

DOI: 10.13382/j.jemi.B2104884

Encoder-Decoder LSTM 网络的输电 母排触点温度预测方法*

李振鹏^{1,2} 董明利^{1,2} 于明鑫^{1,2} 孟凡勇^{1,2} 张羽飞^{1,2}

(1. 北京信息科技大学光电测试技术及仪器教育部重点实验室 北京 100192;

2. 北京信息科技大学光纤传感与系统北京实验室 北京 100016)

摘要: 机场行李传送装置输电母排触点状态的观测,对减少机场行李传送装置意外停机、保障机场正常运营具有重要的意义。输电母排触点故障发生时往往伴随温度的上升,温度的变化能够直观反映输电母排触点状态。因此可以采用编码器-解码器长短期记忆网络(Encoder-Decoder LSTM)对输电母排触点进行温度预测。首先采用双向长短期记忆网络(Bi-LSTM)组成的编码器对母排触点的历史温度数据进行编码,再由长短期记忆网络(LSTM)组成的解码器预测输出输电母排触点未来一段时间的温度值。通过对国内某机场行李传送装置一个月的温度观测数据进行测试。实验结果表明采用 Encoder-Decoder LSTM 的时间序列预测方法优于传统的时间序列预测模型以及其他现有的深度学习预测模型。

关键词: 电力设备;温度预测;深度学习;光纤测温

中图分类号: TH17;TP183

文献标识码: A

国家标准学科分类代码: 460.40

Transmission busbar contact temperature prediction method for Encoder-Decoder LSTM networks

Li Zhenpeng^{1,2} Dong Mingli^{1,2} Yu Mingxin^{1,2} Meng Fanyong^{1,2} Zhang Yufei^{1,2}

(1. Key Laboratory of the Ministry of Education for Optoelectronic Measurement Technology and Instrument, Beijing Information Science & Technology University, Beijing 100192, China; 2. Beijing Laboratory of Optical Fiber Sensing and System, Beijing Information Science & Technology University, Beijing 100016, China)

Abstract: The observation of transmission busbar contact status of airport baggage transfer device is of great significance to reduce the unplanned stoppage of airport baggage transfer device and ensure the normal operation of airport. The temperature change can visually reflect the status of the transmission busbar contact, which is often accompanied by the rise of temperature when the transmission busbar contact failure occurs. Therefore, Encoder-Decoder LSTM can be used to predict the temperature of transmission bus contacts. First, an encoder composed of a bi-directional long and short-term memory network (Bi-LSTM) is used to encode the historical temperature data of the busbar contacts, then a decoder composed of a long and short-term memory network (LSTM) is used to predict the temperature value of the transmission busbar contacts for a future period. One month of temperature observation data of a domestic airport baggage conveyor is tested. The experimental results show that the time series prediction method using Encoder-Decoder LSTM outperforms the traditional time series prediction model as well as other existing deep learning prediction models.

Keywords: electric power equipment; temperature forecast; deep learning; optical fiber temperature measurement

0 引言

众所周知飞机航班发生延误可能造成严重的经济损失,甚至导致旅客与机场工作人员发生语言和肢体冲突。

航班延误的原因之一是机场行李传送装置的输电母排发生故障,导致旅客行李无法按时传送至行李转运车,造成飞机延误。机场行李传送装置受长期震动影响,容易造成输电母排触点螺栓松动,进而导致触点发生温度上升现象。一旦温度持续上升,极有可能发生输电母排断路

从而引起行李传送装置意外停机,影响机场的正常运行。所以对输电母排触点温度的测量和预测十分重要^[1-4]。

目前机场行李传送装置输电母排触点的维护方法主要采用人工巡检方式,现场维护人员利用红外测温仪对输电母排触点进行测量监控。然而,机场行李传送装置的输电母排长度从几公里到几十公里不等,且空间分布错综复杂,这对于现场的日常维护人员来说任务繁重,难以做到对母排上的每个触点进行检测。因此,本文提出采用光纤光栅温度传感器分别采集母排触点的温度,然后通过智能检测算法对输电母排各触点进行温度预测的方法,从而实现故障触点早期预警,保障机场行李传送装置安全运行。

