

“能量高效利用与管理”专栏

基于长短期记忆网络的城市轨道交通系统
通信延时补偿方法

黄子昊, 李红波, 张 超, 徐东昇

(中车株洲电力机车研究所有限公司, 湖南 株洲 412001)

摘 要: 城市轨道交通系统中会出现车地无线通信延时和丢包现象, 其影响列车能量管理系统的控制实现。为此, 文章利用 4G 无线模块采集不同司机在同一区间驾驶的 18 组列车功率数据并进行列车功率典型特征分析, 然后提出一种基于长短期记忆网络 (LSTM) 的列车功率实时滚动预测方法。该方法根据列车实时功率 (短期数据) 及其邻近时刻功率 (长期数据) 对功率进行预测, 有效提升了预测的准确度。通过 4G 通信试验, 文章计算了通信延时误差, 并与采用所提预测方法的计算结果进行对比。结果显示, 采用该预测算法后, 通信延时误差降低了 21.8%, 通信丢包误差降低了 25.8%~26.9%, 可提供更准确的实时列车数据参考, 使得实时改善能量流变得更为可行。

关键词: 通信延时补偿; 神经网络; 功率预测; 长短期记忆网络

中图分类号: TM714

文献标识码: A

文章编号: 2096-5427(2021)03-0008-06

doi:10.13889/j.issn.2096-5427.2021.03.002

A Method of Communication Delay Compensation for Urban Transit System
Based on Long-term and Short-term Memory

HUANG Zihao, LI Hongbo, ZHANG Chao, XU Dongsheng

(CRRC Zhuzhou Institute Co., Ltd., Zhuzhou, Hunan 412001, China)

Abstract: Communication delay and packet loss in train to ground wireless communication of urban rail transit system impedes the application of energy management system. 18 groups of train power data, in which drivers driving in the same section, are collected via 4G wireless communication. A real-time rolling load forecasting method based on long-term and short-term memory network (LSTM) is proposed after analyzing the train power data, which improves the prediction accuracy by forecasting the power based on real-time power (short-term data) and adjacent power (long-term data). After measuring the communication parameters in a 4G communication test, the communication delay induced error is calculated and compared with the prediction method. The result shows that the prediction algorithm can reduce communication delay induced error by 21.8% and packet loss induced error by 25.8% ~ 26.9%, which can provide more accurate real-time train power information and make real-time improvement for energy flow more feasible.

Keywords: communication delay compensation; neural network; load forecast; long-term and short-term memory network (LSTM)

0 引言

基于大数据的智慧能源系统目前已成为业界关

注的热点之一^[1-3]。能量管理系统通过对海量数据的采集、整理和分析, 提炼出能量管理策略, 以提高能量管理水平, 提升系统整体效益。为了进一步优化能源系统性能, 实现能量实时管理, 能源数据的实时性至关重要^[4-6]。当能量管理系统包含较多分散布置的设备时, 受物理距离影响, 中心控制系统接收设备能源数据时普遍存在通信延时现象。延时会劣化中心控

收稿日期: 2021-03-02

作者简介: 黄子昊 (1987—), 男, 博士, 高级工程师, 主要从事能源互联网系统研究和设计。

基金项目: 湖南省高新技术产业科技创新引领计划 (2020GK2073); 系列化中国标准地铁列车研制及试验

制系统的控制性能，其中闭环控制类功能对延时尤为敏感^[7]。通信系统的性能在极大程度上决定了能源管理系统能够实现的控制功能。

城市轨道交通（简称“城轨”）作为高能耗产业，急需引入能量管理系统来优化系统能耗。城轨能量管理系统通过数据采集与监控（supervisory control and data acquisition, SCADA）系统来监控地面设备能源数据，主要涉及地铁主变电站、牵引站和降压变电所等场所^[8-9]。列车通过车载网络通信系统实现不同车厢和设备间的数据互通和总集^[10-11]，之后再通过无线通信将数据传给地面^[12-14]。目前车地无线通信被广泛应用于列车运行调度、隧道及弓网检测等领域。但无线信号传输易受外界干扰，与有线通信相比，延时和丢包现象尤为突出^[15-16]。若在城轨能量管理系统中引入闭环控制，例如通过控制列车运行状态或能馈设备运行参数来改善能量流状态，那么车载数据的延时和丢包将会劣化能量管理算法效果，甚至会影响城轨能源系统的稳定运行。

