

基于 CNN-LSTM 的支撑电容容值软测量

杨培盛¹, 付 宇¹, 李鸿飞², 初开麒², 王梦谦², 李政达²

(1. 济南轨道交通集团建设投资有限公司, 山东 济南 250014;)

(2. 中车青岛四方车辆研究所有限公司, 山东 青岛 266033)

摘要: 实时监测功率变流器中支撑电容的老化状态, 及时发现并更换存在缺陷的电容, 对提高功率变换器的可靠性具有重要意义。基于相关电压电流数据, 通过建立数据集, 确定网络模型参数和模型训练, 最终得到基于 CNN-LSTM 的神经网络模型, 并通过不同工况下的数据集对神经网络模型的准确性进行了验证。结果表明, 该模型可对电容容值进行可靠预测。

关键词: 支撑电容; CNN-LSTM; 可靠性; 神经网络

中图分类号: TN102; TM531

文献标识码: A

DOI: 10.16157/j.issn.0258-7998.201128

中文引用格式: 杨培盛, 付宇, 李鸿飞, 等. 基于 CNN-LSTM 的支撑电容容值软测量[J]. 电子技术应用, 2021, 47(9): 16-19.

英文引用格式: Yang Peisheng, Fu Yu, Li Hongfei, et al. Soft measurement of supporting capacitance based on CNN-LSTM[J]. Application of Electronic Technique, 2021, 47(9): 16-19.

Soft measurement of supporting capacitance based on CNN-LSTM

Yang Peisheng¹, Fu Yu¹, Li Hongfei², Chu Kaiqi², Wang Mengqian², Li Zhengda²

(1. Jinan Rail Transit Group Construction Investment Co., Ltd., Jinan 250014, China;)

(2. CRRC Qingdao Sifang Rolling Stock Research Institute Co., Ltd., Qingdao 266033, China)

Abstract: It is of great significance to monitor the aging state of the supporting capacitors in the power converter in real time and to find and replace the defective capacitors in time. In this paper, based on the relevant voltage and current data, through the establishment of data sets, the network model parameters and model training are determined. Finally, the neural network model based on CNN-LSTM is obtained. The accuracy of the neural network model is verified by the data sets under different working conditions. The results show that the model can reliably predict the capacitance value.

Key words: support capacitor; CNN-LSTM; reliability; neural network

0 引言

近年来, 电力电子系统的可靠性越来越引起社会各界的广泛注意^[1-2]。大量的研究及实践表明, 在轨道交通领域, 实现轨道列车牵引系统的实时健康状态监测, 做到及时的故障预警和提前维修^[3-4], 将大大提高系统的可靠性, 节约维修成本。

直流母线支撑电容作为牵引系统的关键部件, 其健康状态随着投入运行年限的增加而变差, 直流母线电容失效导致的列车系统停机甚至损毁给社会带来了巨大的经济损失^[5-6]。因此, 支撑电容的状态监测技术成为了当前研究的热点^[7-8]。支撑电容的容值能够表征其真实的健康状态^[9], 本文提出了一种大功率变流器直流母线电容容值的在线监测方法, 利用数据训练得到基于卷积神经网络-长短期记忆网络(Convolutional Neural Networks-Long Short Term Memory, CNN-LSTM)的神经网络模型^[10], 可以根据列车系统运行过程中采集到的实时运行数据

进行支撑电容值的准确软测量, 对于实现支撑电容健康状态在线监测、提高功率变流器的可靠性具有重要意义。

1 CNN-LSTM 神经网络模型

CNN(卷积神经网络)能够充分挖掘传感器传回的大批量电压、电流数据中与支撑电容容值有关的数据特征, LSTM 长短期记忆模型能够使得数据特征信息完整化和丰富化^[11]。采用 CNN 和 LSTM 结合的方式对支撑电容相关的电压电流数据进行数据处理和神经网络模型搭建, 能够显著提高电容容值软测量的准确度。

1.1 CNN 神经网络模型

CNN 由数据输入层、卷积层、激活层、池化层、全连接层和输出层构成^[12-13], 如图 1 所示。

卷积层可进行参数共享、卷积等操作, 并通过卷积层滤波器提取输入数据之间的关系; 激活层主要完成卷积层输出的非线性映射, 使得整个网络有更丰富的表达能力, 激活层在结构上属于卷积层; 池化层进行参数降

