

基于 Encoder-Decoder LSTM 的电梯制动滑移量预测方法研究

苏万斌¹,江叶峰¹,徐彪²,易灿灿²

(1. 嘉兴市特种设备检验检测院,浙江 嘉兴 314000; 2. 武汉科技大学,湖北 武汉 430081)

摘要: 电梯曳引系统的可靠性是电梯安全性能评估中的重要部分,紧急制动滑移量是其重要反映指标,对滑移量进行时序预测能有利保证电梯安全,具有重要意义。采用结合 Encoder-Decoder 的 LSTM 模型学习电梯紧急制动滑移量的增长过程,进行多步预测来获得未来区间内滑移预测数据。通过与 RNN 和 LSTM 模型预测结果的对比,表明 Encoder-Decoder LSTM 模型针对电梯紧急制动滑移量的预测具有较好的精度,可以作为电梯曳引能力评估的重要手段。

关键词: 电梯;LSTM;编码器-解码器;滑移量;时间序列;多步预测

中图分类号: TU857 **文献标志码:** A **文章编号:** 1671-5276(2022)06-0028-04

Research on Elevator Brake Slip Prediction Method Based on Encoder-Decoder LSTM

SU Wanbin¹, JIANG Yefeng¹, XU Biao², YI Cancan²

(1. Jiaxing Special Equipment Inspection and Testing Institute, Jiaxing 314000, China;

2. Wuhan University of Science and Technology, Wuhan 430081, China)

Abstract: The reliability of elevator traction system is important for elevator safety performance evaluation, and the emergency brake slip is an important indicator. Time series prediction of the slip amount can ensure elevator safety. Encoder-Decoder LSTM model is used to study the growth process of elevator emergency brake slip, and multi-step prediction is made to obtain the slip prediction data in the future interval. Compared with the prediction results of RNN and LSTM models, the Encoder-Decoder LSTM model has good accuracy in predicting elevator emergency brake slip, and can be applied as important means to evaluate elevator traction ability.

Keywords: elevator; LSTM; Encoder-Decoder; slip amount; time series; multi-step prediction

0 引言

电梯作为现今与国计民生息息相关的重要特种设备,已被我国广泛使用。截至 2020 年底,全国电梯的保有量为 786.55 万台。曳引式电梯作为最常见垂直运输设备,长时间使用后,电梯的曳引轮和钢丝绳之间会因为磨损等原因,使得电梯的曳引能力降低,而电梯曳引能力的下降是电梯事故的最主要原因之一^[1]。现今城市老旧电梯数量越来越多,曳引能力下降而造成电梯事故也愈发常见,因此实现对老旧电梯的曳引能力可靠性进行预测已是现今亟待解决的问题。

现有关于电梯曳引能力判断的研究主要有两种,一种为通过专门的装置对钢丝绳两端施加拉力,记录滞留工况下引起钢丝绳滑移所需的拉力;另一种是通过记录在空载上行制动时的钢丝绳滑移量,判断钢丝绳曳引轮系统的可靠性^[2-3]。在实际应用中,对钢丝绳施加牵引力以验证曳引能力成本较高,而通过测量电梯钢丝绳紧急制动的滑移量来反映钢丝绳曳引性能,具有操作简单、结果可靠、可量

化的优点,能很好地反映由于电梯老旧退化而导致的曳引能力降低趋势及由于维护而导致的曳引能力的回升趋势^[4-5]。因此,通过对钢丝绳滑移量的预测,可以有效反映一段时间内的电梯曳引系统曳引能力变化趋势^[6]。

电梯由于作为运输工具的特殊性,其滑移量具有非线性特征,且由于电梯有维修周期,电梯曳引能力会有周期性的回升。此外,由于电梯的特殊性,对电梯滑移数据的测量无法频繁进行,因此无法获得大量的数据样本量,这些都使得对电梯制动滑移量的预测变得非常困难。因此,本文采集并分析电梯每季度及年维护后的空载上行实验滑移量,利用基于时间序列特征的深度学习算法,实现对未来一年时间内的滑移量进行预测,并使用现有观测数据对理论方法进行可行性验证。

常用于时间序列分析的深度学习算法有 BP 神经网络、循环神经网络 RNN、长短期记忆网络 LSTM 等。BP 神经网络发展时间长,具有模型清晰、结构简单的特点,但却难以处理非线性问题^[7]。循环神经网络^[8] (recurrent neural network, RNN) 对序列的非线性特征进行学习具有一定优势,但在进行较长预测时,存在梯度消失和效果降

基金项目: 国家自然科学基金项目(51805382);2019 年浙江省省级市场监管科研计划项目(20190339);2020 年浙江省市场监管局质量技术监督基础建设项目(20200126)