列车功率曲线属于时间序列数据，在固定运行模式下存在一定规律，如牵引阶段速度较低时功率近似线性增加、惰行阶段功率平稳等，这是预测方法能用于通信延时补偿的基础。时间序列预测常采用统计回归模型，其差分原始序列数据后，再将序列表示为白噪声，与之前数据点移动、平均地组合；但差分操作丢失了数据绝对值，而列车功率绝对值隐含了当前列车运行模式这一重要信息，故统计回归模型不适合用于预测列车功率。神经网络可以逼近任意非线性函数，能够预测时间序列数据。列车瞬时功率与邻近时刻功率相关，因此本文提出一种基于长短期记忆网络（long-term and short-term memory network，LSTM）的神经网络列车功率在线预测方法，其利用预测时间点前的功率数据来预测列车功率。

1 基于 LSTM 的神经网络

基于 LSTM 的神经网络^[17]是一种改进型时间循环神经网络（recurrent neural network, RNN）算法，其拓扑是一条由数个相同神经元依次连接而成的链式网络。神经元基本结构中包含 3 个功能结构，即遗忘门、输入门和输出门，见图 1。图中， X_t 为 t 时刻神经元的时序数据输入； h_t 为 t 时刻神经元的时序数据输出； S_t 为输出状态记忆单元，用于传递历史信息。




图 1 LSTM 神经单元拓扑图

Fig. 1 Topology of LSTM neural unit

当神经元按时间顺序链式连接后， t 时刻神经元输入包括 $(t-1)$ 时刻神经元输出 $h_{(t-1)}$ 、输出状态记忆单元数据 $S_{(t-1)}$ 以及 X_t 。神经元遗忘门、输入门和输出门的输出分别如下：

$$\left. \begin{aligned} S_{(t-1),f} &= S_{(t-1)} \times \sigma(w_{f1}h_{(t-1)} + w_{f2}X_t + b_f) \\ S_{(t-1),i} &= \sigma(w_{i1}h_{(t-1)} + w_{i2}X_t + b_i) \times \tanh(w_{i3}h_{(t-1)} + w_{id}X_t + b_{i2}) \\ h_t &= \sigma(w_{o1}h_{(t-1)} + w_{o2}X_t + b_o) \times \tanh(w_{o3}S_t + b_{o2}) \end{aligned} \right\} (1)$$

式中： σ ——Sigmoid 函数，其输出范围为 $[0,1]$ ； w ——对应函数的权重； b ——对应函数的偏置；下标中， t 代表时刻， f 代表遗忘门， o 代表输出门。

$$\sigma(x) = \frac{1}{1 + e^{(-wx+b)}} \quad (2)$$

Sigmoid 函数用于控制信息的遗忘程度，其输出 1 表示信息全部流通，0 表示信息全部遗忘，介于 0 和 1 之间表示信息部分遗忘。LSTM 神经网络通过这种方式来实现信息的传递和遗忘。单个神经元中，遗忘门、输入门和输出门 Sigmoid 函数的参数分别控制这些门之间信息的遗忘程度。LSTM 神经网络通过多个神经元的链式连接，实现时序信号间的信息记忆通路。图 2 示出 3 层 LSTM 神经网络拓扑，其中圆圈代表 LSTM 神经单元。 t 时刻将 3 个连续时序信





图 2 LSTM 神经网络拓扑

Fig. 2 Topology of LSTM network


号 $X_{(t-2)}$, $X_{(t-1)}$ 和 X_t 依次输送至链式连接的输入层, 通过链式连接的隐藏层后, 输出层输出 $(t+1)$ 时刻的预测数据 $X_{(t+1)}$ 。