近些年国内外学者在温度预测技术进行了大量研究,其研究方法主要分为基于统计模型的方法、基于机器学习的方法和基于深度学习的方法。基于统计模型的方法主要有自回归滑动平均模型(ARMA)^[5]、自回归积分滑动平均模型(ARIMA)^[6],其优点包括模型复杂度低、可解释性强、计算速度较快。对于行李传送装置采集的母排触点温度数据,由于航班频率不固定、装置负载多变等因素影响,导致输电母排触点温度数据呈现高度非线性特点。而基于统计模型的方法,本质上只能捕捉数据间的线性关系,因此这类方法针对母排节点温度数据难以建立非线性模型。基于机器学习的方法主要有支持向量回归模型(SVR)^[7]、多元线性回归模型(MLR)模型^[8-9]、回归决策树模型(RDT)^[10],该方法可以对非线性数据进行建模,实现温度的预测。为了更精准的预测输电母排触点温度,时间滑动窗口一般取值较大,以便深层次挖掘时间序列包含的隐藏特征。基于机器学习的方法需要手动构建特征工程,并且由于时间窗口往往取值较大,算法的复杂度也会呈现指数级增长,导致预测模型较难收敛。基于深度学习的方法主要有卷积神经网络(CNN)^[11-13]、循环神经网络(RNN)^[14-15]、长短期记忆网络(LSTM)^[16-19]。CNN模型利用一维卷积核,以一定的时间窗口大小在时间序列上滑动提取特征,有较好的函数逼近和泛化能力。RNN模型由于记忆门的存在,可以将时间序列的历史信息存储并传递给未来,对具有非线性特征的时间序列具有很好的学习能力,但是由于RNN存在梯度消失和梯度爆炸的问题,导致其仅具有短期记忆。LSTM模型由于特殊的存储单元设计,使其可以在更长的时间内记住输入的历史信息。该网络可以学习输入数据的长期依赖,记住更长时间的历史数据信息。编码器-解码器(Encoder-Decoder)是一种典型的序列到序列的模型,编码器可以将输入的高维度特征向量编码为定长的特征向量,解码器则负责对定长的特征向量解码还原,该模型最初应用于自然语言处理领域,后来也逐渐应用到时间预测领域,如曹阳等^[20]将基于Encoder-Decoder

LSTM模型与注意力机制相结合,在日交通流量预测问题中预测精度远高于传统模型和其他深度学习模型。对于具有高度非线性的输电母排触点温度数据,Encoder-Decoder LSTM模型可以更好的提取时间序列数据的非线性关系,捕捉时间序列的长时间依赖关系。

本文将Encoder-Decoder模型的思想与Bi-LSTM模型相结合,提出了一种Encoder-Decoder LSTM模型,用于预测机场行李传送装置的输电母排触点温度。首先利用光纤光栅温度传感器采集行李传送装置上输电母排触点的温度数据,然后利用数据可视化的方法对原始温度数据的缺失值和异常值查找定位并进行插值填充,接着利用Encoder-Decoder LSTM模型对输电母排触点温度进行预测。模型的编码器部分,采用双向长短期记忆网络代替传统的长短期记忆网络,双向长短期记忆网络从正向和逆向分别提取时间序列上下文特征信息,更充分地挖掘时间序列中的隐藏特征,正向和逆向的编码特征信息经过聚合作为模型解码器的输入,解码后的数据为模型预测的输电母排触点温度数据。本文提出的方法在国内某机场行李传送装置的运行数据上进行了测试,验证了方法的有效性,为保障机场行李传送装置输电母排的安全运行提供了方法与技术支撑。

1 数据采集与处理

1.1 数据采集

本文研究使用的数据集来自国内某机场行李传送装置输电母排触点的温度监测数据。

机场行李传送装置输电母排所处电磁环境恶劣,高电压、大电流产生强磁场,磁场会对电信号温度传感器产生影响。采用光纤光栅温度传感器可以避免磁场的干扰。同时光纤光栅传感器具有体积小、重量轻、多测量点、成本低等优势。因此选用光纤光栅温度传感器对输电母排触点进行温度数据采集。

机场行李传送装置的输电母排触点温度采集系统如图1所示。光纤光栅温度传感器通过粘贴的方式固定在输电母排触点,触点的温度变化作用在光纤光栅温度传感器,引起光纤光栅中心波长产生偏移,光纤光栅解调仪通过对中心波长偏移量进行检测,并根据标定系数计算得到监测位置的母排触点温度数据。光纤光栅解调仪通过以太网接口与工控机通信,将输电母排各触点温度数据通过上位机软件写入到工控机的MySQL数据库中,从而实现输电母排触点温度的全天候数据采集。本文研究使用的数据集来自国内某机场行李传送装置输电母排触点的温度监测数据。

光纤光栅传感器的布设共分为5个采集通道,总计118个温度监测点。实验所用数据集采用第2采集通

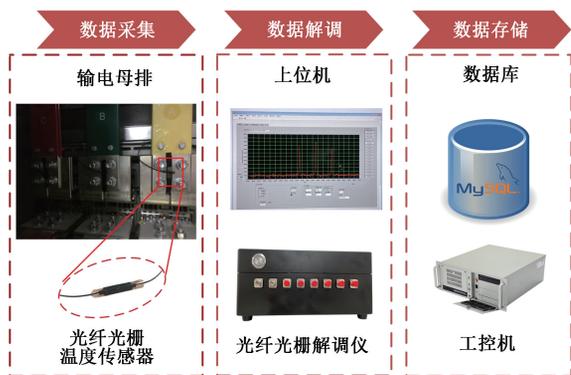


图 1 输电母排触点温度采集系统

Fig. 1 Transmission busbar contact temperature acquisition system

道,母排触点共计 22 个,时间范围为 2020 年 10 月 1 日~2020 年 10 月 31 日,采样周期为 1 min,数据集包含 44 640 条温度数据。采集的输电母排触点温度数据集的统计信息如表 1 所示。

