

# 基于 CNN-LSTM 的光伏逆变器温度预测方法

周星泽<sup>1</sup> 宋丽媛<sup>1</sup> 李晓方<sup>2</sup> 刘 昊<sup>3</sup>

ZHOU Xingze SONG Liyuan LI Xiaofang LIU Hao

## 摘 要

在考虑了多种可能影响预测结果的因素后,使用卷积神经网络(CNN)结合长短期记忆网络(LSTM)的方法来预测光伏逆变器的温度变化。这种方法可以有效捕获数据特征之间的空间关系,从而弥补了LSTM层在捕捉数据空间分布方面的不足,同时保留了数据特征的时序性。实验结果显示,结合CNN和LSTM的混合神经网络在光伏逆变器温度预测方面表现出了较高的准确性和稳定性。通过对比分析两种模型的平均绝对误差(MAE)发现,相较于独立使用LSTM模型,采用CNN-LSTM混合神经网络的性能有着明显提升。

## 关键词

光伏逆变器;温度预测;深度学习;CNN;LSTM

doi: 10.3969/j.issn.1672-9528.2024.08.037

## 0 引言

目前,全球对清洁能源的需求在不断增加,光伏发电系统作为一种可再生能源的重要形式,受到了广泛关注,得到了广泛应用。在光伏发电系统中,逆变器是将光伏组件产生的直流电转换为交流电的关键设备之一。逆变器的性能和稳定性往往受到其工作温度的影响,而温度预测技术可以提供重要的信息用于系统运行和维护。因此,本文旨在研究一种光伏逆变器温度预测的方法,以提高光伏发电系统的效率和可靠性。

本研究源自国内某油田的“光伏发电智能管理云平台”项目。本文通过对某油田实际应用的光伏逆变器的温度、输出功率以及周围环境温度等因素进行综合监测与分析,采用CNN-LSTM混合神经网络,预测光伏逆变器在未来一段时间内的温度变化趋势,以便及时识别光伏逆变器在未来一段时间内可能出现的问题,以确保光伏系统安全、稳定地运行。

然而,光伏发电系统的运行环境复杂多变,预测受到诸多因素的影响,如地理位置、环境等。这些因素直接影响光伏逆变器的工作温度,进而影响其性能和寿命。过高的温度会导致逆变器元件的损坏和性能下降,而过低的温度也可能影响系统的稳定性。因此,准确预测逆变器的温度对于光伏发电系统的安全运行和有效维护至关重要。

当前,常用的预测方法是基于统计数据进行预测,然而对于复杂的系统和环境条件可能预测精度有限。针对这一问题,本文提出了一种基于深度学习的光伏逆变器温度预测

方法,通过利用CNN对数据进行学习和特征提取,并结合LSTM进行预测。

## 1 CNN-LSTM 混合神经网络模型

### 1.1 卷积神经网络(CNN)

卷积神经网络(convolutional neural network, CNN)是一种深度学习模型,被广泛用于处理具有网格结构的数据,如图像和视频。CNN框架在近年的研究中证明同样适用于时间序列数据分析。其强大的特征提取性能使其成为管理时间序列信息的有效工具。时间序列数据(如股票价格、温度记录等)可视为一维“图像”,将时间步骤视为类似于图像的像素。在时间序列分析中应用CNN时,卷积层可提取时间序列中的局部模式,如趋势变化、周期性波动等。由于时间序列的特殊性(数据点有序且时间间隔固定),通常使用一维卷积(1D卷积)处理此类数据。1D卷积通过在时间序列上滑动,能够识别并提取出时间序列中的关键特征。

CNN主要由以下三个类型的层次构成:卷积层、池化层和全连接层。卷积层通过在输入的数据表面滑动过滤器,并估计它与数据之间的点积差来工作<sup>[1]</sup>。这一步骤形成了一组特征图形,分别表示输入数据的各种性质。池化层旨在减小特征图的维度,以降低计算量并减少过拟合风险。在经过若干卷积层和池化层后,数据会传递到一个或多个全连接层,这些层将前面学到的高级特征组合起来,以执行分类或回归任务。