2 列车功率数据提取


本文的列车功率数据源于某市地铁现场试验。该试验共持续了3天, 期间每天安排一位司机驾驶列车在线路上往返运行6趟, 并利用4G无线通信模块进行车地通信。列车传动控制单元(driver control unit, DCU)模块通过4G通信模块每隔100 ms将当前列车实时功率数据发送给地面4G通信模块。图3示出连续3天司机每天在同一区间往返运行6趟的列车功率曲线(曲线间以开动时刻进行对齐)。为便于指代, 将18次试验按时序进行编号, 其中第一天司机a的试验编号为1~6, 第二天司机b的试验编号为7~12, 第三天司机c的试验编号为13~18。



(a) 司机 a 的试验



(b) 司机 b 的试验



(c) 司机 c 的试验

图3 列车3天的功率曲线
Fig. 3 Train power curves in 3 days

列车功率曲线大致可分为牵引阶段、惰行阶段和制动阶段。以司机a的试验为例, 其功率曲线具体如下:

(1) 牵引阶段。司机在零时刻将司控器控制手柄推至全牵引位, 列车进入牵引加速阶段, 其功率近似线性增加; 当列车运行速度逼近运行上限时, 司机减小牵引运行级位, 牵引功率下降。

(2) 惰行阶段。列车运行速度达到上限, 司机将司控器切换至惰行位。列车功率迅速降低到100 kW附近(具体功率范围主要由列车辅助用电决定, 同时受地形上下坡影响), 列车速度缓慢下降。

(3) 制动阶段。列车即将到站, 司机将司控器切换至制动位并调整制动级位, 直至列车平稳进站、完成停车。

由图3可以看出, 各司机的行驶习惯差异较大。如, 司机a开行时间最长, 司机c开行时间最短; 司机b和司机c在惰行期间通过短时间改变列车运行级位来对列车速度进行调整。

同一司机重复开行的列车功率曲线特性也存在差异。要求各位司机尽可能保持驾驶习惯不变, 在此前提下, 在总运行时间不超过120 s的行驶过程中, 同一司机在6次重复开行过程中制动起始时刻最大相差了10 s; 司机b和c的牵引、制动特性在不同的重复开行趟次中存在较大差异, 这是由于动态调整了列车运行级位所致。

纵观列车功率曲线, 除了因司机切换列车运行级位状态而导致的功率变化, 大部分时间列车功率大致保持平稳变化, 而这是对列车实施功率实时预测的可行性基础。

3 基于LSTM的预测模型设计

本节基于图2的LSTM网络拓扑来设计列车功率预测模型, 设计前先进行数据预处理和数据集设置。

3.1 数据预处理

为了消除不同数据间取值范围造成影响, 先对所有列车功率数据进行归一化处理:

$$P_{\text{norm}} = \frac{P - P_{\min}}{P_{\max} - P_{\min}} \quad (3)$$

式中: P_{norm} ——归一化功率; P ——功率原始数据; $P_{\min}$ ——功率最小值, 本文 $P_{\min} = -3\,200$ kW; $P_{\max}$ ——功率最大值, 本文 $P_{\max} = 4\,200$ kW。

3.2 数据集设置

数据集分为训练集、验证集和测试集。本文数据集包含了3位司机各重复6次共18组试验数据, 每组试验数据包含1 000多个连续时序数据。其中, 训练集采用第1, 2, 7, 8, 13组数据用于模型拟合训练; 验证集采用第14组数据, 用于评估训练模型的准确率, 以避免模型过拟合; 测试集采用剩余的12组数据, 用于评价模型性能。

由于列车功率在不同运行阶段下的绝对值相差较大。为了定量分析预测数据和实际数据的偏差程度, 本文采用代表归一化数据绝对误差的方均根误差(root mean square error, RMSE) δ 作为评价指标。

$$\delta = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2}$$

(4)

3.3 模型设计

本文基于 Keras 深度学习框架来搭建 LSTM 模型，其后台为 TensorFlow。LSTM 模型参数包括输入层神经元数量、隐藏层神经元数量、激活函数、损失函数和优化函数。

3.3.1 输入层神经元数量

预测采用连续输入 x 个点预测第 $(x+1)$ 点的滚动预测方法。为了确定输入层神经元个数 x 的取值，用训练集和验证集数据训练不同输入层神经元个数神经网络。不同输入层神经元的预测误差如图 4 所示。




