

文章编号: 2095-2163(2022)06-0054-06

中图分类号: TP183

文献标志码: A

基于 BP-LSTM 组合神经网络模型的汽车车速预测

王维强, 于金泉, 周一鹤, 严运兵

(武汉大学汽车与交通工程学院, 武汉 430065)

摘要: 准确的汽车车速预测对整车能量分配、道路交通管理具有重要意义。针对汽车车速本身具有高度时变性以及单模型预测存在局限性的特点, 提出: 反向传播神经网络-长短期记忆网络(BP-LSTM)组合神经网络模型, 首先利用 BP 神经网络进行训练, 将训练集数据和得到的预测输出、残差输入到 Adam 算法优化的 LSTM 神经网络中, 用于训练 LSTM 模型。结合 BP 神经网络结构简单、预测时间短、LSTM 精度高的优点, 通过深度学习框架 Tensorflow 进行模型的搭建与验证, 实现基于 BP-LSTM 组合神经网络模型的短时车速预测。结果表明: 组合神经网络预测效果优于 BP、LSTM 两种单一模型, 预测精度得到改善。

关键词: 车速预测; 组合神经网络模型; BP 神经网络; LSTM 神经网络

Automobile speed prediction based on BP-LSTM combined neural network model

WANG Weiqiang, YU Jinquan, ZHOU Yihe, YAN Yunbing

(College of Automobile and Traffic Engineering, Wuhan University of Science and Technology, Wuhan 430065, China)

[Abstract] Accurate vehicle speed prediction is of great significance to vehicle energy distribution and road traffic management. In view of the high time-varying properties of the vehicle speed and the limitations of single model prediction, the paper proposes Back Propagation Neural Network-Long Short-term Memory Network (BP-LSTM) combined neural network model. First, the BP neural network is used for training. The collected data and the obtained prediction output and residual are input into the LSTM neural network optimized by Adam algorithm for training the LSTM model. Combining the advantages of simple BP network structure, short prediction time and high accuracy of LSTM, the model is built and verified through the deep learning framework Tensorflow to realize short-term vehicle speed prediction based on the BP-LSTM combined neural network model. The results show that the prediction effect of the combined neural network is better than the two single models of BP and LSTM, and the prediction accuracy is improved.

[Key words] speed prediction; combined neural network model; BP neural network; LSTM neural network

0 引言

随着智能交通出行的发展需求, 道路信息实时预测变得越来越重要, 神经网络通过自身学习为汽车车速预测提供了新的解决方案。汽车的能量管理策略可以结合神经网络、机器学习等方法对路况信息进行实时预测, 大大提高能量管理策略的效率, 改善发动机的工作区间, 优化整车能量分配, 降低故障发生率。如果提前预知汽车在未来时刻的行驶状态, 如车速、需求转矩等信息, 便能运用全局优化算法控制车辆性能达到一定时域内的最优状态^[1]。此外, 预测汽车未来车速, 可用于汽车路径导航、碰撞预警及节能辅助驾驶系统, 其研究具有重要的理论与应用价值^[2]。

近些年随着机器学习的发展, 不少学者使用基于数据驱动的方法对未来车速进行预测^[3]。牛超凡^[4]提出了基于 BP 神经网络的短期车速预测器, 实现车速的预测, 未考虑 BP 网络容易陷入局部极值的问题。楼挺^[5]设计了遗传算法优化的 LSTM 神经网络, 用于道路车速预测, 证明 LSTM 在解释时间序列的波动性上有明显优势。Epelbaum 等人^[6]融合多深度学习模型构建时间依赖的数据回归模型, 并将历史速度数据汇总到网络模型中, 实验结果表明该方法比单独的深度学习模型具有更好的准确性。韩少剑等人^[7]建立了混合深度学习的工况预测模型, 并利用 STL 分解算法实现对车速的预测。提升了车速预测的准确性, 但是由于结构复杂、算法繁琐, 大大增加了预测时间, 导致预测效率较低。

基金项目: 国家自然科学基金面上项目(51975428); 湖北省科技创新专项重点项目(2018AAA060); 中央引导地方科技发展专项(2018ZYYD027)。

作者简介: 王维强(1967-), 男, 副教授, 主要研究方向: 汽车新能源与节能技术; 于金泉(1996-), 男, 硕士研究生, 主要研究方向: 基于深度学习的混合动力汽车能量管理。

