vehicles-road-traffic is proposed. A real-road traffic simulation model is established using SUMO to acquire vehicle and road traffic data. Principal components analysis is applied for data dimensionality reduction, with input features for the speed prediction model selected based on contribution rates. A speed prediction algorithm integrating Radial Basis Function-Linear Regression is designed, utilizing a sliding time window to update the prediction model. Joint simulation results using MATLAB and SUMO demonstrate that, compared to using vehicle speed information alone, the proposed method reduces the mean root-mean-square error and mean absolute error in speed prediction by 39.86% and 40.48%, respectively; compared to backpropagation neural networks, the average reduction is 40.30% and 41.84%; compared to generalized regression neural networks, the average reduction is 31.78% and 35.28%. Through Hardware-in-the-Loop simulation, the deployability and real-time capability of the vehicle speed prediction method are further validated.

Key words: Vehicle speed prediction, Neural network algorithm, Electric heavy-duty truck, Multi-source information fusion, Hardware-in-the-Loop

【引用格式】 王朋, 雷雨龙, 阴晓峰, 等. 基于车辆和道路交通信息融合的电动重型载货汽车车速预测方法研究[J]. 汽车技术, 2026(4): 26-33.

WANG P, LEI Y L, YIN X F, et al. Research on Speed Prediction Method for Electric Heavy-Duty Trucks Based on Vehicle-Road-Traffic Information Fusion[J]. Automobile Technology, 2026(4): 26-33.

*基金项目：四川省自然科学基金重点项目（2024NSFSC0015）。

通信作者：阴晓峰（1972—），教授，主要研究方向为汽车智能驱动传动控制、V2X通信与控制、软件定义汽车技术，xfyin@139.com。

1 前言

电动重型载货汽车以电机驱动与能量高效管理为核心，深度耦合绿色能源体系，是公路运输减排的关键载体[1]。在其智能化控制策略开发中，车速预测技术受到广泛关注。该技术广泛应用于自动变速器挡位决策、安全辅助驾驶系统和预测控制策略等环节，对于车辆动力性、安全性和经济性的提升具有重要意义。

车速预测主要分为基于理论模型、基于机器学习和基于智能交通系统的方法[2]。其中，基于理论模型的车速预测方法常使用指数函数、自回归综合移动平均（Auto-Regressive Integrated Moving Average，ARIMA）模型等，此类方法在明确的数学逻辑基础上，具有模型结构清晰、易于工程实现等优点。Zhang等[3]假设驾驶员转矩需求在预测时域内呈指数下降，使用指数函数模型预测车速；解少博等[4]基于马尔可夫链模型计算转矩状态转移概率，得到不同预测时域长度下的预测车速；陈国强等[5]使用Python程序采集车速数据，并将车速时间序列进行分解，使用ARIMA模型进行车速预测。

基于机器学习的车速预测方法更加关注从历史数据中挖掘非线性关系，典型方法为神经网络、深度学习等。田韶鹏等[6]通过经验模态分解算法将车速时间序列在保持原来基本属性和特征的基础上进行分解，建立非线性自回归神经网络模型进行车速预测；张凯等[7]融合图卷积神经网络（Graph Convolutional Network，GCN）和双向长短期记忆（Bidirectional Long Short-Term Memory，BiLSTM）网络，引入变分模态分解（Variational Modal Decomposition，VMD）进行降噪处理；Du等[8]对比循环神经网络（Recurrent Neural Network，RNN）和长短期记忆（Long Short-Term Memory，LSTM）网络车速预测方法，发现LSTM能够选择性地对信息进行记忆和遗忘，比RNN具有更高的预测准确度。

随着智能交通系统（Intelligent Transportation System，ITS）、车联网（Vehicle-to-Everything，V2X）等技术的发展，基于智能交通系统的车速预测方法不再局限于单车历史数据，而是将车速预测与多源信息融合技术相结合，从而提高车速预测精度。Ye等[9]提出一种基于V2X通信的车速预测方法，使用深度学习网络建立车速预测模型，模型输入为目标车辆前30辆车的位置、速度和加速度，输出为目标车辆的速度和加速度；潘弄帅等[10]将驾驶意图、车间运动特征及工况历程特征信息作为多源信息输入，构建经遗传算法（Genetic Algorithm，GA）优化的反向传播神经网络（Back Propagation Neural Network，BPNN）预测模型；张战冰等[11]提出基于实时车速、交通流密度等交通信息的车速预测方法。

针对车速预测模型输入信息选取、预测精度和工况适应能力提升问题，本文使用主成分分析法（Principal Components Analysis，PCA）对多源信息进行降维处理，以确定影响车速的关键信息；采用基于径向基函数-线性回归（Radial Basis Function-Linear Regression，RBF-LR）融合的电动重型载货车汽车速预测算法，并通过MATLAB和SUMO联合仿真，以及硬件在环（Hardware-in-the-Loop，HiL）仿真，对该方法的有效性和实时性进行验证。

2 基于主成分分析的多源信息处理

2.1 多源信息获取

本文基于实际道路建立包含车辆、路网、信号灯等的交通系统模型[12]。通过MATLAB调用SUMO的交通控制接口（Traffic Control Interface，TraCI），获取反映车辆和道路交通信息时变特征的完整仿真路段数据，主要包括：

a. 自车信息：速度x_1、加速度x_2、加速度变化率x_3、加速踏板开度x_4、制动踏板开度x_5。

b. 最近前车信息：前车速度x_6、前车加速度x_7、前车距离x_8。

c. 交通环境信息：限速x_9、交通灯的距离x_{10}、交通灯剩余时间x_{11}、车辆密度x_{12}。

本文模拟成都市郫都区港大路三段至温江区骑士大道温泉大道三段实际路线，涵盖城市、高速和郊区3种典型道路，全长共计27.6 km，其中，城市道路8.9 km、高速道路7.5 km、郊区道路11.2 km。