图 4 预测模型输入点数和预测误差
Fig. 4 Input number of predictive model and predictive error

预测误差随着输入点数增加而减小，但若输入点数过多，输入数据中遇到信号丢包的概率也会增大；且当输入点数大于 3 后，预测误差区别不大，基本可认为处于同一水平，说明瞬时功率与该时刻前两点数据关系最大。综合考虑，本文采用输入 5 点预测第 6 点的预测方式。

3.3.2 隐藏层神经元数量

隐藏层神经元数量若过少，则无法提供足够的拟合能力；若过多，则训练时间长，容易引起过拟合。为防止模型无法为不同输入层神经元个数提供足够的拟合能力，在通过验证集防止过拟合的前提下，本文选择隐藏层神经元数量为 28，略大于经验公式的^[18]。

3.3.3 激活函数

激活函数采用双曲正切函数 tanh，其与 Sigmoid 函数曲线类似，但值域为 $(-1,1)$ ，且收敛速度比 Sigmoid 的更快^[19]。

3.3.4 损失函数

损失函数采用均方误差函数 (mean square error, MSE)。MSE 为 RMSE 的平方，两者均可用于评估误差，仅存在量纲区别，3.2 节采用 RMSE 是为了保持和列车功率的量纲一致。

3.3.5 优化函数

优化函数采用默认的 Adam 函数。

3.4 预测效果评估

预测效果评估包括 3 方面：通信参数指标、预测效果、掉包工况预测效果。


3.4.1 通信参数指标

预测算法用于补偿通信延时和解决丢包问题，只有明确通信延时和丢包指标后再评价预测效果，这样预测评估才有意义。为了模拟城市轨道交通跨城环境，通过 Ping 命令测试 2 个相距 40 km 的 4G 模块的通信情况。通信测试时，发送 760 个数据包，结果成功接收到 747 个数据包，丢失 13 个数据包，丢包率为 1.71%。Ping 命令最短耗时为 147 ms，最长耗时为 277 ms，平均耗时 175 ms。由于 Ping 命令是双方应答式通信，因此，可认为单向数据传输平均耗时约 87.5 ms。


车地实验时，车载 DCU 经传感器采样到数据包生成并发出、地面接收数据包并解析都需要额外的时间，且平均延时长于 87.5 ms。为了便于分析，将列车数据传输延时与采样时间保持一致，设为 100 ms，与本次列车试验数据采集间隔一致。列车连续发送 n 个数据点，当接收方接收第 $(n-1)$ 个数据点时，列车此时真实数据为第 n 点，延时误差为相邻数据点的差值。

3.4.2 预测效果

预测模型输出的列车功率数据和实际数据分别如图 5 和图 6 所示。可以看出，当列车功率特性平稳时，预测误差总体较小。列车功率存在突变点时，预测误差增大。列车状态切换时，预测数据在功率拐点处存在 1 个点的滞后。



(a) 实际功率和预测功率



(b) 功率预测误差

图 5 实际功率和预测功率及预测误差
Fig. 5 Actual and predictive power, predictive error




图6 实际功率和预测功率(局部)

Fig. 6 Actual and predictive power (partial enlarged view)

为了对比通信延时误差和预测误差,分别计算各次试验的延时误差和预测误差 RMSE (图7)。图7同时展示了司机驾驶行为对功率特性的影响。可以看出,司机a(试验序号1~6)的数据变化较为平缓,平均延时误差最小,预测优化效果较为稳定;司机b(试验序号7~12)的牵引加速曲线后半段差异较大,且惰行存在短时加速,平均延时误差高;司机c(试验序号13~18)的牵引加速曲线每次都存在较大差异,且牵引加速功率偏低,可通过后续惰行阶段的频繁加速来弥补。




图7 延时数据和预测数据 RMSE

Fig. 7 RMSE of delayed and predictive data

图7中,优化效果最差的为试验10和试验15,原始数据见图3(b)和图3(c)中实线。经查验,试验10惰行阶段50 s时刻附近存在多个超出正常惰行功率3倍的突变点;试验15在惰行阶段初期持续惰行20 s(超出正常惰行功率300 kW)和制动阶段都存在多次功率突变,劣化了预测效果。