通讯作者: 于金泉 Email: wangwq03@163.com

收稿日期: 2021-12-24

单一模型的预测方法很难满足多方面的要求, 综合考虑预测精度和预测效率两方面因素, 本文提出了 BP-LSTM 组合神经网络模型。其中, BP 神经网络具有出色的非线性映射能力且结构简单, 模型训练时间较短, 将其放在组合神经网络模型的第一层。LSTM 揭示了时间序列的本质, 是处理时间序列数据的常用方法^[8], 将其放在第二层。训练集数据首先利用 BP 进行训练, 训练集数据和得到的残差序列输入到第二层 LSTM 网络中, Adam 算法优化 LSTM 网络的权值和阈值。把 2 种神经网络的优点结合起来, 降低了网络复杂度, 提高模型训练效率的同时, 增强预测精度。本文以东风华神 R401 纯电动载货汽车监测数据为基础, 利用深度学习框架 Tensorflow 进行模型的搭建与验证, 证明此组合神经网络模型预测精度优于 BP、LSTM 单模型, 对汽车车速预测有重大意义。

1 神经网络理论基础

1.1 BP 神经网络基本原理

BP 神经网络(Back Propagation Neural Network, BPNN)、即反向传播神经网络, 由输入层、隐藏层、输出层组成, 各层之间的神经元是全连接, 层内各个神经元无连接^[9], 网络结构如图 1 所示。

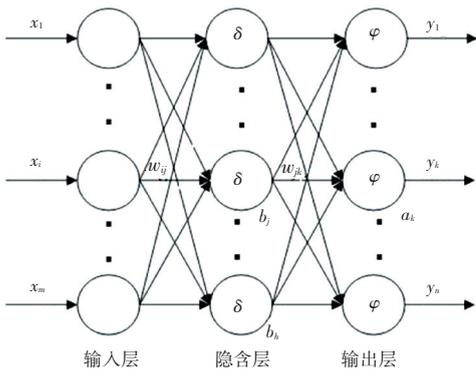


图 1 BP 神经网络结构

Fig. 1 BP neural network structure

在图 1 中, x_i 表示输入层第 i 个神经元的输入, $i = 1, 2, \dots, m$; w_{ij} 为输入层第 i 个神经元到隐含层第 j 个神经元的连接权值, $j = 1, 2, \dots, h$; 隐含层第 j 个神经元阈值记为 b_j ; 隐含层激活函数为 δ ; w_{jk} 为隐含层第 j 个神经元到输出层第 k 个神经元之间的权值, $k = 1, 2, \dots, n$, 输出层第 k 个神经元的阈值为 a_k , 输出层的激活函数为 φ ; y_k 为输出层第 k 个神经元输出。

BP 神经网络算法有正向传播、反向传播两个过程, 并利用梯度下降法, 通过反向传播来不断调整网络的权值和阈值, 使误差平方和最小。其原理和学

习过程如下。

(1) 正向传播过程。隐含层第 j 个神经元的输入 net_j 和输出 h_j 分别为:

$$net_j = \sum_{i=1}^n w_{ij}x_i + b_j \tag{1}$$

$$h_j = \delta(net_j) = \delta(\sum_{i=1}^n w_{ij}x_i + b_j) \tag{2}$$

输出层第 k 个神经元的输入 net_k 和输出 y_k 为:

$$net_k = \sum_{j=1}^h w_{jk}h_j + a_k = \sum_{j=1}^h w_{jk}\delta(\sum_{i=1}^n w_{ij}x_i + b_j) + a_k \tag{3}$$

$$y_k = \varphi(net_k) = \varphi[\sum_{j=1}^h w_{jk}\delta(\sum_{i=1}^n w_{ij}x_i + b_j) + a_k] \tag{4}$$

(2) 反向传播过程。得到输出层输出 y_k 后, 利用反向传播的思想来调整参数, 减少网络训练迭代次数, 提高模型训练准确性。对于每一个样本 p , 设其输出层第 k 个节点的期望输出为 T_k , 则此样本的二次型误差目标函数 E_p 为:

$$E_p = \frac{1}{2} \sum_{k=1}^n (T_k - y_k)^2 \tag{5}$$

定义损失函数 $cost(x)$, 可以表示为:

$$cost(w, b) = \frac{1}{N} \sum_{k=1}^N (wx_k + b - y_k)^2 \tag{6}$$

1.2 LSTM 神经网络

LSTM 通过控制缓存中的值保存的时间来记住更长期的信息, 有效解决了当连续数据的序列变长、反向传播更新参数时, 梯度消失或梯度爆炸等问题。其核心在于引入自循环的思想, 以产生梯度长时间持续流动的路径, 在处理与时序相关的问题上具有较好的效果。