表 1 实验数据集统计信息

Table 1 Statistics of the experimental dataset

数据集	Temp-Dataset
触点数量	22 个触点
时间范围	1 min
时间跨度	2020. 10. 1~2020. 10. 31
时间区间长度	44 640

1.2 数据预处理

输电母排触点原始温度数据往往包含数据缺失或者数据异常的情形,因此不能被深度学习模型加载使用,需要对输电母排触点温度数据进行清洗。通过对数据集以天为单位进行作图分析,可以直观的找到数据集中的缺失值和异常值。图 2 所示为母排触点温度数据出现缺失值的情况,由于母排触点 node8 位置的传感器出现短暂故障,导致一段时间内采集的温度数据为 0。图 3 所示为母排触点温度数据出现异常值的情况,母排触点 node10 在某个时刻出现温度值瞬间升高又降低的异常情形。

由于温度量具有较大的惯性,因此数据集中的缺失值和异常值可以采用一段时间的平均值方法进行填充数据,从而保证了数据集在时间维度的连续性。

采用标准化方法对数据集进行标准化,标准化可以提高模型的精度以及加快模型的收敛速度。通过标准化,将数据集的值转换为标准正态分布,使得数据集的平均值为 0,标准差为 1。标准化公式表示如下:

$$x' = \frac{x - \bar{X}}{S} \quad (1)$$

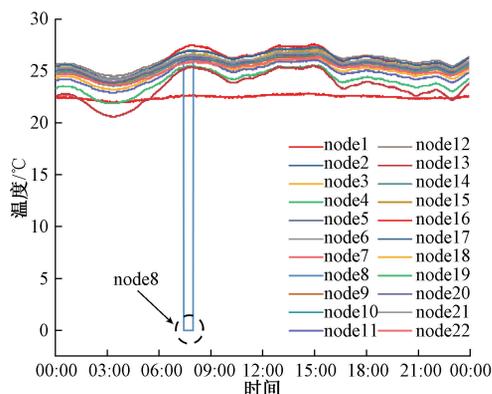


图 2 2020 年 10 月 16 日第 2 通道数据中的缺失值

Fig. 2 Missing values in channel 2 data on October 16, 2020

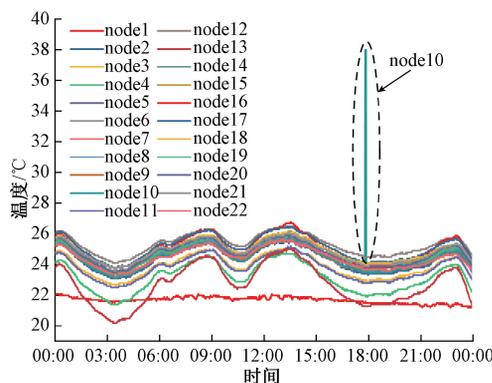


图 3 2020 年 10 月 24 日第 2 通道数据中的异常值

Fig. 3 Outliers in Channel 2 data on October 24, 2020

式中: x' 为标准化之后的温度值, x 为触点采集的原始温度值, \bar{X} 为触点所有数据的平均值, S 为触点所有数据的标准差。

数据集的划分采用滑动窗口的方式截取时间序列数据集,每个滑动窗口宽度为 60 min,滑动步长为 1 min。总样本数为 44 560 条,将数据集按照 7 : 3 的比例划分为训练集和测试集,训练集时间范围为 2020 年 10 月 1 日~2020 年 10 月 22 日,验证集时间范围从 2020 年 10 月 23 日~2020 年 10 月 31 日。

2 编码器-解码器长短期记忆网络模型

2.1 Encoder-Decoder LSTM 网络模型建立

本文建立了 Encoder-Decoder LSTM 网络结构,如图 4 所示,该网络由两部分组成,即 Bi-LSTM 神经网络作为网络的编码器,LSTM 神经网络作为网络的解码器。

图 4 的底端表示模型的输入。将窗口大小为 n 的输电母排单个触点的温度数据进行标准化,得到编码器层的输入 $X = \{x_1, x_2, \dots, x_n\}$,然后编码器对输入数据 X 通