在整条路段中随机生成轿车、载货汽车和公交车3种类型车辆，同时增加1条电动重型载货汽车车流，该类型车辆的最高车速达90 km/h，加、减速度分别为1.3 m/s^2、-3 m/s^2，车辆最小间隙为2.5 m。

2.2 信息降维处理

在选择信息时尽量减少数据处理量，采用PCA对车辆和道路交通多源信息进行降维处理，流程如图1所示。

将收集的多源信息标记为x_1~x_{12}，并进行标准化处理。假设存在n个样本，每个样本m个维度，可构成$n \times m$的样本矩阵$\boldsymbol{X}=\begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1m} \\ x_{21} & x_{22} & \cdots & x_{2m} \\ \vdots & \vdots & & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{nm} \end{bmatrix}$。

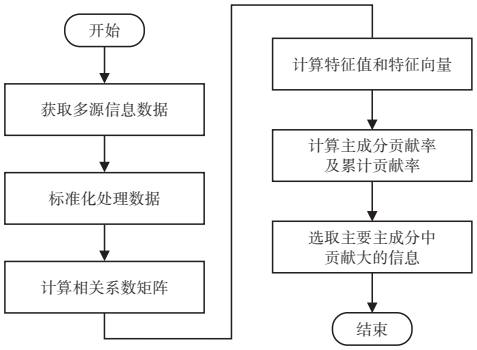


图1　降维处理流程

使用零-均值标准化方法处理数据：

$$z_{ij}=\frac{x_{ij}-\bar{x}_j}{S_j} \tag{1}$$

式中：x_{ij}为第i个样本在第j个维度的值，$\bar{x}_j$为按列计算的均值，S_j为标准差。

基于标准化后的数据构建相关系数矩阵：

$$\begin{cases}\boldsymbol{R}=\begin{bmatrix}r_{11} & r_{12} & \cdots & r_{1m}\\ r_{21} & r_{22} & \cdots & r_{2m}\\ \vdots & \vdots & & \vdots\\ r_{n1} & r_{n2} & \cdots & r_{nm}\end{bmatrix}\\ r_{ij}=\dfrac{\sum\limits_{k=1}^{n}(x_{ki}-\bar{x}_i)(x_{ki}-\bar{x}_j)}{\sqrt{\sum\limits_{k=1}^{n}(x_{ki}-\bar{x}_i)^2\sum\limits_{k=1}^{n}(x_{ki}-\bar{x}_j)^2}}\end{cases} \tag{2}$$

式中：r_{nm}为相关系数。

根据$\lambda\boldsymbol{I}-\boldsymbol{R}=0$求解相关系数矩阵的特征方程，得到$m$个非负特征值$\lambda_1$~$\lambda_m$和对应特征向量。计算主成分贡献率及累计贡献率，第$i$个主成分的贡献率为：

$$\beta_i=\frac{\lambda_i}{\sum\limits_{k=1}^{m}\lambda_k} \tag{3}$$

前i个主成分的累积贡献率为：

$$Z_i=\frac{\sum\limits_{j=1}^{i}\lambda_j}{\sum\limits_{k=1}^{m}\lambda_k} \tag{4}$$

将主成分按其贡献率从大到小排序，PCA统计结果如表1所示。其中，$a_i(i=1,2,\cdots,12)$表示各主成分，各主成分列与x_1~x_{12}对应的值为该主成分的特征向量。

由表1可知，前7个主成分的累计贡献率已达到84.52%，选取累计贡献率达到80%的主成分为主要主成分[13]，因此，本文使用前7个主成分，并根据贡献率确定各主成分的参数数量，依次为4个、3个、1个、1个、1个、1个、1个。依据特征向量中系数绝对值选择具体指标，最终确认将x_1、x_2、x_3、x_4、x_5、x_6、x_9、x_{10}、x_{11}、x_{12}作为本文车速预测模型的输入。

3　基于多源信息融合的车速预测方法

3.1　基于RBF-LR融合的车速预测算法

径向基函数（Radial Basis Function，RBF）神经网络为3层静态前馈神经网络，其结构如图2所示。在训练过程中，隐层神经元数量N根据设定的误差目标自动增加，所以该网络结构可在训练阶段自适应调整。RBF神经网络需要学习的参数有3个，分别为RBF的中心、宽度和连接权重。