由于训练数据参与了预测模型的训练,为公平起见,从结果中去除6组训练数据(试验序号1,2,7,8,13,14),得到的延时数据平均 RMSE 值为0.007 9,预测数据为0.006 2。换算为功率值,延时数据平均功率误差为58.73 kW,预测数据为45.88 kW。预测数据相对于延时数据误差改善了21.8%。

3.4.3 掉包工况预测效果

实际通信场景中,通信数据偶发掉包也是需要考

虑的问题。假设 n 时刻应当接收数据包 n ,若没有收到,则视为掉包。从延时的角度考虑,当前最新数据仍为之前时刻接收的数据包($n-1$),故掉包可以等效于增加一个数据包的延时。预测算法在掉包时,可将上一时刻的预测结果作为实际数据输入预测模型,对当前时刻数据进行滚动预测。

图8示出不同丢包点数下的预测数据和延时数据的 RMSE。当丢包点数分别为0,1和2时,等效通信延时分别为100 ms,200 ms和300 ms;延时误差随着丢包点数的增加而急剧上升,分别为58.73 kW,103.60 kW和146.99 kW;预测数据分别45.88 kW,75.70 kW和109.03 kW,相对于延时误差减小了21.8%,26.9%和25.8%。




图8 不同丢包点数下的预测数据和延时数据 RMSE

Fig. 8 RMSE of predictive and delayed data with different dropout points

4 结语

为弥补通信导致的延时和丢包误差,本文设计了一种基于LSTM的列车功率在线滚动预测方法,其通过控制列车运行状态、能馈设备运行参数或其他能源设备状态参数,提高城轨列车能量管理系统数据的实时性,实时改善能量流,提升能源系统整体效率,从而提高能量管理水平。采用该方法后,延时功率误差可降低21.8%~26.9%。

受限于城轨列车的现场试验条件,本文未能实地测量列车在不同线路位置时(高架、隧道)通信参数的差异,线路和乘客对实际通信的影响也有待进一步研究。后续将研究自动驾驶策略下列车功率的预测算法,并增加其他相关信息(如线路条件、列车速度和工况),以提高预测精度。

参考文献:

- [1] 许海涛,许春香,许少鹏.基于大数据的智慧能源管理系统研究[J].信息系统工程,2019(3):89-90.
- XU H T, XU C X, XU S P. Research on Smart Energy Management System based on Big Data[J]. China CIO News,