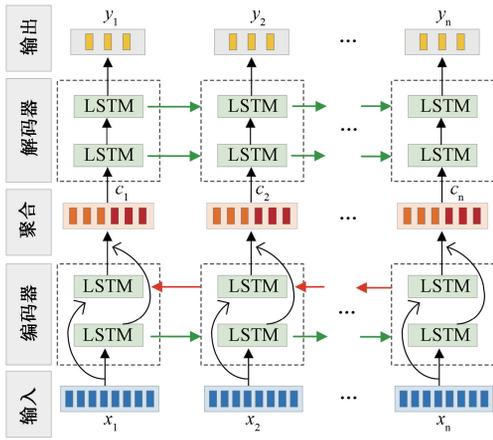


图 4 Encoder-Decoder LSTM 结构
Fig. 4 Encoder-Decoder LSTM structure

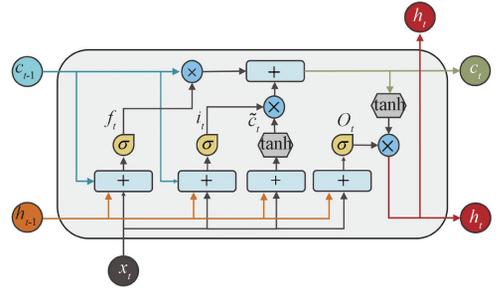


图 5 LSTM 模型结构
Fig. 5 LSTM model structure

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \quad (6)$$

$$h_t = o_t \odot \tanh(c_t) \quad (7)$$

式中: $U^{(i)}, U^{(f)}, U^{(o)}, U^{(c)}$ 和 $W^{(i)}, W^{(f)}, W^{(o)}, W^{(c)}$ 为 LSTM 单元的权重参数, b_i, b_f, b_o, b_c 对应 LSTM 单元的偏置参数, σ 和 \tanh 对应 sigmoid 和 tanh 激活函数, 表示对应元素逐个相乘。

如式(2)~(7)所示,对于 t 时刻的输入时间序列值 x_t , LSTM 网络单元计算出 t 时刻一个隐藏状态 h_t 和一个记忆状态 c_t , 它是对 $t-1$ 时刻的输入时间序列值的编码, 通过对当前 LSTM 网络单元状态的信息遗忘和记忆新的信息, 使得对后续有用的信息得以向前继续传递, 而无用的信息则被丢弃, 并在每个时刻都会输出隐藏状态 h_t 。

2.3 Bi-LSTM 模型

传统的编码器-解码器网络结构大多基于单向的 LSTM 网络单元搭建, 但是单向的 LSTM 网络单元有一个缺点, 它只能捕捉前向时间序列的数据信息, 无法挖掘当前时刻时间序列的上下文信息, 因此在搭建编码器-解码器网络时, 选择双向 LSTM 模型 (Bi-LSTM) 作为编码器层的组成单元。

Bi-LSTM 模型如图 6 所示。Bi-LSTM 模型由两层不同方向的 LSTM 网络组成, 一个方向代表正向信息传递, 记忆细胞状态从 \vec{c}_{t-1} 到 \vec{c}_t , 隐藏状态从 \vec{h}_{t-1} 到 \vec{h}_t , 另外一个方向为逆向信息传递, 记忆细胞状态从 \overleftarrow{c}_t 到 \overleftarrow{c}_{t-1} , 隐藏状态从 \overleftarrow{h}_t 到 \overleftarrow{h}_{t-1} 。 t 时刻 Bi-LSTM 模型的输入 x_t 经过正向 LSTM 网络和逆向 LSTM 网络分别得到正向隐藏状态 \vec{h}_t 和逆向隐藏状态 \overleftarrow{h}_t , 对两个方向的隐藏状态进行张量拼接得到 Bi-LSTM 模型的隐藏状态 h_t , 隐藏状态 h_t 经过 tanh 激活函数即可得到最终 Bi-LSTM 模型的输出结果 y_t 。

Bi-LSTM 计算公式如下所示。

$$\vec{h}_t = \sigma(\vec{U}^{(i)} x_t + \vec{W}^{(i)} \vec{h}_{t-1} + \vec{b}_i) \quad (8)$$

$$\overleftarrow{h}_t = \sigma(\overleftarrow{U}^{(f)} x_t + \overleftarrow{W}^{(f)} \overleftarrow{h}_{t-1} + \overleftarrow{b}_f) \quad (9)$$

过双向长短期记忆网络特征提取, 生成上下文特征向量 $C = \{c_1, c_2, \dots, c_n\}$, 解码器层对上下文特征向量 C 进行解码得到输出目标时间序列 $F = \{f_1, f_2, \dots, f_n\}$, 最终得到的时间序列 F 为输电母排多个触点未来一段时间的温度预测值。

Bi-LSTM 为双向 LSTM 网络, 它可以从多变量时间序列中学习一个时刻的上下文信息, 更能提取深层次的时间序列隐藏特征。由 LSTM 网络组成的解码器则负责预测未来的时间序列值。同时编码器-解码器网络的输入输出时间序列长度是可变的, 这使得时间序列预测更加灵活。该结构可以对输电母排触点温度数据进行端到端建模。

2.2 LSTM 模型

LSTM 网络属于一种特殊的循环神经网络, 它可以捕捉时间序列的长期依赖关系。LSTM 网络由输入门、遗忘门、输出门、记忆细胞状态以及隐藏状态组成。

一个典型的 LSTM 模型结构如图 5 所示, t 时刻的 LSTM 网络单元的输入为输入 x_t 与 $t-1$ 时刻隐藏状态 h_{t-1} 。输出门 o_t 的输出由激活函数为 sigmoid 函数的全连接层计算得到。遗忘门 f_t 控制 $t-1$ 时刻的记忆细胞状态 c_{t-1} 中的信息是否传递到当前时刻。输入门 i_t 与临时细胞状态 \tilde{c}_t 则共同控制当前信息如何更新到记忆细胞状态 c_t 。输出门 o_t 控制记忆细胞状态 c_t 到隐藏状态 h_t 的信息流动。