表1　数据PCA处理结果

参数	a_1	a_2	a_3	a_4	a_5	a_6	a_7	a_8	a_9	a_{10}	a_{11}	a_{12}
x_1/km·h^{-1}	−0.401 6	−0.362 7	0.083 1	0.096 5	0.058 2	−0.025 2	−0.034 9	−0.098 5	−0.227 7	0.354 8	−0.705 9	−0.001 0
x_2/m·s^{-2}	−0.376 1	0.425 9	0.048 9	−0.041 1	0.144 7	0.021 8	0.000 4	−0.207 5	−0.173 2	−0.179 9	0.001 9	−0.739 1
x_3/m·s^{-3}	−0.125 8	0.270 1	0.286 8	−0.280 8	−0.690 8	−0.153 4	−0.368 6	0.248 1	−0.055 5	0.220 8	−0.010 8	0.003 9
x_4/%	−0.326 6	0.226 6	−0.283 2	0.095 1	0.308 0	−0.369 0	−0.279 1	0.414 3	−0.283 6	−0.276 4	−0.004 4	0.339 5
x_5/%	0.285 6	−0.407 6	−0.224 3	0.101 9	−0.003 9	−0.248 3	−0.166 5	0.505 2	0.053 7	0.075 9	0.002 4	−0.581 8
x_6/km·h^{-1}	−0.445 7	−0.291 5	0.095 4	0.110 8	0.080 7	−0.019 8	0.037 5	−0.007 4	−0.135 2	0.429 4	0.695 7	0.005 2
x_7/m·s^{-2}	−0.219 8	0.357 6	−0.035 1	0.124 5	0.088 0	0.019 80	0.443 8	0.421 9	0.546 8	0.328 2	−0.131 4	−0.000 1
x_8/m	−0.282 5	−0.216 0	−0.100 6	−0.449 8	0.189 4	−0.065 9	−0.410 8	−0.184 3	0.637 3	−0.109 5	0.001 7	0.001 6
x_9/km·h^{-1}	−0.233 0	−0.212 2	−0.326 8	−0.203 3	−0.426 5	−0.420 1	0.547 3	−0.130 3	−0.019 6	−0.277 5	0.013 2	−0.000 9
x_{10}/m	−0.181 5	−0.158 5	0.459 9	0.628 5	−0.186 4	−0.124 9	−0.085 8	−0.007 5	0.291 6	−0.438 9	0.004 4	−0.003 1
x_{11}/s	−0.107 9	0.112 8	−0.662 7	0.428 4	−0.351 0	0.293 6	−0.274 3	−0.208 8	0.105 6	0.115 9	0.011 4	−0.002 3
x_{12}/辆·m^{-1}	0.260 1	0.232 9	0.006 3	0.202 0	0.116 7	−0.702 9	−0.089 4	−0.431 6	0.108 3	0.351 5	0.001 8	0.003 3
特征值	3.006 3	2.678 4	1.077 4	1.029 5	0.847 0	0.800 8	0.702 4	0.664 1	0.577 5	0.534 4	0.076 3	0.005 8
贡献率	0.250 5	0.223 2	0.089 8	0.085 8	0.070 6	0.066 7	0.058 5	0.055 3	0.048 1	0.044 5	0.006 4	0.000 5
累计贡献率	0.250 5	0.473 7	0.563 5	0.649 3	0.719 9	0.786 6	0.845 2	0.900 5	0.948 6	0.993 2	0.999 5	1.000 0

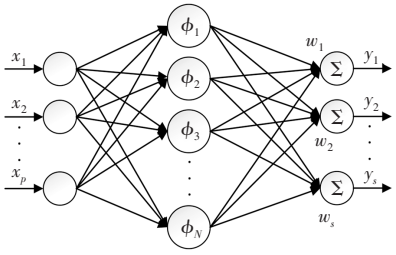


图2　RBF神经网络结构

由于线性回归（Linear Regression，LR）算法能够表示车速变化的整体线性趋势，RBF能在复杂交通环境下对自身车辆状态变化、前车扰动及道路工况变化引起的非线性特征进行拟合，因此，结合两者的优势，利用两种算法当前预测值和实际值的误差比例，使权重α根据当前时刻的预测偏差及时修正模型输出，从而提高车速预测精度以及模型对复杂工况的适应能力。故RBF-LR融合预测为：

$$\begin{cases} y_{\text{fusion}} = \alpha y_{\text{RBF}} + (1-\alpha) y_{\text{LIN}} \\ \alpha = \dfrac{E_{\text{LIN}}}{E_{\text{RBF}} + E_{\text{LIN}} + \varepsilon} \\ E_{\text{RBF}} = \| y_{\text{RBF}} - y_{\text{true}} \|_2 \\ E_{\text{LIN}} = \| y_{\text{LIN}} - y_{\text{true}} \|_2 \\ y_{\text{RBF}} = \sum\limits_{s=1}^{N} \boldsymbol{w}_s \phi_N(\boldsymbol{x}_p) \\ y_{\text{LIN}} = (\boldsymbol{x}_p^{\text{T}}, 1) b \end{cases} \tag{5}$$

式中：$\boldsymbol{x}_p$为模型输入向量，$\phi_N()$为第N个径向基核函数，$\boldsymbol{w}_s$为输出层权重，b为回归系数，y_{RBF}、y_{LIN}、y_{true}分别为RBF预测值、线性回归预测值和当前实际值，E_{RBF}、E_{LIN}分别为RBF预测值、线性回归预测值误差范数，$\varepsilon = 1 \times 10^{-6}$为防止分母为0的裕量，$\alpha$为RBF权重。

3.2　基于多源信息融合的车速预测

基于降维后的多源信息，采用RBF-LR融合算法进行车速预测，流程如图3所示。其中，D、P分别为预设训练时域长度和预测时域长度，d、p分别为实际训练时域长度和预测时域长度。