LSTM 网络有输入门限、遗忘门限、输出门限三个门控单元, 网络结构如图 2 所示。

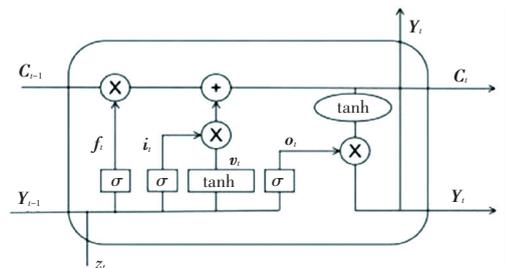


图 2 LSTM 神经网络结构

Fig. 2 LSTM neural network structure

由图 2 可知, LSTM 神经网络中各组成部分的设计功能拟做阐释与解析如下。

(1) 遗忘门 f_t : 决定哪些信息被遗忘, 哪些信息通过细胞状态。公式如下:

$$f_i = \sigma(W_f[Y_{i-1}, Z_i] + b_f) \quad (7)$$

其中, W_f 是遗忘门权重矩阵; Z_i 为当前时刻负载; b_f 表示偏置向量; σ 表示激活函数 *sigmoid*。

(2) 输入门 i_i : 通过激活函数来决定哪些值用来更新, 并保留到下个状态单元中。2 个神经元 i_i 和 v_i 计算公式如下:

$$i_i = \sigma(W_i[Y_{i-1}, Z_i] + b_i) \quad (8)$$

$$v_i = \tanh(W_j[Y_{i-1}, Z_i] + b_j) \quad (9)$$

其中, W_i 、 W_j 是输入门权重矩阵, b_i 和 b_j 为偏置向量。

生成更新后的神经元状态信息 C_i 的数学公式可写为如下形式:

$$C_i = f_i \cdot C_{i-1} + i_i \cdot v_i \quad (10)$$

(3) 输出门 o_i : 计算当前信息输出到下一时刻的程度, 决定着模型的输出。此处需用到的数学公式为:

$$o_i = \sigma(W_o[Y_{i-1}, Z_i] + b_o) \quad (11)$$

其中, W_o 为输出门权重矩阵, b_o 为偏差向量。

当前时刻神经元的输出 Y_i 可由如下数学公式计算求出:

$$Y_i = o_i \cdot \tanh(C_i) \quad (12)$$

2 组合神经网络模型设计

通过统计分析和大量的实验可以看出, 当前的道路交通状况对后续的交通状况有很大的影响, 并且连续时间段内的车速状况之间存在较强的时间序列关系^[10]。

2.1 模型设计

本文提出的组合模型网络结构有 2 层。第一层采用 BP 网络, BP 网络结构简单, 训练速度快, 能提高预测效率, 但是其在处理时间序列上精度不如 LSTM, 故模型第二层采用 LSTM, 并用 Adam 算法优化 LSTM。输入端接入 BP 神经网络, 预测输出和残差作为 LSTM 的输入, 在提高网络的非线性映射能力的同时降低过拟合的概率, 前一时刻的输出值参与下一时刻的计算, 增强对车速的识别与预测^[11]。本文设计研发的组合神经网络结构如图 3 所示。

图 3 中, z_{i1} 、 z_{i2} 表示 BP、LSTM 神经网络隐含层神经元, y_i 为 BP 网络输出层的神经元, y_i' 为预测残差, f_i 、 i_i 、 o_i 分别表示输入门、遗忘门、输出门, Y_i 为模型输出。

汽车行驶在同一工况时, 当下及未来一小段时间内汽车车速和前几个时间段的车速有关, 利用神经网络的自学习能力, 构建出组合神经网络模型, 忽

略紧急情况的影响。定义 Δt 为采集报文信号的时间间隔。

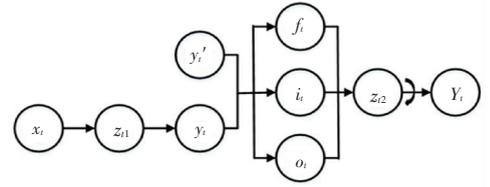


图 3 BP-LSTM 组合神经网络结构

Fig. 3 BP-LSTM combined neural network structure

令 Δt 为预测时间, v_i 为第 t 个时间间隔中采集到的车速信息, 车速序列可表示为:

$$V = (v_1, v_2, \dots, v_i)$$

记组合模型输入序列、输出序列分别为:

$$X = (x_1, x_2, \dots, x_i)$$

$$Y = (Y_1, Y_2, \dots, Y_i)$$

采集 10 min 内的车速数据, Δt 为 200 ms, ΔT 设置为 180 000 ms, 使用前 2 400 个数据对模型进行训练, 后 600 个数据对模型进行测试验证。这里的组合预测模型参数见表 1。