- 2019(3):89-90.
- [2] 郭荣, 张强, 陈家颖, 等. 基于大数据分析的综合智慧能源系统控制优化研究 [J]. 发电设备, 2020(6): 20-25.
GUO R, ZHANG Q, CHEN J Y, et al. Control Optimization of an Integrated Intelligent Energy System Based on Big Data Analysis[J]. Power Equipment, 2020(6): 20-25.
- [3] 朱治中, 夏昊锴. 基于 ICT 技术的智慧能源云平台的研究 [J]. 三峡大学学报 (自然科学版), 2017, 39(2): 98-102.
ZHU Y Z, XIA H K. Study of Smart Energy Cloud Platform that Based on ICT Technology[J]. Journal of China Three Gorges University(Natural Sciences), 2017, 39(2): 98-102.
- [4] 杨琪. 电力能源实时数据仓库系统研究与实现 [D]. 西安: 西安科技大学, 2012.
YANG Q. Research and Implementation of Real-time Data Warehouse System for Electrical Energy[D]. Shaanxi: Xi'an University of Science and Technology, 2012.
- [5] 祁乐, 唐健, 陈新和, 等. 新能源实时错误数据辨识与修正深度学习模型 [J]. 电网与清洁能源, 2020, 36(11): 19-29.
QI L, TANG J, CHEN X H, et al. New Energy Real-Time Error Data Identification and Correction Deep Learning Model[J]. Power System and Clean Energy, 2020, 36(11): 19-29.
- [6] 董华彪. 能源互联网大数据分析技术综述 [J]. 数码世界, 2017(11): 187.
- [7] KUN Z, MOUSTAFA C, LARS N. ICT Architecture Impact on Wide Area Monitoring and Control Systems' Reliability[J]. IEEE Transactions on Power Delivery, 2011, 26(4): 2801-2808.
- [8] 周伟. 城轨供电系统的 SCADA 系统应用研究 [J]. 科学与信息化, 2018(33): 123.
- [9] 戎喻. 电气化铁路牵引变电所综合自动化系统研究 [D]. 武汉: 华中科技大学, 2008.
RONG Y. The Research on Traction Substation Automation System of Electrified Railway[D]. Wuhan: Huazhong University of Science and Technology, 2008.
- [10] 戚小莎. 基于工业以太网的列车通信网络实时性算法研究 [D]. 长春: 长春工业大学, 2020.
QI X S. Research on Real-time Algorithms of Train Communication Network Based on Industrial Ethernet[D]. Changchun: Changchun University of Technology, 2020.
- [11] 代娇. 基于工业以太网的地铁列车通信网络实时性及仿真研究 [D]. 北京: 北京交通大学, 2016.
DAI J. Research on Real-time Performance and Simulation of Subway Train Communication Network Based on Industrial Ethernet[D]. Beijing: Beijing Jiaotong University, 2016.
- [12] 辛静. 基于 IEEE802.11n 的城市轨道交通车地通信研究 [D]. 兰州: 兰州交通大学, 2014.
XIN J. Research on Train-ground Communication in Urban Rail Transit Based on IEEE802.11n[D]. Lanzhou: Lanzhou Jiaotong University, 2014.
- [13] 戴克平, 张艳兵, 朱力, 等. 基于 LTE 的城市轨道交通车地通信综合承载系统 [J]. 都市快轨交通, 2016, 29(1): 69-74.
DONG K P, ZHANG Y B, ZHU L, et al. An Integrated LTE-based Urban Rail Train Ground Communication System[J]. Urban Rapid Rail Transit, 2016, 29(1): 69-74.
- [14] 林海香, 董昱. 无线 CBTC 系统车地通信方案研究 [J]. 兰州交通大学学报, 2010, 29(6): 124-128.
LIN H X, DONG Y. Scheme of Train-to-Wayside Communication for Wireless CBTC[J]. Journal of Lanzhou Jiaotong University, 2010, 29(6): 124-128.
- [15] 李伟, 唐涛, 王呈, 等. 无线通信延迟对城市轨道交通 CBTC 列车追踪间隔影响研究 [J]. 铁道学报, 2017, 39(7): 73-78.
LI W, TANG T, WANG C, et al. Research on Influence of Wireless Communication Delay on CBTC Train Headway of Urban Rail Transit System[J]. Journal of the China Railway Society, 2017, 39(7): 73-78.
- [16] 杜时勇. 基于通信的列车控制系统车地通信抗干扰措施 [J]. 铁路通信信号工程技术, 2015, 12(2): 54-58.
DU S Y. Anti-interference Measures for Train-Ground Communication of CBTC System[J]. Railway Signalling and Communication Engineering, 2015, 12(2): 54-58.
- [17] HOCHREITER S, SCHMIDHUBER J. Long Short-term Memory[J]. Neural Computation, 1999, 9(8): 1735-1780.
- [18] 蔡荣辉, 崔雨轩, 薛培静. 三层 BP 神经网络隐层节点数确定方法探究 [J]. 电脑与信息技术, 2017, 25(5): 29-33.
CAI R J, CUI Y X, XUE P J. Research on the Methods of Determining the Number of Hidden Nodes in Three-layer BP Neural Network[J]. Journal of Computer Science and Technology, 2017, 25(5): 29-33.
- [19] 宋怡臻. 基于时间序列与 LSTM 模型的经济预测研究 [D]. 成都: 西南交通大学, 2019.
SONG Y Z. Research on Prediction of Economic Based on Time Series and LSTM Model[D]. Chengdu: Southwest Jiaotong University, 2019.