由图3可知，基于多源信息融合的车速预测主要分为2个阶段。其中，第一阶段（$t < D + P$）：

a. 设置$d = p = 1$。

b. 初始化多源信息数据集和训练样本矩阵。在t时刻初始化前一时刻的多源信息数据矩阵$\boldsymbol{V}_{t-1}$、训练样本输入矩阵$\boldsymbol{X}_{t-1}$和输出矩阵$\boldsymbol{Y}_{t-1}$：

$$\boldsymbol{V}_{t-1} = \begin{bmatrix} x_{1,t-d-p} & x_{2,t-d-p} & \cdots & x_{l,t-d-p} \\ x_{1,t-d-p+1} & x_{2,t-d-p+1} & \cdots & x_{l,t-d-p+1} \\ \vdots & \vdots & & \vdots \\ x_{1,t-1} & x_{2,t-1} & \cdots & x_{l,t-1} \end{bmatrix} \tag{6}$$

$$\boldsymbol{X}_{t-1} = \begin{bmatrix} x_{1,0} & \cdots & x_{1,d-1} & x_{2,0} & \cdots & x_{l,d-1} \\ x_{1,1} & \cdots & x_{1,d} & x_{2,1} & \cdots & x_{l,d} \\ \vdots & & \vdots & \vdots & & \vdots \\ x_{1,t-d-p} & \cdots & x_{1,t-p-1} & x_{2,t-d-p} & \cdots & x_{l,t-p-1} \end{bmatrix}^{\text{T}} \tag{7}$$

$$\boldsymbol{Y}_{t-1} = \begin{bmatrix} x_{1,d} & x_{1,d+1} & \cdots & x_{1,d+p-1} \\ x_{1,d+1} & x_{1,d+2} & \cdots & x_{1,d+p} \\ \vdots & \vdots & & \vdots \\ x_{1,t-p} & x_{1,t-p+1} & \cdots & x_{1,t-1} \end{bmatrix}^{\text{T}} \tag{8}$$

式中：l为降维后多源信息的维度，$x_{l,t-1}$为$(t-1)$时刻降维后第l个数据。

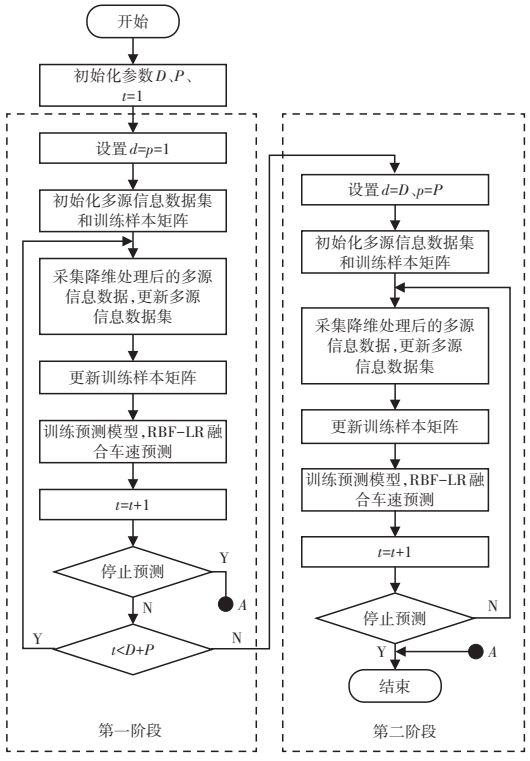


图3　车速预测流程

c. 采集t时刻降维后多源信息数据$x_{1,t}$~$x_{l,t}$，使用滑动时间窗口更新多源信息数据集，将当前t时刻的多源信息数据增至数据集最后一行，同时删除数据集第一行。更新后的数据集为$\boldsymbol{V}_t = \begin{bmatrix} x_{1,t-d-p+1} & x_{2,t-d-p+1} & \cdots & x_{l,t-d-p+1} \\ x_{1,t-d-p+2} & x_{2,t-d-p+2} & \cdots & x_{l,t-d-p+2} \\ \vdots & \vdots & & \vdots \\ x_{1,t} & x_{2,t} & \cdots & x_{l,t} \end{bmatrix}$。

d. 在更新后的多源信息数据集中提取新的训练样本输入向量$\boldsymbol{X}_{\text{in},t}$、输出向量$\boldsymbol{Y}_{\text{out},t}$，并将其分别置入前一时刻的训练样本输入矩阵$\boldsymbol{X}_{t-1}$、输出矩阵$\boldsymbol{Y}_{t-1}$的最后一列，得到当前时刻的输入矩阵$\boldsymbol{X}_t$、输出矩阵$\boldsymbol{Y}_t$，训练样本数量为$M = t - d - p + 1$：

$$\begin{aligned} \boldsymbol{X}_{\text{in},t} &= [\, x_{1,t-d-p+1} \quad \cdots \quad x_{1,t-p} \quad x_{2,t-d-p+1} \quad \cdots \quad x_{l,t-p} \,]^{\text{T}} \\ \boldsymbol{Y}_{\text{out},t} &= [\, x_{1,t-p+1} \quad x_{1,t-p+2} \quad \cdots \quad x_{1,t} \,]^{\text{T}} \end{aligned} \tag{9}$$

$$\boldsymbol{X}_t=\begin{bmatrix} x_{1,1} & \cdots & x_{1,d} & x_{2,1} & \cdots & x_{l,d} \\ x_{1,2} & \cdots & x_{1,d+1} & x_{2,2} & \cdots & x_{l,d+1} \\ \vdots & & \vdots & \vdots & & \vdots \\ x_{1,t-d-p+1} & \cdots & x_{1,t-p} & x_{2,t-d-p+1} & \cdots & x_{l,t-p} \end{bmatrix}^{\mathrm{T}} \tag{10}$$

$$\boldsymbol{Y}_t=\begin{bmatrix} x_{1,d+1} & x_{1,d+2} & \cdots & x_{1,d+p} \\ x_{1,d+2} & x_{1,d+3} & \cdots & x_{1,d+p+1} \\ \vdots & \vdots & & \vdots \\ x_{1,t-p+1} & x_{1,t-p+2} & \cdots & x_{1,t} \end{bmatrix}^{\mathrm{T}} \tag{11}$$