LSTM 模型计算公式如下所示。

$$i_t = \sigma(U^{(i)} x_t + W^{(i)} h_{t-1} + b_i) \quad (2)$$

$$f_t = \sigma(U^{(f)} x_t + W^{(f)} h_{t-1} + b_f) \quad (3)$$

$$o_t = \sigma(U^{(o)} x_t + W^{(o)} h_{t-1} + b_o) \quad (4)$$

$$\tilde{c}_t = \tanh(U^{(c)} x_t + W^{(c)} h_{t-1} + b_c) \quad (5)$$

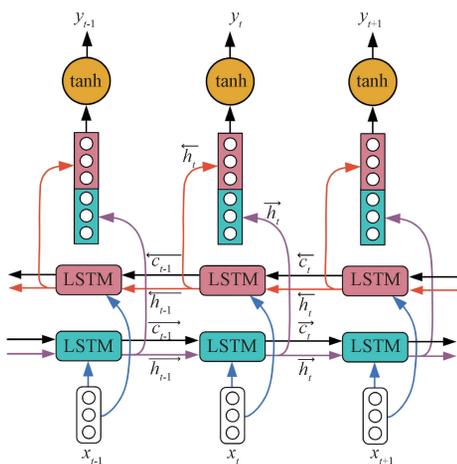


图 6 Bi-LSTM 模型结构

Fig. 6 Bi-LSTM model structure

$$\vec{o}_t = \sigma(\vec{U}^{(o)} \vec{x}_t + \vec{W}^{(o)} \vec{h}_{t-1} + \vec{b}_o) \quad (10)$$

$$\vec{c}_t = \tanh(\vec{U}^{(c)} \vec{x}_t + \vec{W}^{(c)} \vec{h}_{t-1} + \vec{b}_c) \quad (11)$$

$$\vec{c}_t = \vec{f}_t \odot \vec{c}_{t-1} + \vec{i}_t \odot \vec{c}_t \quad (12)$$

$$\vec{h}_t = \vec{o}_t \odot \tanh(\vec{c}_t) \quad (13)$$

$$\vec{i}_t = \sigma(\vec{U}^{(i)} \vec{x}_t + \vec{W}^{(i)} \vec{h}_{t-1} + \vec{b}_i) \quad (14)$$

$$\vec{f}_t = \sigma(\vec{U}^{(f)} \vec{x}_t + \vec{W}^{(f)} \vec{h}_{t-1} + \vec{b}_f) \quad (15)$$

$$\vec{o}_t = \sigma(\vec{U}^{(o)} \vec{x}_t + \vec{W}^{(o)} \vec{h}_{t-1} + \vec{b}_o) \quad (16)$$

$$\vec{c}_t = \tanh(\vec{U}^{(c)} \vec{x}_t + \vec{W}^{(c)} \vec{h}_{t-1} + \vec{b}_c) \quad (17)$$

$$\vec{c}_t = \vec{f}_t \odot \vec{c}_{t-1} + \vec{i}_t \odot \vec{c}_t \quad (18)$$

$$\vec{h}_t = \vec{o}_t \odot \tanh(\vec{c}_t) \quad (19)$$

$$y_t = \tanh(\vec{h}_t \oplus \vec{h}_t) \quad (20)$$

式中: $\vec{U}^{(i)}$, $\vec{U}^{(f)}$, $\vec{U}^{(o)}$, $\vec{U}^{(c)}$ 和 $\vec{W}^{(i)}$, $\vec{W}^{(f)}$, $\vec{W}^{(o)}$, $\vec{W}^{(c)}$ 为正向 LSTM 网络的权重参数, \vec{b}_i , \vec{b}_f , \vec{b}_o , \vec{b}_c 对应正向 LSTM 网络的偏置参数, $\vec{U}^{(i)}$, $\vec{U}^{(f)}$, $\vec{U}^{(o)}$, $\vec{U}^{(c)}$ 和 $\vec{W}^{(i)}$, $\vec{W}^{(f)}$, $\vec{W}^{(o)}$, $\vec{W}^{(c)}$ 为逆向 LSTM 网络的权重参数, \vec{b}_i , \vec{b}_f , \vec{b}_o , \vec{b}_c 对应逆向 LSTM 网络的偏置参数。σ 和 tanh 对应 sigmoid 和 tanh 激活函数, ⊙ 表示特征向量的点乘。⊕ 表示特征向量拼接。相较于单向的 LSTM 网络结构, Bi-LSTM 网络的输出隐藏状态 h_t 由前向输出隐藏状态 \vec{h}_t 和逆向输出隐藏状态 \overleftarrow{h}_t 共同决定。