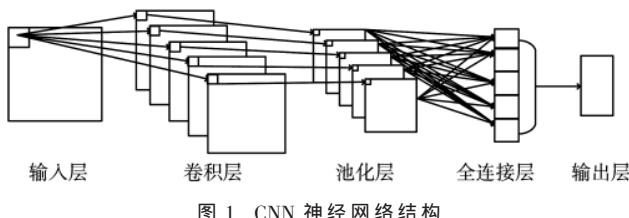


图 1 CNN 神经网络结构

维,减小过拟合;全连接层对特征进行重新拟合,减少特征信息的丢失。

实时采集支撑电容相关的信号数据量大,通过传统的数理统计方法梳理出传感器数据和容值的统计规律难度较大。卷积层作为 CNN 神经网络的核心,其参数共享操作能够很大限度减少运算量,尤其适用于大数据量应用场合;局部感知功能使得每一个卷积核都关注局部的数据信息,最后结合卷积层多核特性,实现多维度数据特征提取,最大化反映数据信息中包含的所有电容相关特征信息。CNN 神经网路模型能够提取信号特征,基于提取的信号特征进行支撑电容值的软测量分析。

1.2 LSTM 神经网络模型

牵引系统支撑电容的运行状态,不仅与当前时刻主回路状态参数有关,准确预测电容容值还需要结合历史数据状态信息。LSTM 长短期记忆网络单元能够对长期依赖信息进行学习,可实现支撑电容时序信息的回归预测,并且能够避免传统的 RNN(循环神经网络)的梯度下降、梯度爆炸等问题^[14]。

LSTM 的关键环节是“电容细胞状态更新”,细胞更新后的状态决定了最终的输出信息。图 2 为 LSTM 单元结构图。从图中可以看到,LSTM 单元内部通过 4 个神经网路层相互交互。

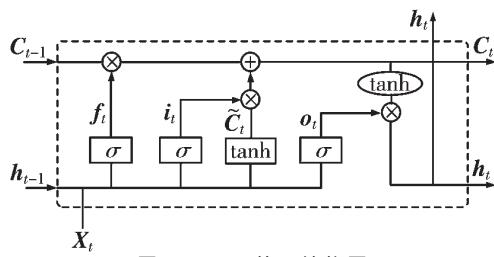


图 2 LSTM 单元结构图

在图 2 中可以看到,LSTM 神经网络单元的链式结构中,电容细胞状态 C_t 在整条链上贯穿前行,LSTM 通过忘记门、输入层门和输出层门,对信号状态信息进行更新和调控,旨在丢弃无价值的信息,保留并填充有用信息。LSTM 的“门”结构由 σ (即 sigmoid 激活函数)神经网络层和一个按位乘的操作构成。sigmoid 激活函数层输出 0~1 的数值,其中,0 表示信息完全被丢弃,1 表示信息完成保留。

忘记门层通过 sigmoid 激活函数决定丢弃何种信息,公式如下:

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

其中, f_t 为忘记层门输出, x_t 为 LSTM 单元在 t 时刻的输入, h_{t-1} 为 LSTM 单元在 $t-1$ 时刻的输出, W_f 为权值矩阵, b_f 为偏置参数。

输入层门通过 sigmoid 激活函数选择何种信息保留在状态中,tanh 层创建一个新的候选值向量,用于状态信息的填充,公式如下:

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

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3)$$

其中, i_t 为输入层门输出,tanh 为双正切激活函数, \tilde{C}_t 为 tanh 层创建的候选值向量, W_i 、 W_c 为权值矩阵, b_i 、 b_c 为偏置参数。

经过信息丢弃、填充后,细胞状态已经更新为新状态 C_t ,如下式:

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (4)$$

其中, \odot 表示哈达马乘积。更新后的细胞状态 C_t 通过 tanh 激活函数后和输出层门的输出 o_t 相乘决定最终的输出 h_t , W_o 为权值矩阵, b_o 为偏置参数,公式如下:

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t \odot \tanh(C_t) \quad (6)$$

2 模型训练

在网络模型中,定义损失函数为 MSE(均方误差),MSE 主要用于反映估计量与观测值之间的差异程度,其公式如下^[15]:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (7)$$