表 1 组合预测模型参数表

Tab. 1 Parameters table of combined prediction model

训练参数	参数值
BP 隐含层神经元数	36
LSTM 隐含层神经元数	24
Dropout	0.2
激活函数	<i>sigmoid</i>
迭代次数	60

2.2 基本原理

BP 神经网络模型接受来自训练集数据的输入, 通过梯度下降算法不断修正权值 w_{ij} 和阈值 b_i , 反复训练最后输出预测结果 y_i 和预测残差 y_i' , 二者共同输入到后端 LSTM 模型中, LSTM 再对输入进行训练, 其中 LSTM 模型内使用自适应矩估计 (Adaptive moment estimation Adam) 算法, 核心即是矩估计思想和动量衰减, Adam 通过计算梯度的一阶矩估计和二阶矩估计给不同的参数设计独立的自适应性学习率, 算法设计表述见如下。

1: 步长 ε 默认设置为 0.001

2: 矩估计的指数衰减率 ρ_1 和 ρ_2 分别设置为 0.9 和 0.999

3: 用于数值稳定的小常数 μ 设置为 10^{-8}

4: 初始化一阶和二阶矩变量 $s = 0, r = 0$

5: 初始化时间步 $t = 0$

6: while 没有达到停止标准 do

7: 从训练集采集包含 m 个样本 $\{x^{(1)}, \dots, x^{(m)}\}$

的小批量, 对应目标为 $y^{(i)}$

$$8: \text{梯度: } g = \frac{1}{m} \nabla_{\theta} \sum_i L(f(x^{(i)}; \theta), y^{(i)})$$

$$9: \text{更新有偏一阶矩估计: } s \leftarrow \rho_1 s + (1 - \rho_1) g$$

$$10: \text{偏一阶矩估计: } m_t = b_1 m_{t-1} + (1 - b_1) * g$$

$$11: \text{修正一阶矩的偏差: } m' = \frac{m_t}{1 - b_1^t}$$

$$12: \text{偏二阶矩估计: } v_t = b_2 v_{t-1} + (1 - b_2) * g * m'$$

$$13: \text{修正二阶矩的偏差: } v' = \frac{v_t}{1 - b_2^t}$$

$$14: \text{计算更新: } \theta_t = \theta_t - m'$$

$$15: \text{应用更新: } \theta \leftarrow \theta + \theta_t$$

16: End while

2.3 模型预测流程

综合预测精度、预测效率(以运行时间为准)两方面因素, 考虑 BP 神经网络和 LSTM 神经网络各自优势, 提出了 BP-LSTM 组合神经网络模型实现汽车车速预测, 预测流程如图 4 所示。对此, 文中给出研究详述如下。

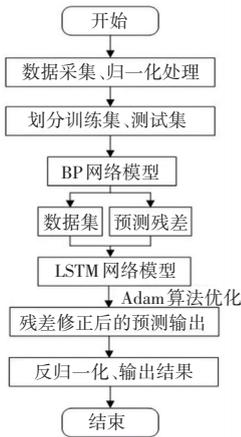


图 4 预测流程图

Fig. 4 Prediction flow chart

(1) 把采集到的数据进行数据增强、归一化处理, 然后把数据集随机分成并无交集的训练集、测试集, 各占 80%、20%, 最后 For 循环遍历整个训练集, 配成输入特征、输入标签对, 送入样本。

(2) Python 语言设计 BP 神经网络, 初始化权重、阈值, 输入训练集、测试集, 训练 BP 网络模型, 得到最优模型参数, 输出预测值和预测残差。

(3) 利用 Python 语言、深度学习框架 Tensorflow 进行 LSTM 神经网络模型搭建, 接收来自上一层 BP 神经网络的输入, 利用 LSTM 优化预测残差, 此处的 LSTM 神经网络中引入 Adam 算法。