2.4 模型训练

Encoder-Decoder LSTM 模型的目标函数为 L2 损失函数。公式定义如下:

$$Loss = \sum_{i=1}^m (y_i - \hat{y}_i)^2 \quad (21)$$

式中: y_i 表示输电母排触点温度的真实值, \hat{y}_i 表示输电母排触点温度的预测值, m 表示预测时间步长大小。

模型参数包括模型的超参数与训练参数。模型的超参数为编码器和解码器神经元的个数、激活函数、损失函数以及优化器函数。模型训练参数为学习率、批大小和训练次数。其中, 模型的超参数采用网格搜索法进行优化。本文提出的 Encoder-Decoder LSTM 模型详细参数如表 2 所示。

表 2 Encoder-Decoder LSTM 模型参数设置

Table 2 Encoder-Decoder LSTM model parameter settings

参数	值
Encoder 神经元个数	200
Decoder 神经元个数	200
激活函数	tanh
损失函数	L2 损失函数
优化器	RMSprop
学习率	0.001
批大小	4 096
训练次数	800

模型的训练策略采用早停法, 在模型训练过程中, 当模型在验证集上的损失不再下降时, 自动停止模型训练, 早停法可以有效避免模型过拟合问题。学习率初始值为 0.001, 如果模型在验证集上的损失在 10 次迭代中变化幅度不大时, 自动降低学习率为当前学习率的 1/10, 以此保证模型有效收敛, 提升模型的准确度。

模型的训练与测试环境采用机器学习库 Scikit-learn 和深度学习框架 Keras。实验的硬件环境配置为 Intel CPU i7-9700K 3.60 GHz, 显卡为 12 G 显存的 NVIDIA TITAN-V, 电脑内存为 16 GB。

3 实验结果与分析

3.1 评估方法

本文使用平均绝对误差 (MAE) 和均方误差 (MSE) 作为模型预测效果的评价指标:

$$MAE = \frac{1}{m} \sum_{i=1}^m |y_i - \hat{y}_i| \quad (22)$$

$$MSE = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 \quad (23)$$

式中: y_i 表示输电母排触点温度的真实值, \hat{y}_i 表示输电母排触点温度的预测值, m 表示预测时间步长大小。

3.2 Encoder-Decoder LSTM 模型预测结果与分析

由于行李传送装置的输电母排触点较多, 因此从输电母排触点中随机选取某个母排触点进行研究。本文最

终选取第 2 数据采集通道的第 3 个触点进行分析预测。选取测试集中 2020 年 10 月 24 日 0 时 0 分~2020 年 10 月 24 日 23 时 59 分的历史数据,对单个母排触点进行全天的温度预测,共计 1 440 个预测时间点。实验结果如图 7 所示,模型预测值和输电母排触点温度实际值构成的两条曲线拟合度较高,说明 Encoder Decoder LSTM 模型对长时间序列有较强的特征提取能力,并且模型在未知的数据上有较好的泛化性,不仅能准确预测温度走势,并且预测温度的偏差较小。

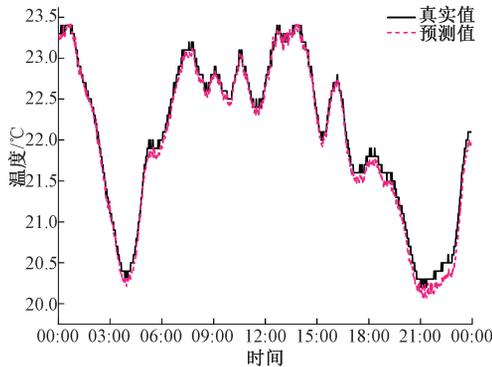


图 7 Encoder Decoder LSTM 触点温度预测图

Fig. 7 Encoder Decoder LSTM node temperature prediction graph

3.3 与其他方法比较与分析

选取测试集中 2020 年 10 月 24 日 0 时 0 分~2020 年 10 月 24 日 23 时 59 分的历史数据,第 2 采集通道母排的第 3 个触点进行预测,预测时间步长为 1,共计 1 440 个预测时间点。

不同模型的预测结果如图 8 所示,从图中可以看出各个模型的整体预测情况与真实值相差较小,但是在波峰和波谷位置,各个模型预测的温度差异值较大,与真实值的最大偏差约 0.5 °C。经业务分析,在波谷的上升段对运行行李传送装置启动阶段,输电母排触点温度逐渐上升,其中 Encoder Decoder LSTM 模型预测值与实际值曲线拟合度较高,说明该模型相较于其他模型,对长时间序列有更出色的记忆功能,更能捕捉到长时间序列中的周期性规律。ARIMA 模型表现相较于 MLR 模型要略好一些,在输电母排整体运行期间 ARIMA 模型预测值与真实值相差较小,但是在行李传送装置启动阶段,ARIMA 模型预测值与真实值偏差较大,说明 ARIMA 模型在长时间序列上的表现不如短时间序列,对于长时间的周期性趋势预测情况较差。LSTM 模型相较于 RNN 模型对于长时间序列具有周期性记忆功能,因此在预测输电母排触点温度走势时表现优于 RNN 模型,但是在短时间序列的预测效果上,RNN 表现更好。