第一作者简介: 苏万斌(1972—),男,浙江嘉兴人,高级工程师,本科,研究方向为特种设备检验检测技术。

低等问题,同时由于预测长期数据时,后期数据会因为前期预测的误差而造成预测精度降低。LSTM (long short-term memory) 神经网络可以看作是一类改进后 RNN,其优势是能够更好地学习序列长期的规律^[9-10],在交通流预测及股市预测等时序预测领域有较好的应用效果。LSTM 神经网络结构继承了 RNN 的链式循环结构,并且弥补了 RNN 在学习过程中对于长期数据效果下降的问题,在长间隔、非线性时间序列的预测方面有较好的效果^[11]。但作为 RNN 的改进版本,其同样无法解决多步预测时的误差累积问题。

针对单步预测导致的误差累积放大的问题,本文采用编码器-解码器 (Encoder-Decoder) 框架进行处理。Encoder-Decoder 结构^[12]在自然语言处理等领域有着出色的表现,编码器将序列信号压缩成一个受参数约束的固定维度语义向量,再通过解码器对该语义向量进行解析,并使用递归方式将预测结果反馈至网络中,实现单变量的多步预测,避免了单步预测所造成误差累积。基于此,本文采用 Encoder-Decoder LSTM 模型对电梯滑移量进行预测,并利用电梯滑移量实际观测数据对分析结果进行评价。

1 基于 Encoder-Decoder LSTM 模型的预测技术

1.1 LSTM 模型

LSTM 作为 RNN 的改进算法,其重要改进是通过增加遗忘门、输入门、输出门获得变化的自循环权重,以此避免 RNN 所面临的梯度消失问题。这使得 LSTM 可以在 RNN 效果的基础上记忆更长的时序信息,增加预测精度。LSTM 的单元结构如图 1 所示,每个 LSTM 单元中存在细胞 (cell) 用于描述单元当前状态,同时在单元中存在着 3 类控制门,即用于控制输入的输入门 (input gate),控制数据输出的输出门 (output gate) 及控制单元状态的遗忘门 (forget gate)^[13]。当控制门打开时,表示允许所有信息通过;当控制门关闭时,表示不允许任何信息通过。




图 1 LSTM 结构

遗忘门、输入门、输出门方程如下:

$$f_t = \sigma(\mathbf{W}_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

$$i_t = \sigma(\mathbf{W}_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$o_t = \sigma(\mathbf{W}_o \cdot [h_{t-1}, x_t] + b_o) \quad (3)$$

式中: b_f, b_i, b_o 分别为遗忘门、输入门、输出门的偏置; $\mathbf{W}_f, \mathbf{W}_i, \mathbf{W}_o$ 分别是遗忘门、输入门、输出门的权矩阵; σ 是 sigmoid 型激活函数。当前输入的单元状态 \tilde{c}_t ,当前时刻的

单元状态 c_t 的计算公式为

$$\tilde{c}_t = \tanh(\mathbf{W}_c \cdot [h_{t-1}, x_t] + b_c) \quad (4)$$

$$c_t = f_t c_{t-1} + i_t \tilde{c}_t \quad (5)$$

式中: \tanh 为激活函数; \mathbf{W}_c, b_c 分别是单元状态的权矩阵和偏置。当前网络的输出值 h_t 由下式计算:

$$h_t = o_t \cdot \tanh(c_t) \quad (6)$$

1.2 Encoder-Decoder 模型

Encoder-Decoder 模型,又叫做编码-解码模型,常被应用于 seq2seq 问题^[14],即根据一个输入序列 X 来生成另一输出序列 Y 。本文中运用其解决电梯滑移量的多步预测。编码过程是将输入序列转化成一个固定长度的向量;解码时再将所生成的语义向量转化成设定的输出序列。

本文使用 LSTM 作为编码层和解码层,组成 Encoder-Decoder LSTM 模型(图 2)。




图 2 Encoder-Decoder 模型结构

图 2 中的 h 代表编码端的隐含层状态, s 则代表解码端的隐含层状态。在编码阶段, h 为当前时刻的隐含层状态,由当前时间的输入 x 及上一时间的隐含层状态 h_{t-1} 计算得,公式为

$$h_t = f(h_{t-1}, x_t) \quad (7)$$

之后可将各时刻的隐含层状态汇总得到一个固定长度的中间语言向量 C :

$$C = L(h_1, h_2, h_3, \dots, h_n) \quad (8)$$

L 一般可以选用任一 RNN,本文选用 LSTM。解码阶段可以视为编码阶段的逆过程,解码器根据编码阶段生成的语义向量 C 及历史的的滑移数据序列 y 来预测之后的滑移数据。

$$y_t = \prod_{i=1}^T p(y_i | \{y_1, \dots, y_{i-1}\}, C) \quad (9)$$

Encoder-Decoder 作为一种深度学习框架,一般会搭配 RNN 一起使用,用于解决输入与输出不同时的问题,本文使用其来解决传统 LSTM 算法在多步时间序列,会由于前面预测值作为历史数据使用导致之后数据的误差越来越大,Encoder-Decoder 将时间序列表达为向量,并使用解码器对向量解读并预测,规避了该问题^[15]。