(4) 最终的预测结果为 BP 网络预测结果加上 LSTM 修正后的预测残差。

3 仿真结果和分析

3.1 数据采样及预处理

对于汽车车速预测问题, 历史车速将作为最重要的输入, 因此汽车历史数据的采集对车速预测的准确性影响很大。为了验证汽车在频繁启停工况下车速连续变化时组合模型的准确性, 特采集东风华神 R401 纯电动载货汽车在连续急加速、急减速时的行驶信息, 收集到的信号根据 CAN 通信协议进行解码处理, 解码后的部分信息见表 2。

表 2 解码信息表

Tab. 2 Decoded information table

timestamp	Original data	Speed/(km · h ⁻¹)
27 075.1	00000154C	34
27 277.5	5EC25C29E	34
27 475.1	00000154C	34
27 675.2	00000154C	34
27 875.8	5EC25C29E	35

汽车车速数据具有波动性、复杂性, 数据预处理是以数据为驱动的机器学习算法应用中重要的环节^[12]。本文所使用的汽车车速数据, 不可避免地会出现一些异常数据, 对于这些数据, 要及时地调整、剔除。把剩下的数据和时序数据一一匹配, 此后经过清洗、归一化处理后得到增强数据集, 作为组合模型的输入数据。

3.2 模型训练环境及评价指标

BP-LSTM 组合模型使用 pycharm3.6、深度学习框架 Tensorflow2.7 实现模型的搭建, 利用 Anaconda 环境中 Keras、numpy 数据库训练模型。模型隐藏层神经元个数均是 128, 其中使用 Adam 优化器对 LSTM 进行优化, sigmoid 为激活函数。本次研究中搭建的环境设置是: 硬件设备为华硕 W519L; CPU 为酷睿 i5-5200U; 软件为 pycharm3.6。

为了客观准确地评价提出 BP-LSTM 网络结构对汽车车速的预测效果, 本文选定均方根误差 (RMSE) 和平均相对误差 (MAPE) 作为预测精度评价指标, 以模型学习、预测总时间衡量预测效率。本文给出的数学定义具体如下。

(1) 均方根误差 (RMSE)。指预测值与真实值偏差的平方和与观测次数 n 比值的平方根, 表征了预测的精确度。公式如下:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_{BP-LSTM}(t) - Y(t))^2} \quad (13)$$

(2)平均相对误差(MAPE)。表征了样本数据离散程度,公式如下:

$$MAPE = \frac{1}{n} \sum_{t=k+1}^{n+k} \frac{Y_{BP-LSTM}(t) - Y(t)}{Y(t)} \quad (14)$$

其中, $Y_{BP-LSTM}(t)$ 和 $Y(t)$ 分别表示 BP-LSTM 网络的预测车速和真实车速。

3.3 模型预测及对比分析

为了验证本文所提出的混合神经网络方法的有效性,将 BP-LSTM 组合神经网络预测结果分别和 BP、LSTM 神经网络算法进行结果对比分析,并通过均方根误差和平均相对误差两个评估指标的计算值来评判预测模型的性能。

采集报文信号的时间间隔 Δt 为 200 ms,取过去 10 min 的车速数据,共 3 000 个。预测时间间隔 ΔT 设定为 3 min,把上述数据输入到 BP 单模型中,得到的结果如图 5 所示。

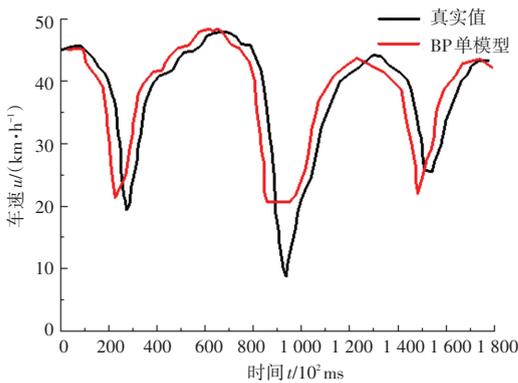


图 5 BP 神经网络预测结果

Fig. 5 BP neural network prediction results

由图 5 中可以看出,BP 模型预测结果反映了真实值的变化趋势,但是也存在较高的延迟,且对急剧变化时的车速不敏感。将同样的数据放进 LSTM 模型中,得到的预测结果如图 6 所示。