其中, y_i 是真实数据, \hat{y}_i 是对应模型输出结果。其值越小表示估计量与观测值之间的差异越小,越符合人们的期待和优化目标。

在卷积操作中,使用 ReLU(Rectified Linear Unit)激活函数,ReLU 函数相较于其他激活函数,能够有效地防止梯度弥散,引入了稀疏激活性,在同样的条件下,能够加快网络计算,其公式如下^[16]:

$$f(x) = \max(0, x) \quad (8)$$

利用基于随机梯度下降的优化方法来最优化网络参数估计,利用反向传播算法来最小化损失函数。为了防止过拟合,给 LSTM 部分加上了 Dropout 层。Dropout 的实质就是按照一定的概率随机地删除部分神经元,然后进行计算、梯度传播和更新,下一次再选取其他的神经元丢弃的一个过程。训练过程主要由 3 阶段组成:前向传播、后向传播、梯度更新。

前向传播的目标是将数据输入网络,沿着网络前进计算,最后得到输出,比较输出与观测值的关系。计算卷积和池化得到最后的输出。

后向传播基于前向传播得到的网络输出值,然后计算输出与观测值的 MSE,通过各层的参数,将误差从输出层反向传递往输入层,经历上采样,与卷积和的倒置

相乘等逆操作。

梯度更新采用随机梯度下降的方法,计算参数的梯度,更新参数,以使得MSE最小。学习率是梯度学习的关键因子,随着模型训练的深入,需要适时改变学习率才能更好地调整模型。学习率过快可能跳过最低点,导致信息丢失;过慢则时间消耗太大,严重影响代码效率。应让学习率随着训练的深入等比例地降低。

3 试验结果分析

3.1 数据集

针对列车运行过程中牵引系统预充电、牵引加速、恒速运行、减速制动等不同工况下的电压、电流数据,基于CNN-LSTM神经网络模型实现支撑电容容值的软测量,本次试验共测得35组实时运行数据,对应的电容值范围为9.50 mF~10.0 mF。

其中,每组数据包含7个运行参数,分别为网压、网流、电容电压、电容电流以及逆变桥三相输出电流。从数据集中随机选取30组数据作为训练集对LSTM卷积神经网络模型进行训练;剩余5组作为测试集,验证模型的准确度。

首先对传感器采集的电压、电流数据进行预处理,各路电压电流数据的时域特征不明显,因此对数据集进行快速傅里叶变换,将时域信号转化为频域信号,作为卷积神经网络的输入。

3.2 试验结果

基于CNN-LSTM神经网络模型,制作数据集(包括训练集、验证集和测试集)。验证试验数据集共5组,采样频率为100 kHz,采样参数同之前相同,均为网压、网流、电容电压、电容电流以及三相电流。实验目标是通过神经网络软测量上述5组验证数据对应电容值。

定义寿命误差计算公式为:

$$\text{Error}_{\text{Life}} = \frac{E}{C_s - C_e} \times 100\% \quad (9)$$

其中, $\text{Error}_{\text{Life}}$ 为寿命误差, E 为绝对误差, C_s 为初始电容值(取10.00 mF), C_e 为寿命阈值电容值(取9.50 mF)。

在预先不知道真实电容值的情况下,用神经网络软测量,之后对比真实值,结果如表1所示。

表1 验证数据集电容值预测结果

组别	预测值/ mF	真实值/ mF	绝对 误差/mF	相对 误差/%	寿命 误差/%
1	9.89	9.90	0.01	0.10	2.00
2	9.75	9.75	0.00	0.00	0.00
3	9.53	9.53	0.00	0.00	0.00
4	9.67	9.67	0.00	0.00	0.00
5	9.49	9.50	0.01	0.11	2.00

对不同运行功率下的试验数据进行容值软测量,结果如表2所示。

由表1和表2可见,CNN-LSTM模型对于试验数据

表2 不同运行功率下,电容值预测结果

运行功率/kW	电容预测值/mF	电容实测值/mF
90	9.503 34	9.499 72
170	9.508 27	9.499 72
240	9.512 12	9.499 72

的软测量结果较好,具有较高的精度。

为进一步验证CNN-LSTM神经网络模型的软测量结果,分别以BP神经网络模型、CNN模型、LSTM模型和本文应用的CNN-LSTM模型为对比模型,由相同的数据集进行训练和测试,随机选取20组试验数据作为数据集,每组数据集由不同随机种子随机得到。由于以间隔0.1 mF的试验数据作为训练和验证数据,以间隔0.01 mF的试验数据作为测试数据,因此设定训练误差阈值为0.1 mF的10%,即0.01 mF。