1.3 基于 Encoder-Decoder LSTM 模型的电梯滑移量预测方法

预测流程如图 3 所示。输入为已知的训练集数据,通过归一化以后,经过作为编码器的 LSTM 网络层,编码器将历史数据进行编码并生成固定长度语义向量。语义向量大小由隐含层大小决定,之后将语义向量输入同为 LSTM 网络层的解码器进行解码,返回多步的预测结果,实现单一变量数据的多步预测,其具体步骤如下。

数据采集:按每季度频率定期进行空载上行制动实验,采集电梯的制动滑移数据,在以年为单位进行维修后,收集维修前、维修后两段数据。

归一化:依照目标电梯的标准参数及国标要求,计算出空载上行制动实验允许最大滑移量,使用 min-max 标准化方法对滑移量历史数据进行归一化处理,使数据映射到[0,1]的区间。

Encoder 编码层:通过一个单层 LSTM 将输入单变量时间序列编码成一个语义向量,作为解码层的输入,语言向量长度由隐含层大小决定。

Decoder 解码层:通过一个单层 LSTM 对编码层输出的语义向量进行解码。

全连接层:通过全连接层将解码层输出转化成所需的多步预测结果。




图3 电梯滑移量预测模型结构

2 实验数据分析

通过专业曳引系统检测装置,将轮状采集器安装在试验机的钢丝绳与曳引轮上进行位移采集。采集电梯轿厢质量为1300kg,额定载重2000kg,曳引轮直径640mm,平衡系数0.48,传动系统减速比32,曳引比2,试验速度为额定速度1m/s,工况为空载上行紧急制动。本文使用采集的50组数据用于实验分析,并分别使用LSTM、RNN及Encoder-Decoder LSTM模型对数据进行预测,并对比3种模型的预测结果,验证所提方法的可靠性。

2.1 实验数据

实验所用电梯制动滑移数据,通过对某区域不同使用时长的多台同型号货梯进行空载上行制动实验,采集制动时电梯曳引轮位移、钢丝绳位移等数据,获得相同工况下每年5组,跨度10年的共50组电梯制动滑移数据,每年5组数据中,前4组为各季度测得滑移量,最后1组为常规维护后的滑移数据,滑移数据如图4所示。本文将50组数据分为2部分,使用前44组数据对模型进行训练,使用最后6组数据进行模型有效性的验证。




图4 电梯空载上行紧急制动滑移数据

2.2 数据预处理

本文使用 Min-Max 函数对采集的滑移量数据做归一化处理,通过将滑移量数据规约至[0,1]区间,提高各预测模型的收敛速度和预测能力。归一化公式为

$$x'_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (10)$$

式中: x_i 为原始数据; x'_i 为归一化后数据; x_{\max} 为采集数据中的最大值; x_{\min} 为采集数据中的最小值。

2.3 参数设置及指标选取

文中设置400个隐含单元并使用relu函数作为激活函数,MSE作为损失函数,Adam作为求解器。为防止训练中出现梯度爆炸,影响预测结果,将梯度阈值设置为1。模型设置初始学习率0.005,150轮训练后通过乘以因子0.2来降低学习率至0.0001。

为了能对各模型的预测结果准确性进行客观评价,分别对各模型预测结果计算其方均根误差(RMSE)与平均绝对误差(MAE)。通过比对进行评判, RMSE与MAE值越小,预测效果越好。

2.4 电梯紧急制动滑移量预测

图5为基于RNN模型的电梯滑移量预测结果。从图中可以看出,RNN模型计算得到的预测结果与实际数据趋势基本一致,但整体误差较大,预测值相较于真实值仍有不小差距。这是由于RNN模型在接受的输入时间序列过长时,模型将丧失学习到先前输入序列的信息,因而导致预测效果较差。模型预测结果的方均根误差及平均绝对误差经过计算为: $R_{EMS} = 0.0018$; $M_{AE} = 0.0016$ 。




图5 RNN预测结果

图6为基于LSTM的滑移量预测。可以看出整体预测效果好于RNN预测,但由于单步预测导致的误差累积,整体效果仍然不理想。虽然经过误差统计得出LSTM模型整体预测效果优于RNN模型,但由于滑移量是波动较大的数据,预测结果仍与实际值存在一定差距。这是由于LSTM模型本身在面对更长的输入序列时所存在的局限性造成的。模型预测结果的方均根误差及平均绝对误差经过计算为: $R_{EMS} = 0.00095272$; $M_{AE} = 0.0011$ 。