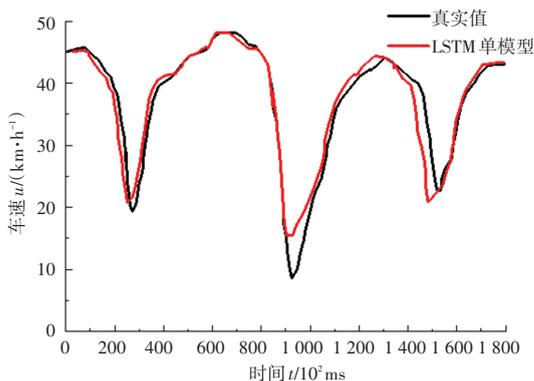


图 6 LSTM 模型预测结果

Fig. 6 LSTM neural network prediction results

由图 6 不难看出,LSTM 模型的预测结果相较于 BP 模型有了很大提升,二者拟合效果更好,在车速呈近似线性变化时效果最理想,但在车速变化呈非线性时仍有提升空间,而且在车速最低、且急剧变化时预测效果不理想。针对此现象,根据组合神经网络模型设计思路,把相同的数据输入到 BP-LSTM 组合神经网络模型中,得到的预测结果见图 7,损失结果见图 8。

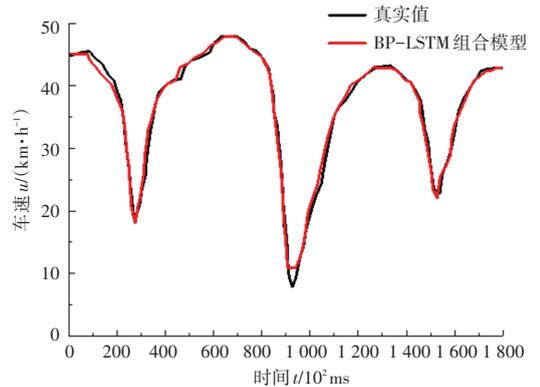


图 7 BP-LSTM 模型预测结果

Fig. 7 BP-LSTM neural network prediction results

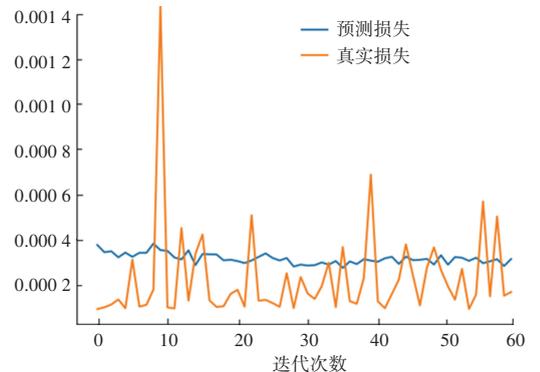


图 8 BP-LSTM 模型预测损失结果

Fig. 8 BP-LSTM neural network prediction loss results

从图 7 中可以看出,组合模型在预测精度上表现得比前 2 种单模型要好,预测的车速拟合了真实车速的变化趋势。从图 8 中可以看到,真实数据损失大多一直处在 0.000 2 和 0.000 6 之间,迭代次数为 10 次时,真实损失突然升高。随着迭代次数的增加,预测损失一直在 0.004 范围,基本上保持不变。预测误差始终在一较低范围浮动,也说明了组合神经网络模型在预测车速方面的准确性和稳定性。

3 种模型的预测误差指标和组合神经网络模型相比于 2 种单模型的预测指标降低百分比则详见表 3、表 4。

表 3 3 种模型预测结果对比

Tab. 3 Comparison of prediction results of the three models

模型	均方根误差 (RMSE)	平均相对误差 (MAPE)	TIME /s
BP	0.746 92	0.556 54	58
LSTM	0.602 84	0.432 42	70
BP-LSTM	0.489 25	0.399 76	74

表 4 组合神经网络预测指标降低百分比

Tab. 4 Percentage reduction in combined neural network predictors %

基准	BP	LSTM
RMSE 降低百分比	34.498	18.842
MAPE 降低百分比	28.171	7.553

由表 3 中可以看出, BP-LSTM 组合模型的预测结果与实际车速数据二者之间的均方根误差 RMSE 为 0.489 25, 平均绝对误差 MAPE 为 0.399 76, 远远小于 BP、LSTM 的误差数值。误差在可接受范围内, 反映了汽车未来 3 min 内的趋势, 准确完成了车速预测。组合神经网络预测模型用的时间长于 2 种单模型, 但是用时增加的百分比低于精度提升的百分比。此外, 根据表 4 可知, 组合模型在均方根误差、平均相对误差上相比 BP 单模型分别降低了 34.498% 和 28.171%; 相比于 LSTM 模型分别降低了 18.842%、7.553%, 预测精度得到明显提高。