式中：$\boldsymbol{X}_{\mathrm{in},t}$为$l\times d$维向量，$\boldsymbol{Y}_{\mathrm{out},t}$为$p$维向量。

e. 使用更新后的训练样本对预测模型进行训练，以预测样本为$l\times d$维输入向量$\boldsymbol{X}_{p,t}$，使用更新后的预测模型预测未来p时刻的车速。

$$\boldsymbol{X}_{p,t}=[\,x_{1,t-d+1}\quad\cdots\quad x_{1,t}\quad x_{2,t-d+1}\quad\cdots\quad x_{l,t}\,]^{\mathrm{T}} \tag{12}$$

f. 更新$t=t+1$，并判断是否停止车速预测。若是，则停止车速预测，否则继续执行下一步。

g. 判断t是否小于$(D+P)$。若是，则返回步骤b，否则进入下一阶段。

第二阶段（$t\geqslant D+P$）：设置d=D、p=P，执行第一阶段步骤b。在执行第一阶段步骤c~e后，更新t=t+1，并判断是否停止车速预测：若是，则停止任务；否则返回执行第一阶段步骤c。

4 仿真分析

本文采用的联合仿真试验模型如图4所示，主要包括交通仿真模型和车速预测模型。通过TraCI接口更新SUMO的仿真时间，完成仿真软件时间同步后，获取SUMO的交通仿真模型数据。

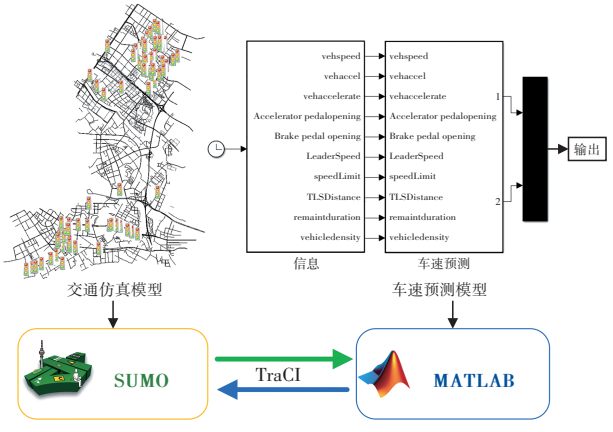


图4 联合仿真试验

4.1 时域长度对车速预测的影响

为了分析时域长度对车速预测精度的影响，使用不同D、P组合进行车速预测试验。由文献[14]可知，时域长度的选取需兼顾预测效果与计算代价，时域设置过大会增加模型训练与在线应用的复杂度。因此，本文采用$D\in\{2\text{ s},5\text{ s},10\text{ s},15\text{ s},20\text{ s}\}$、$P\in\{2\text{ s},4\text{ s},6\text{ s},8\text{ s},10\text{ s}\}$。

采用平均均方根误差[15]（Average Root Mean Squared Error，ARMSE）和平均绝对误差（Mean Absolute Error，MAE）作为评价指标：

$$\begin{cases} E_{\mathrm{ARMSE}}=\dfrac{1}{Q}\displaystyle\sum_{n=1}^{Q}E_{\mathrm{RMSE}} \\ E_{\mathrm{RMSE}}=\sqrt{\dfrac{\displaystyle\sum_{z=1}^{p}\left(v_{\mathrm{re}}(z)-v_{\mathrm{pr}}(z)\right)^2}{p}} \end{cases} \tag{13}$$

$$\begin{cases} E_{\mathrm{MAE}}=\dfrac{1}{Q}\displaystyle\sum_{n=1}^{Q}E \\ E=\dfrac{\displaystyle\sum_{z=1}^{p}\left|v_{\mathrm{re}}(z)-v_{\mathrm{pr}}(z)\right|}{p} \end{cases} \tag{14}$$

式中：$v_{\mathrm{re}}(z)$、$v_{\mathrm{pr}}(z)$分别为第z时刻的实际车速和预测车速，Q为预测总次数，E_{RMSE}、E分别为单次预测的均方根误差和平均绝对误差。

不同时域长度下，基于多源信息融合的电动重型载货汽车车速预测ARMSE和MAE结果如表2~表3所示。当D固定时，预测精度随着P的增加而下降；当P=2 s时，预测精度随着D的增加而下降，在$D>15$ s后预测精度无明显变化；当P取其他固定值时，预测精度随着D的增加而上升，在$D>5$ s后预测精度无明显变化。因此，在实际训练中需要合理选择训练和预测时域长度组合。

表2 不同时域长度车速预测的ARMSE

D/s	ARMSE/km·h^{-1}				
	P=2 s	P=4 s	P=6 s	P=8 s	P=10 s
2	1.964 8	3.777 8	5.896 1	8.216 6	10.572 7
5	2.104 3	3.644 9	5.481 6	7.440 8	9.205 7
10	2.290 4	3.991 9	5.707 6	7.533 9	9.128 5
15	2.437 0	4.016 2	5.686 6	7.475 4	9.067 5
20	2.398 9	4.082 1	5.984 6	7.754 0	9.275 5