通过对各个模型的预测结果进行评估计算,各个模

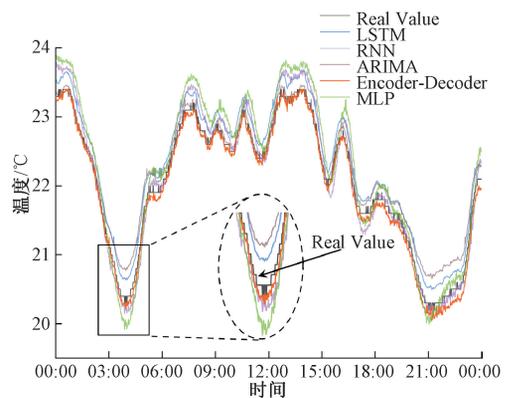


图 8 模型预测结果对比

Fig. 8 Comparison chart of model prediction results

型的 MAE 和 MSE 值如表 3 所示,实验结果表明本文提出的 Encoder-Decoder LSTM 模型在测试数据上有更小的预测误差,并且相对于其他的时间序列预测模型,该模型预测准确率有明显的提升。通过进一步对各个模型的 MAE 值和 MSE 值对比分析发现,对于长时间序列预测问题,基于深度学习的方法(如 RNN、LSTM)优于基于统计学习的方法(如 ARIMA)和基于机器学习的方法(如 MLR),说明基于深度学习的方法对于长时间序列、高度非线性的数据具有更好的拟合能力和鲁棒性。同时对于基于深度学习的时间序列预测方法中,由于 Decoder-Encoder 网络结构设计和 Bi-LSTM 模块的加入,使得 Encoder-Decoder LSTM 模型优于 LSTM 和 RNN 模型,表明该模型对于长时间序列有更强的特征提取能力,更能捕捉和记忆长时间序列的周期性规律。

表 3 各个模型预测结果

Table 3 Predicted results of each model

模型	MAE	MSE
ARIMA	0.493 7	0.251 2
MLR	0.642 2	0.433 9
RNN	0.472 5	0.229 3
LSTM	0.283 2	0.101 4
Encoder Decoder LSTM	0.213 5	0.048 9

4 结 论

本文提出一种端到端的基于编码器-解码器长短期记忆网络模型,用于解决机场行李装置输电母排触点的温度预测问题,做到输电母排触点故障提前预警,保障机场行李传送装置安全平稳运行。编码器-解码器长短期记忆网络模型由 Bi-LSTM 网络组成的编码器和 LSTM 网络组成的解码器组成,可以从输电母排触点的长时间序列中提取隐藏特征,并最终得到相对准确的触点温度预

测结果。本文通过与经典的时间预测模型 ARIMA 模型、基于机器学习方法的 MLR 模型以及基于深度学习的预测模型 RNN 模型和 LSTM 模型在数据集上进行对比实验。实验结果表明 Encoder-Decoder LSTM 网络模型有较好的预测效果。除此之外,本文提出的模型的预测性能与神经网络的超参数选取以及优化函数的选取有很大的关系,今后将在这些方面提升我们模型的预测精准性以及稳定性。