3.4 对比实验及分析

为了说明组合模型的可适用性, 使用另外一种数据集验证仿真, 采集报文信号的时间间隔 Δt 为 200 ms, 取过去 10 min 的车速数据, 共 3 000 个。预测时间间隔 ΔT 设定为 3 min, 把上述数据输入到 BP-LSTM 模型中, 误差损失曲线如图 9 所示。

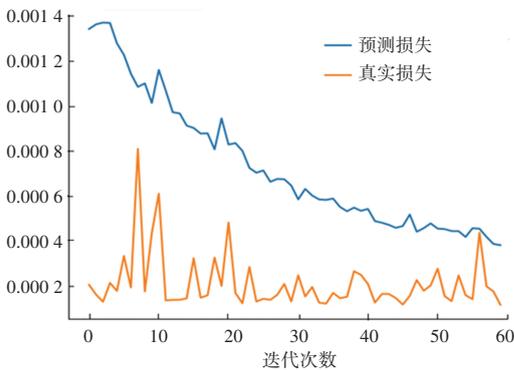


图 9 BP-LSTM 模型预测损失结果

Fig. 9 BP-LSTM neural network prediction loss results

从图 9 可以看到, 真实数据损失一直处在 0.000 2 和 0.000 4 之间, 随着迭代次数的增加, 预测损失在逐步下降, 最终接近于真实数据损失。刚开始预测损失较高的原因可能是出现了过拟合现象, 随着 BP 神经网络模型不断迭代和 LSTM 神经网络模型对预测残差的不断优化, 使得预测误差逐步减小, 最终和真实损失误差一致。

4 结束语

综上所述, 通过建立 BP、LSTM、BP-LSTM 三种神经网络模型, 利用 Python 语言实现对应算法, 对不同数据集进行仿真分析和对比验证, 得出本文提出的 BP-LSTM 组合神经网络模型相较于单一模型, 在预测精度、训练稳定性上有较大的提高, 使用不同的数据集, 也能保证预测误差在一较小范围内, 提出的 BP-LSTM 组合神经网络模型在汽车车速预测方面具有更高的准确度。

参考文献

- [1] ZENG Xiangrui, WANG Junming. A parallel hybrid electric vehicle energy management strategy using stochastic model predictive control with road grade preview[J]. IEEE Transactions on Control Systems Technology, 2015, 23(6): 2416-2423.
- [2] 杨盼盼. 汽车未来行驶车速预测[D]. 重庆: 重庆大学, 2015.
- [3] 丁峰, 王伟达, 项昌乐, 等. 基于行驶工况分类的混合动力车辆速度预测方法与能量管理策略[J]. 汽车工程, 2017, 39(11): 1223-1231.
- [4] 牛超凡. 基于工况预测的燃料电池汽车能量管理策略研究[D]. 长春: 吉林大学, 2021.
- [5] 楼挺. 基于深度学习的道路车速预测模型研究[D]. 杭州: 浙江工业大学, 2019.
- [6] EPELBAUM T, GAMBOA F, LOUBES J M, et al. Deep learning applied to road traffic speed forecasting[J]. arXiv preprint arXiv: 1710.08266, 2017.
- [7] 韩少剑, 张凤奇, 任延飞, 等. 基于深度学习的混合动力汽车预测能量管理[J]. 中国公路学报, 2020, 33(08): 1-9.
- [8] GULLI A, PAL S. Deep learning with Leras[M]. Birming: Packt, 2017.
- [9] 谢浩. 基于 BP 神经网络及其优化算法的汽车车速预测[D]. 重庆: 重庆大学, 2014.
- [10] 张徽阳. 基于深度学习的道路车速预测算法的研究与实现[D]. 北京: 北京邮电大学, 2020.
- [11] 许宁, 徐昌荣. 改进型 LSTM 变形预测模型研究[J]. 江西理工大学学报, 2018, 39(05): 45-51.
- [12] 陈国涛, 滕欢. 基于混合神经网络深度学习的短期负荷预测[J]. 水电能源科学, 2020, 38(04): 193-196.