定义ACC(正确率)为:

$$\text{ACC} = \frac{T_{\text{Pos}}}{N} \times 100\% \quad (10)$$

其中, T_{Pos} 是在误差阈值内的样本个数, N 总样本个数。ACC主要用于反映估计值与观测值相符合的程度。其值越大越好,表示软测量的准确度越高。

图3、图4为不同神经网络模型下,正确率ACC和

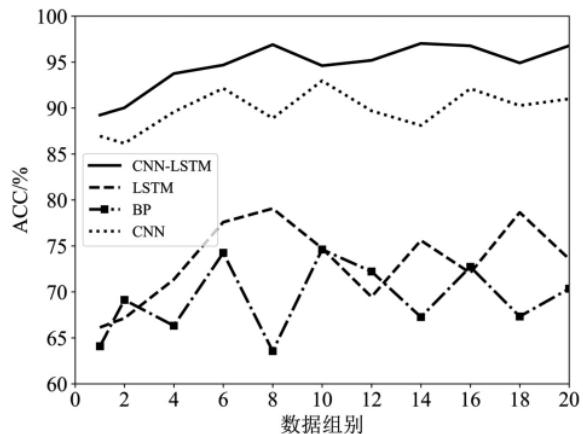


图3 不同神经网络模型正确率对比

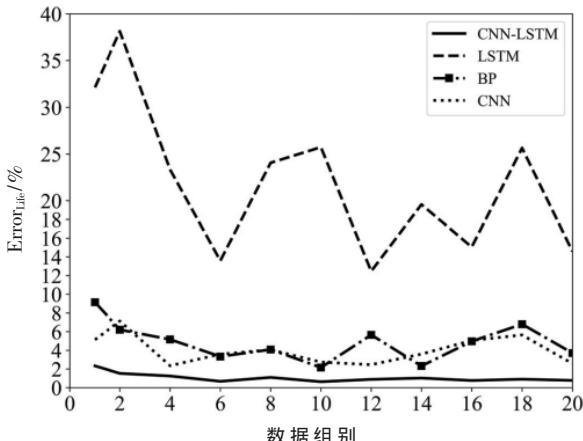


图4 不同神经网络模型寿命误差对比

寿命误差 $Error_{Life}$ 随组别的变化曲线。从对比结果中可以看出 BP 神经网络和 LSTM 的正确率较低, 寿命误差较大, 且曲线波动比较严重, CNN 和 CNN-LSTM 模型 ACC 和 $Error_{Life}$ 曲线较平稳, 正确率较高且寿命误差较小。

表 3 为不同神经网络模型下均方误差 MSE 均值、正确率 ACC 均值和平均寿命误差 $Error_{Life}$ 。由表 3 可知, CNN-LSTM 神经网络模型综合了 CNN 高级数据特征提取能力和 LSTM 对时序数据的长期依赖特性, 预测精度最高, 反映出模型能够对网络进行较好的回归。BP 既无特征提取能力, 也无历史数据信息保存神经层结构, 因此预测精度最差。因为 LSTM 无数据特征提取能力, 所以仅使用 LSTM 模型做容值软测量并不能提升容值测量精度。

表 3 不同模型电容值预测准确率比较

模型	MSE/%	ACC/%	$Error_{Life}/\%$
BP	0.006 3	71.38	3.72
CNN	0.005 6	90.02	2.15
LSTM	1.984 1	73.67	16.3
CNN-LSTM	0.003 0	95.40	0.83

4 结论

本文基于列车系统实时监测的数据, 充分利用 CNN-LSTM 在信号特征提取和对时序数据长期依赖的优势, 实现对支撑电容容值的在线软测量。通过提取不同工况下的支撑电容相关试验数据作为 CNN-LSTM 神经网络模型的训练样本, 以均方误差、正确率和寿命误差作为容值软测量精度的评价指标。

利用试验数据训练得到的神经网络模型可以准确软测量不同试验数据对应的容值, 最后与 BP 神经网络模型、LSTM 神经网络模型和 CNN 神经网络模型进行对比。实验结果表明, 该方法辨识精度较高, 能够满足电容测量的工程需求。

电解电容的健康状态与电容容值高度相关, 因此监测电容容值对评测电容的健康水平具有重要意义。本文所提出的基于 CNN-LSTM 神经网络模型的容值软测量方法能够大大减轻传统列车系统电气部件检修和测量的工作量, 工程应用意义较大。

参考文献

- [1] 雷万钧, 刘进军, 吕高泰, 等. 大容量电力电子装备关键器件及系统可靠性综合分析与评估方法综述[J]. 高电压技术, 2020, 46(10): 3353–3361.
- [2] 何湘宁, 石巍, 李武华, 等. 基于大数据的大容量电力电子系统可靠性研究[J]. 中国电机工程学报, 2017, 37(1):

209–220.