参考文献

- [1] 刘英波. 输电母排运行故障分析与防治[J]. 工程技术(文摘版):00148-00148.
LIU Y B. Analysis and prevention of operation faults of transmission lines[J]. Engineering Technology (Abstract Edition): 00148-00148.
- [2] 赵建青,姚瑶,邱玩辉,等. 基于输电母排在线巡视系统的智能预警系统研究[J]. 电力系统保护与控制, 2013(23):49-54.
ZHAO J Q, YAO Y, QIU W H, et al. Study on intelligent early warning system based on transmission line on-line inspection system [J]. Power System Protection and Control, 2013(23):49-54.
- [3] 王琳慧,吴松,冯骏杰,等. 基于大数据的输电母排温度分析与预测[J]. 湖州师范学院学报, 2018, 40(2):47-52,56.
WANG L H, WU S, FENG J J, et al. Temperature analysis and prediction of transmission line based on the large data. [J]. Journal of Huzhou University, 2018, 40 (2):47-52,56.
- [4] 王炳材,覃霞妹. 输电母排线夹温度安全预警系统. CN206891597U[P], 2018.
WANG B C, QIN X M. Temperature safety early warning system for transmission line clamps, CN206891597U[P], 2018.
- [5] 任守纲,张景旭,顾兴健,等. 时间序列特征提取方法研究综述[J]. 小型微型计算机系统, 2021, 42(2):8.
REN SH G, ZHANG J X, GU X J, et al. Survey of spatio-temporal sequence prediction methods[J]. Journal of Chinese Computer Systems, 2021, 42(2):8.
- [6] 林琳,刘譞,康慧玲. 基于季节分类和 RBF 自适应权重的并行组合电价预测[J]. 电子测量技术, 2020, 43(12):101-105.
LIN L, LIU H, KANG H L. Seasonal classification and RBF adaptive weight based parallel combined method for day-ahead electricity price forecasting [J]. Electronic Measurement Technology, 2020, 43(12):101-105.
- [7] 康守强,叶立强,王玉静,等. 基于 MCEA-KPCA 和组合 SVR 的滚动轴承剩余使用寿命预测[J]. 电子测量与仪器学报, 2017, 31(9):1365-1371.
TANG SH Q, YE L Q, WANG Y J, et al. Remaining useful life prediction of rolling bearing based on MCEA-KPCA and combined SVR [J]. Journal of Electronic Measurement and Instrumentation, 2017, 31 (9): 1365-1371.
- [8] 王大荣,张忠占. 线性回归模型中变量选择方法综述[J]. 数理统计与管理, 2010(4):615-627.
WANG D R, ZHANG ZH ZH. Variable selection for linear regression models: A survey [J]. Journal of Data Statistics and Management, 2010(4):615-627.
- [9] ABU-SHIKHAH N, ELKARMI F, ALOQUILI O M. Medium-term electric load forecasting using multivariable linear and non-linear regression [J]. Smart Grid and Renewable Energy, 2011, 2(2):126-135.
- [10] 姜文瑞,王玉英,郝小琪,等. 决策树方法在气温预测中的应用 [J]. 计算机应用与软件, 2012(8):141-144.
JIANG W R, WANG Y Y, HAO X Q, et al. Application of decision tree in temperature prediction [J]. Computer Applications and Software, 2012(8):141-144.
- [11] ZHAO B, LU H, CHEN S, et al. Convolutional neural networks for time series classification [J]. Journal of Systems Engineering and Electronics, 2017, 28(1):166-173.
- [12] VELASTEGUI R, ZHININ-VERA L, CHANG O, et al. Time series prediction by using convolutional neural networks [C]. Proceedings of the Future Technologies Conference, 2020.
- [13] DALTO M. Deep neural networks for time series prediction with applications in ultra-short-term wind forecasting. 2014.
- [14] GJYLAPI D, PROKO E. Recurrent neural networks in time series prediction [C]. New Research and Advances on Computer Science and Information Technology NRACSIT-2017, 2017.
- [15] 张林琳,鞠森,于立杰. 居民用电负荷超短期预测研究[J]. 电子测量技术, 2019, 42(9):98-101.
ZHANG L L, JU S, YU L J. Research on ultra-short-term prediction of residential electricity consumption [J]. Electronic Measurement Technology, 2019, 42 (9): 98-101.
- [16] BHANJA S. Deep neural network for multivariate time-series forecasting [J]. Advances in Intelligent Systems and Computing, 2020, 1255:267-277.
- [17] 史国荣,戴洪德,戴邵武,等. 基于长短期记忆网络的时间序列预测研究 [J]. 仪表技术, 2020, 370(2):28-30,33.

- SHI G R, DAI H D, DAI SH W, et al. Time series prediction based on long short-term memory network[J]. Instrumentation Technology, 2020, 370(2): 28-30,33.
- [18] MALHOTRA P, RAMAKRISHNAN A, ANAND G, et al. LSTM-based encoder-decoder for multi-sensor anomaly detection [J]. arXiv preprint arXiv: 1607.00148, 2016.
- [19] 孙俊峰, 李志斌. 基于 LSTM 的滚动预测算法的电缆缆芯温度的研究[J]. 电子测量技术, 2021, 44(12): 84-88.
- SUN J F, LI ZH B. Research on cable core temperature based on rolling prediction algorithm of LSTM [J]. Electronic Measurement Technology, 2021, 44 (12): 84-88.
- [20] 曹阳, 茅一波, 施隼. 日交通流预测的编码器-解码器深度学习模型研究 [J/OL]. 计算机工程与应用: 1-11 [2022-04-11].
- CAO Y, MAO Y B, SHI Q. Encoder-decoder deep learning model for daily traffic flow prediction [J/OL]. Computer Engineering and Applications: 1-11 [2022-04-11].

作者简介



李振鹏, 2018 年于郑州轻工业大学获得学士学位, 现为北京信息科技大学硕士研究生, 主要研究方向为预测性维护和神经网络。

E-mail: 760715590@qq.com

Li Zhenpeng received his B. Sc. degree from Zhengzhou University of Light Industry in 2018. Now he is a M. Sc. candidate at Beijing Information Science and Technology University. His main research interests include predictive maintenance and neural networks.



董明利 (通信作者), 2009 年于北京理工大学获得博士学位, 现为北京信息科技大学教授, 主要研究方向为光电与视觉测量、光纤传感与器件。

E-mail: dongml@bistu.edu.cn

Dong Mingli (Corresponding author) received Ph. D. degree from Beijing Institute of Technology in 2009. Now she is a professor in Beijing Information Technology University. Her main research interests include photoelectric and vision measurement, fiber sensing and devices.