表3 不同时域长度车速预测的MAE

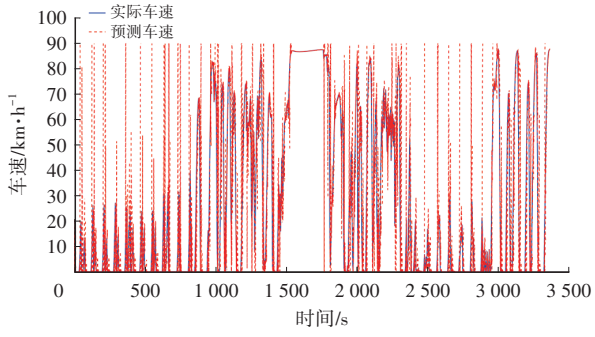
D/s	MAE/km·h^{-1}				
	P=2 s	P=4 s	P=6 s	P=8 s	P=10 s
2	1.819 6	3.313 2	5.041 0	6.889 4	8.782 4
5	1.959 4	3.197 3	4.656 8	6.218 7	7.649 8
10	2.150 6	3.563 2	4.930 0	6.410 2	7.691 3
15	2.286 9	3.578 3	4.940 8	6.410 9	7.694 5
20	2.247 6	3.647 2	5.235 4	6.704 3	7.934 9

4.2 联合仿真对比分析

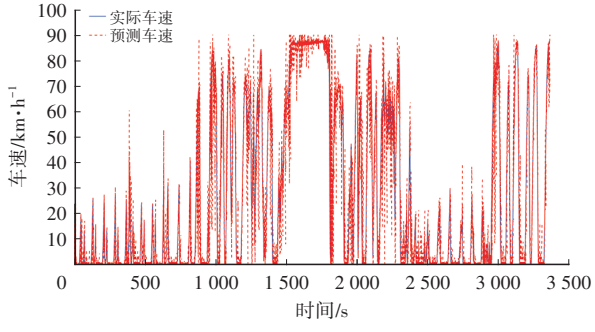
为了验证本文车速预测方法的有效性，与以单一车速信息作为模型输入的预测方法、基于BPNN多源信息

融合、广义回归神经网络（Generalized Regression Neural Network，GRNN）多源信息融合的车速预测方法进行对比试验。

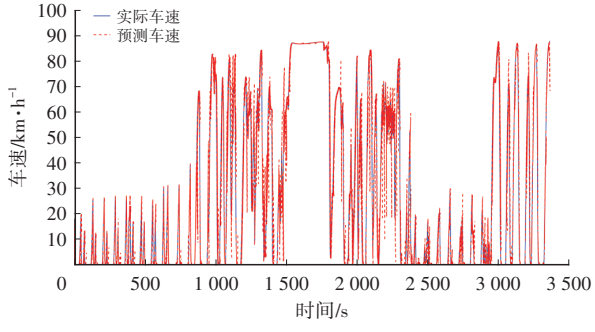
选取 D = 2 s、P = 2 s 和 D = 5 s、P = 4 s 的 2 种组合，使用由 SUMO 建立的实际道路路线中同一时段的车辆和道路交通信息，总时长为 3 372 s，包含城市、高速和郊区 3 种工况场景。在 D = 5 s、P = 4 s 的车速预测结果如图 5 所示。



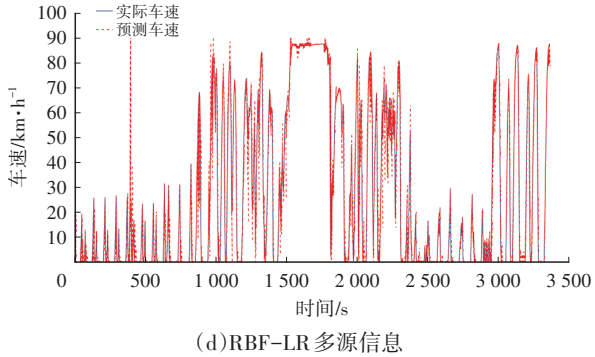
（a）单一车速信息



（b）BPNN 多源信息



（c）GRNN 多源信息



（d）RBF-LR 多源信息

图 5　不同方法的车速预测结果

由图 5 可知，基于单一车速信息的预测方法在车速变化较为急促时，容易出现预测车速突变的情况，而基于多源信息融合的预测方法的预测车速均接近实际车速。进一步统计预测误差，结果如表 4 所示。

表 4　预测结果误差统计　　km/h

方法	ARMSE		MAE	
	D = 2 s、P = 2 s	D = 5 s、P = 4 s	D = 2 s、P = 2 s	D = 5 s、P = 4 s
单一车速信息	2.730 4	7.544 0	2.533 6	6.770 1
BPNN 多源信息	4.157 6	5.051 9	3.967 4	4.538 5
GRNN 多源信息	3.249 7	4.796 7	3.165 8	4.442 9
RBF-LR 多源信息	1.964 8	3.64 49	1.819 6	3.197 3

由表 4 可知，相较于单一车速信息预测 RBF-LR 的 ARMSE 和 MAE 平均降低 39.86%、40.48%，相较于 BPNN 多源信息预测，RBF-LR 的 ARMSE 和 MAE 平均降低 40.30%、41.84%，相较于 GRNN 多源信息预测，RBF-LR 的 ARMSE 和 MAE 平均降低 31.78%、35.28%，表明本文方法能有效提高车速的预测精度。

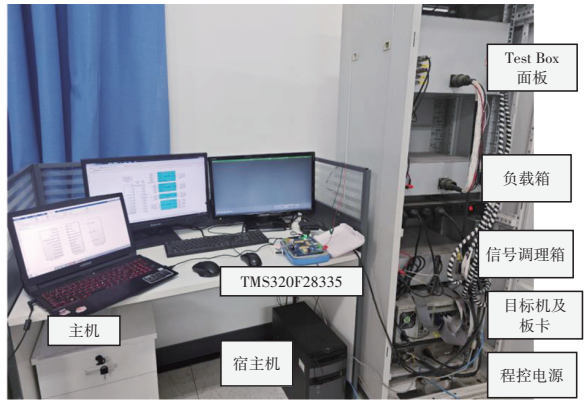
在 D = 2 s、P = 2 s 时，基于单一车速信息的预测方法预测精度略优于基于 BPNN 和 GRNN 的多源信息融合车速预测方法，主要源于在短时域内，车速信息自身相关性较强，多源信息的贡献有限，而在中长时域内，车速变化趋势更多由外部信息驱动，仅依靠车速信息无法准确预测未来车速变化，需要参考更多的信息来减少递推误差累计，故此时基于多源信息融合的车速预测方法精度更高。