- [3] 罗鸣洲. 高速铁路牵引供电设备故障预测与健康管理平台设计与实现[D]. 成都: 西南交通大学, 2019.
- [4] 孟苓辉. 牵引变流器的故障预测与健康管理(PHM)及可靠性评估技术研究[D]. 北京: 北京交通大学, 2017.
- [5] 黄建华, 金园, 何青. 电容型设备绝缘在线监测系统及其选用原则[J]. 高电压技术, 2001, 27(5): 13–19.
- [6] 潘佩明. 电力电容器安全运行分析与在线监测技术研究[D]. 北京: 华北电力大学, 2015.
- [7] 何卫国. 电力电容器运行状态在线监测装置[D]. 苏州: 苏州大学, 2012.
- [8] Chang Leilei, Sun Jianbin, Jiang Jiang, et al. Parameter learning for the belief rule base system in the residual life probability prediction of metalized film capacitor[J]. Knowledge-Based Systems, 2015, 73: 60–80.
- [9] 唐伟杰, 姚凯, 胡文斌, 等. 一种无电流传感器的 CCM Buck 变换器输出电容 ESR 和 C 的在线监测方法[J]. 中国电机工程学报, 2015, 35(21): 5569–5576.
- [10] 赵建利, 白格平, 李英俊, 等. 基于 CNN-LSTM 的短期风电功率预测[J]. 自动化仪表, 2020, 41(5): 37–41.
- [11] 李冰荣, 皮德常, 候梦如. 基于 CNN 和 LSTM 的移动对象目的地预测[J]. 计算机科学, 2021, 48(4): 70–77.
- [12] 葛哲学, 孙志强. 神经网络理论与 MATLAB R2007 实现[M]. 北京: 电子工业出版社, 2007.
- [13] 倪水平, 李慧芳. 基于一维 CNN 与 LSTM 结合的电池 SOC 预测方法[J/OL]. 计算机应用, 1–9[2021-08-01]. <http://kns.cnki.net/kcms/detail/51.1307.TP.20201011.1426.004.html>.
- [14] 李自纳, 唐银敏, 吴延艳. 基于长短时记忆循环网络的塑料编织机故障诊断研究[J]. 塑料科技, 2020(10): 86–89.
- [15] 蔡自兴, 徐光佑. 人工智能及其神经网络(第 3 版)[M]. 北京: 清华大学, 2004.
- [16] 姚明海, 隆学斌. 基于改进的卷积神经网络的道路井盖缺陷检测研究[J]. 计算机测量与控制, 2020, 28(1): 66–70.

(收稿日期: 2020-11-18)

作者简介:

杨培盛(1981-), 男, 硕士, 高级工程师, 主要研究方向: 城轨设备、车辆工程。

付宇(1993-), 男, 本科, 主要研究方向: 车辆工程。

李鸿飞(1995-), 通信作者, 男, 硕士, 主要研究方向: 深度学习、神经网络、轨道交通列车故障诊断、PHM, E-mail: 18954128606@163.com。



扫码下载电子文档

版权声明

经作者授权，本论文版权和信息网络传播权归属于《电子技术应用》杂志，凡未经本刊书面同意任何机构、组织和个人不得擅自复印、汇编、翻译和进行信息网络传播。未经本刊书面同意，禁止一切互联网论文资源平台非法上传、收录本论文。

截至目前，本论文已经授权被中国期刊全文数据库（CNKI）、万方数据知识服务平台、中文科技期刊数据库（维普网）、DOAJ、美国《乌利希期刊指南》、JST 日本科技技术振兴机构数据库等数据库全文收录。

对于违反上述禁止行为并违法使用本论文的机构、组织和个人，本刊将采取一切必要法律行动来维护正当权益。

特此声明！

《电子技术应用》编辑部

中国电子信息产业集团有限公司第六研究所