图7为基于Encoder-Decoder LSTM模型的电梯滑移量预测结果。通过前44组数据训练模型后,对后6组数据进行预测,发现Encoder-Decoder LSTM模型预测的结

果都明显优于上述两种方法,模型成功地从历史数据中学习出年滑移量变化趋势。经过理论计算,模型预测结果的方均根误差及平均绝对误差为: $R_{EMS} = 0.00071124$; $M_{AE} = 0.00077641$ 。




图6 LSTM 预测结果




图7 Encoder-Decoder LSTM 模型预测结果

最后,通过表1列出了不同时间序列预测方法对滑移量数据分析的效果。由表1可以看出,Encoder-Decoder LSTM模型在对电梯制动滑移量的预测上效果明显优于RNN及LSTM模型。Encoder-Decoder LSTM相较于LSTM的预测效果分别提高了25.4%和29.6%。由此可以说明,在单变量多步预测问题上,Encoder-Decoder LSTM模型有着更优于其他模型的效果,该模型能较好地解决电梯紧急制动滑移量的预测问题。

表1 对比预测结果评价指标

模型	R_{MSE}	M_{AE}
RNN	1.800×10^{-3}	1.600×10^{-3}
LSTM	0.953×10^{-3}	1.100×10^{-3}
Encoder-Decoder LSTM	0.711×10^{-3}	0.776×10^{-3}

3 结语

针对电梯曳引能力定量预测问题,本文在LSTM时间序列预测模型的基础上,结合Encoder-Decoder框架,解决了传统LSTM难以进行长期预测的问题,实现高精度的单变量多步预测。本文通过Encoder-Decoder LSTM模型对电梯制动滑移数据进行预测,预测结果的方均根误差 $R_{EMS} = 0.00071124$,平均绝对误差 $M_{AE} = 0.00077641$,这表明模型在单变量多步的电梯制动滑移数据的预测上可以达到较好效果,对于电梯曳引性能的可靠性预测具有一定的参考意义。

参考文献:

- [1] 陈建勋,林晓明,吴周立,等. 曳引轮槽磨损对电梯曳引能力的影响分析[J]. 中国特种设备安全,2019,35(10):14-19,24.
- [2] 陈本瑶,俞平,陈辉,等. 电梯曳引轮与钢丝绳之间滑移检测系统设计[J]. 中国特种设备安全,2020,36(12):89-93,111.
- [3] 潘林. 探讨曳引驱动电梯曳引能力的检验及判定分析[J]. 中国电梯,2019,30(19):37-39.
- [4] 沈永强,郑曲飞,李九海. 电梯紧急制动时曳引轮与钢丝绳之间打滑原因分析[J]. 特种设备安全技术,2020(6):35-37.
- [5] 何若泉,卢永根. 关于电梯曳引能力检验中钢丝绳滑移问题的定量分析[J]. 中国电梯,2004,15(22):24-25.
- [6] 王炎,常晓清,方良,等. 曳引钢丝绳制停滑移量的研究[J]. 中国电梯,2021,32(8):19-22,27.
- [7] 陈智雨,陆金桂. 基于ACO-BP神经网络的光伏系统发电功率预测[J]. 机械制造与自动化,2020,49(1):173-175,187.
- [8] 张子贤,李敏,苗红霞,等. 基于RNN的故障预测算法及在GIS上的应用[J]. 计算机测量与控制,2020,28(12):27-31,36.
- [9] 胡聿文. 基于优化LSTM模型的股票预测[J]. 计算机科学,2021,48(增刊1):151-157.
- [10] 王琦,赵静,胡磊,等. 基于机器学习LSTM网络的SO₂排放浓度预测[J]. 自动化与仪表,2021,36(7):77-80,85.
- [11] 程肇兰,张小强,梁越. 基于LSTM网络的铁路货运量预测[J]. 铁道学报,2020,42(11):15-21.
- [12] 宋良才,索贵龙,胡军涛,等. 基于注意力机制的Encoder-Decoder光伏发电预测模型[J]. 计算机与现代化,2020(9):112-117.
- [13] 李文静,王潇潇. 基于简化型LSTM神经网络的时间序列预测方法[J]. 北京工业大学学报,2021,47(5):480-488.
- [14] 杨永娇,唐亮亮. 一种基于深度Encoder-Decoder神经网络的智能电网数据服务器流量异常检测算法[J]. 计算机与现代化,2019(10):66-71.
- [15] 王博文,王景升,王统一,等. 基于长短时记忆网络的Encoder-Decoder多步交通流预测模型[J]. 重庆大学学报,2021,44(11):71-80.

收稿日期:2021-08-27