4.3　硬件在环仿真验证

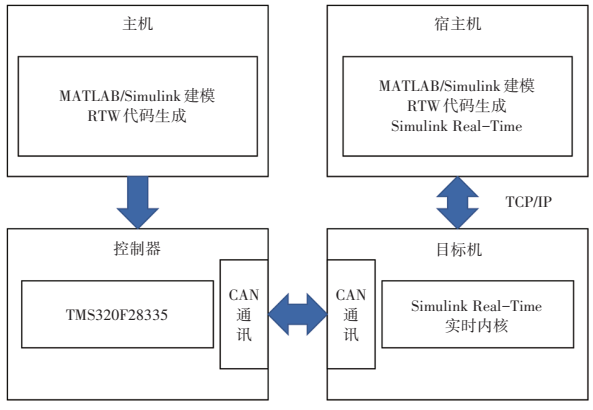
使用硬件在环仿真系统对车速预测方法的可部署性和实时性进行验证，系统结构如图 6 所示。HiL 仿真系统中宿主机使用 MATLAB/Simulink 对受控对象、多源信息数据和控制器局域网（Controller Area Network，CAN）模块进行建模，利用实时工作室（Real-Time Workshop，RTW）代码生成器将模型生成可执行代码并下载至目标机。主机同样对车速预测算法及 CAN 模块进行建模，将模型生成可执行的代码下载至以 TMS320F28335 为主控芯片的控制器。

使用 D = 5 s、P = 4 s 对本文方法进行可部署性和实时性仿真验证，结果如图 7 所示。本文方法的 ARMSE 和 MAE 分别为 3.573 6 km/h、3.280 8 km/h，与联合仿真结果基本一致，HiL 仿真的 ARMSE 增加 2.0%、MAE 降低 2.6%。预测车速和实际车速变化趋势基本吻

合，表明本文方法能够在实际控制器中部署，且满足实时性要求。



（a）实物图



（b）系统结构

图6　HiL测试环境

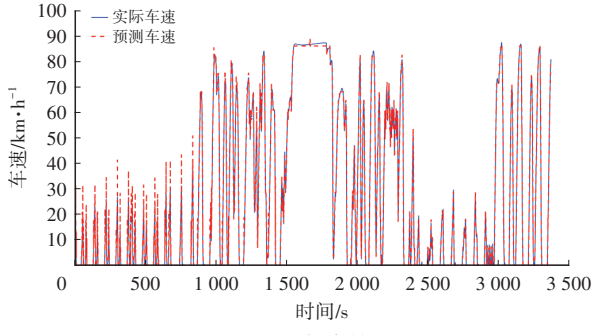


图7　HiL仿真结果

5　结束语

针对电动重型载货汽车车速预测中预测精度不足和工适应性较弱的问题，本文提出了一种基于车辆和道路交通信息融合的车速预测方法。通过主成分分析法对车辆和道路交通多源信息进行降维处理，设计了基于RBF-LR融合的电动重型载货汽车车速预测算法，分析了训练和预测时域长度对车速预测精度的影响。通过MATLAB和SUMO的联合仿真发现：相比于基于单一车速信息、基于BPNN多源信息、基于GRNN多源信息的车速预测算法，基于RBF-LR融合的车速预测算法能够有效提高预测精度。进一步通过硬件在环仿真，验证了本文所提出的方法能够部署至实际控制器，且满足实时性要求。后续研究将通过大量实际道路试验，丰富训练数据集，以提升模型的泛化能力。

参　考　文　献

[1] 支青鹿，郭娟丽，燕升飞. 新能源重卡换电在试点城市的发展路径研究[J]. 中国工程咨询，2024(2)：106-111.
ZHI Q L，GUO J L，YAN S F. Research on Development Pathways for Battery Swapping in New Energy Heavy Trucks in Pilot Cities[J]. China Engineering Consulting，2024(2)：106-111.

[2] 张子岩. 面向混动能量管理的自适应在线车速预测算法研究[D]. 杭州：浙江大学，2023.
ZHANG Z Y. Research on Adaptive Online Vehicle Velocity Prediction Algorithm for Hybrid Energy Management Strategy[D]. Hangzhou：Zhejiang University，2023.

[3] ZHANG S，XIONG R，SUN F C. Model Predictive Control for Power Management in a Plug-in Hybrid Electric Vehicle with a Hybrid Energy Storage System[J]. Applied Energy，2017，185：1654-1662.

[4] 解少博，刘通，李会灵，等. 基于马尔科夫链的并联PHEB预测型能量管理策略研究[J]. 汽车工程，2018，40(8)：871-877+911.
XIE S B，LIU T，LI H L，et al. A Study on Predictive Energy Management Strategy for a Plug-in Hybrid Electric Bus Based on Markov Chain[J]. Automotive Engineering，2018，40(08)：871-877+911.

[5] 陈国强，张道文，周凯. 基于高德地图API的路段车速预测研究[J]. 西华大学学报（自然科学版），2021，40(5)：35-41.
CHEN G Q，ZHANG D W，ZHOU K. Research on the Prediction of Road Speed Based on Amap API[J]. Journal of Xihua University (Natural Science Edition)，2021，40(5)：35-41.

[6] 田韶鹏，姜文琦，杨灿. 基于工况预测的PHEV自适应等效油耗最小策略[J]. 武汉理工大学学报，2023，45(6)：111-122+138.
TIAN S P，JIANG W Q，YANG C. Adaptive Equivalent Fuel Consumption Minimization Strategy for Phevs Based on Operating Condition Prediction[J]. Journal of Wuhan University of Technology，2023，45(6)：111-122+138.

[7] 张凯，卢海鹏，韩莹，等. 融合变分模态分解的时空卷积短时车速预测[J]. 系统仿真学报，2023，35(8)：1651-1660.
ZHANG K，LU H P，HAN Y，et al. Short-Term Vehicle Speed Prediction with Spatiotemporal Convolution Fused with Variational Modal Decomposition[J]. Journal of System Simulation，2023，35(8)：1651-1660.

[8] DU Y，CUI N X，LI H X，et al. The Vehicle's Velocity

Prediction Methods Based on RNN and LSTM Neural Network[C]// 2020 Chinese Control and Decision Conference (CCDC). Hefei, China: IEEE, 2020: 99-102.

[9] YE M, CHEN J, LI X, et al. Energy Management Strategy of a Hybrid Power System Based on V2X Vehicle Speed Prediction[J]. Sensors, 2021, 21(16).

[10] 潘龙帅，高建平，宋哲，等．多源信息融合的车速预测方法及整车能量管理[J]. 河南科技大学学报（自然科学版），2020, 41(6): 23-31+4-5.
PAN L S, GAO J P, SONG Z , et al. Vehicle Speed Prediction Method Based on Multi-Source Information Fusion and Whole-Vehicle Energy Management[J]. Journal of Henan University of Science and Technology (Natural Science Edition), 2020, 41(6): 23-31+4-5.

[11] 张冰战，朱昊，康谷峰，等．基于实时交通信息的PHEV模型预测控制策略研究[J]. 汽车技术，2023(9): 1-8.
ZHANG B Z, ZHU H, KANG G F, et al. Research on PHEV Model Predictive Control Strategy Based on Real-Time Traffic Information[J]. Automobile Technology, 2023(9): 1-8.

[12] 马小未．不确定性环境下智能车辆轨迹规划研究[D]. 长春：吉林大学，2023.
MA X W. Research on Trajectory Planning for Intelligent Vehicle in Uncertain Environments[D]. Changchun: Jilin University, 2023.

[13] JING Z C, WANG G L, ZHANG S P, et al. Building Tianjin Driving Cycle Based on Linear Discriminant Analysis[J]. Transportation Research Part D: Transport and Environment, 2017, 53: 78-87.

[14] LI Y C, HE H W, PENG J K. An Adaptive Online Prediction Method with Variable Prediction Horizon for Future Driving Cycle of the Vehicle[J]. IEEE Access, 2018, 6: 33062-33075.

[15] 侯珏．增程式电动汽车预测型能量管理策略研究[D]. 杭州：浙江大学，2022.
HOU J. Research on the Predictive Energy Management Strategy for Range Extended Electric Vehicles[D]. Hangzhou: Zhejiang University, 2022.

（责任编辑　瑞　秋）

修改稿收到日期为2026年1月1日。

《汽车工艺与材料》投稿须知

《汽车工艺与材料》于1986年创刊，是由中国第一汽车集团有限公司主办的国内外公开发行的汽车材料与制造技术类月刊，目前已入选《中文核心期刊要目总览》（第二版）、RCCSE中国准核心学术期刊（B+）、中国核心期刊（遴选）数据库、中国学术期刊综合评价数据库、欧洲学术出版中心数据库（EuroPub）、哥白尼精选期刊数据库（ICI Journals Master List）、EBSCO International数据库、J-Gate数据库。

《汽车工艺与材料》以“为中国报道汽车制造，为汽车引领工艺材料”为办刊宗旨，致力于报道以汽车轻量化技术和智能制造技术为核心的先进制造技术与材料应用技术，重点关注电动汽车蓄电池、电机、电控关键材料技术，燃料电池材料技术，高强度钢、铝镁合金、非金属材料及其成形技术，连接技术，智能装备与绿色制造等，以期通过高质量学术内容的出版和传播助推行业创新技术的交流与发展。

《汽车工艺与材料》杂志关注领先的整车及零部件企业和材料、装备等供应商，及时报道汽车行业最新的产品设计、制造、材料、加工技术、生产装备、检测技术等方面的成功案例。

主要栏目：

AT&M视界、生产现场、材料应用、生产装备、检测技术、数字化园地、行业动态等。

投稿要求：

（1）来稿须具有独创性并与实践相结合，文章字数最好控制在5 000～8 000字。

（2）来稿不能在国内、外公开杂志上发表过，请勿一稿多投。

（3）来稿的试验方法、试验数据、试验结论必须准确、可靠。

（4）来稿须包括以下项目：题名、作者姓名、作者单位、摘要（200字左右）、参考文献等。来稿采用word文档的格式。

（5）来稿文章格式应符合一般科技论文格式，或参考近期本刊所刊登文章格式。

（6）文章必须附有公开发表的、体现本领域最新研究成果的参考文献，且在文中应标注文献引用处。

（7）本刊使用网站投稿，投稿网址：http://qcgyycl.cbpt.cnki.net，咨询电话：0431-82026054。

竭诚欢迎汽车行业及相关各界的专家学者积极向本刊投稿。