### 1.2 长短期记忆网络(LSTM)

长短期记忆网络(long short-term memory, LSTM)是一种特殊的循环神经网络(RNN),它能够学习长期依赖关系。LSTM由Hochreiter和Schmidhuber于1997年提出<sup>[2]</sup>,解决

1. 长庆油田分公司新能源事业部 陕西西安 710103

2. 长庆油田分公司第三采气厂 陕西西安 710103

3. 西安石油大学计算机学院 陕西西安 710065

了传统 RNN 在长序列数据处理中面临的梯度消失和梯度爆炸问题<sup>[3]</sup>,使得网络能够处理长期依赖关系。LSTM 在自然语言处理、语音识别、时间序列分析等领域有广泛的应用。LSTM 神经网络中每个单元的结构如图 1 所示,包括输入门、遗忘门、输出门和记忆单元<sup>[4]</sup>。通过记忆单元的逻辑控制决定对数据的处理方式,可以较好地应对权重对网络训练的影响,使网络可以更好收敛。

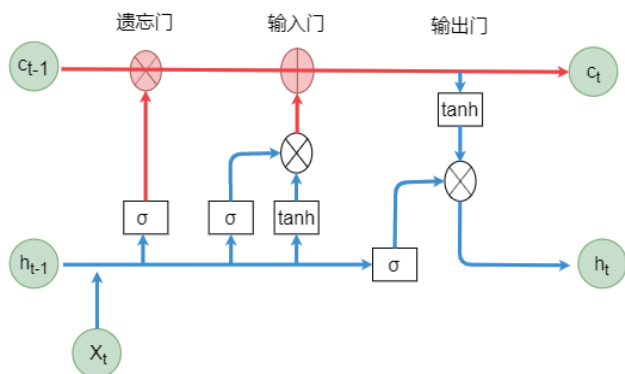


图 1 LSTM 神经网络单元结构

遗忘门负责调控前一时间点的记忆对当前时间点的影响程度。遗忘门的输出  $f_t$  通过式 (1) 计算得到,遗忘门的输出是一个介于 0 和 1 之间的数值,当遗忘门的输出结果值为 0 时,代表全部遗忘了前一时刻的输出信息;当遗忘门的输出值为 1 时,代表完全保留了前一时刻的输出信息,其表达式为:

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

式中:  $W_f$ 、 $b_f$ 、 $\sigma$ 、 $[h_{t-1}, x_t]$ 、 $h_{t-1}$ 、 $x_t$  分别表示遗忘门的权重矩阵、遗忘门的偏置项、函数、两个向量直接连接起来后形成的向量、前一时刻隐藏层的输出值、当前时刻的输入值<sup>[5]</sup>。

输入门的主要职责是从新接收的信息中筛选出对更新当前状态有用的数据。它通过结合当前的输入信号和上一时刻的隐藏层状态,利用 Sigmoid 激活函数来判断哪些信息是关键的,从而决定哪些信息应该被加入到状态更新中。此外,还有一个  $\tanh$  激活层的工作是产生一个新的候选状态向量,这个向量包含了可能对当前状态有益的信息。这个新生成的候选向量之后将被融合进当前的状态中,以此来帮助模型更好地记忆和处理信息。这种机制使得模型能够在处理序列数据时,更加有效地保留长期依赖信息。输入门的输出决定了添加新信息的程度,其表示式为:

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

式中:  $W_i$ 、 $b_i$  分别表示输入门的权重矩阵、输入门的偏置项。

输出门控制着 LSTM 单元的输出,表示要输出的信息量,取值范围 [0,1]。0 代表不输出任何信息;1 代表输出当前时刻的全部记忆细胞状态。

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

$$c_t = f_t c_{t-1} + c_t f_i \quad (4)$$

式中:  $W_c$ 、 $b_c$  分别为记忆单元的权重矩阵、记忆单元的偏置项<sup>[6]</sup>。

输出门将经过非线性函数处理后得到 LSTM 网络的输出。

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

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

式中:  $W_o$  为输出门的权重矩阵,  $b_o$  为输出门的偏置项<sup>[7]</sup>。

### 1.3 混合神经网络模型设计

CNN-LSTM 结构是一种综合型神经网络模型,结合了 CNN 的空间特征提取功能和 LSTM 的时间序列分析功能。这种结合不仅使网络能够高效地处理图像等空间数据,还能精确地分析随时间变化的数据。通过这种方式, CNN-LSTM 模型能够在多个层面上理解数据,为逆变器温度预测提供强大的支持,从而在实际应用中展现出其独特的优势。因此, CNN-LSTM 神经网络模型结合了两种网络的优势,提高了序列数据处理的性能。

CNN-LSTM 预测模型的结构如图 2 所示。本研究开发的混合神经网络模型,结合 CNN 和 LSTM 技术,针对多元时间序列数据进行单变量预测。该模型框架包括输入层、两层一维卷积层、池化层、长短期记忆网络层、全连接层以及输出层<sup>[8]</sup>。在此架构中,第一层一维卷积层负责将原始输入数据转化为 32 个特征通道,而第二层一维卷积层则进一步将这些特征通道转化为 64 个。每个卷积层之后接有激活函数<sup>[9]</sup>,这是为了引入必要的非线性特性,以提高模型对复杂数据模式的识别能力。每个卷积层之后都有一个最大池化层,以降低数据的空间尺寸,从而减少参数数量和计算量,同时有助于提取关键特征。

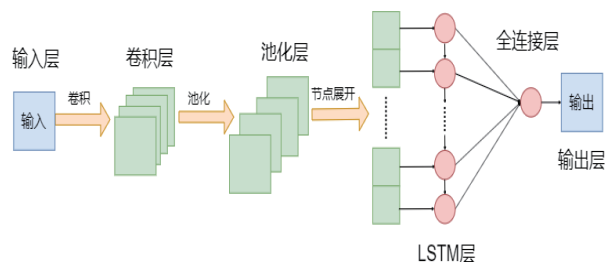


图 2 CNN-LSTM 预测模型结构

通过结合长短期记忆网络 (LSTM), CNN 可以进一步提高在处理具有强时间依赖性特征的时间序列数据时的性能。这种组合利用了 CNN 在特征提取方面的优势和 RNN/LSTM 在处理时间序列数据的依赖性方面的能力,实现了更为准确的预测和分析。

## 2 实验结果与分析

### 2.1 实验环境

该模型使用 PyCharm 编译工具,在基于 Python 3.9 的 PyTorch 深度学习框架上进行开发。训练和测试过程的硬

件环境, 包括运行在 2.50 GHz 的 Intel (R) Core i5-7300HQ CPU、NVIDIA GeForce GTX 1050Ti GPU 和 16 GB RAM 的 Windows 10 操作系统。

## 2.2 实验数据

本文使用的数据集来源于作者参加的某油田光伏电站的项目, 一共收集了 1 台逆变器在 8 天内的参数, 包括逆变器的温度 (T)、逆变器的输出电压 (P)、逆变器的输出电流 (Ia)、环境温度 (Ambient\_temperature) 和湿度 (Ambient\_humidity)。数据的采集频率是每隔一分钟采集一次参数, 光伏逆变器在 8 天内共有 11 520 条数据。

## 2.3 实验过程

第一步对数据进行归一化, 将特征值缩放到 0 和 1 之间。本实验使用的归一化方法是最小 - 最大归一化。这种方法通过将特征缩放至 0 和 1 之间, 来进行数据的预处理。第二步构建时间序列数据集。这些模型需要基于过去的序列来预测未来的值。为了适应模型的输入需求, 实现的函数将归一化后的数据转换为特定的序列格式。这一过程包括确定序列长度, 即模型将考虑过去多少时间点的数据来做出预测, 以及预测长度, 即模型需要预测未来多少时间点的数据。本实验中, 设置序列长度为 180, 预测长度 60, 即用过去 3 小时的时间来预测未来 1 小时的温度变化。第三步划分训练和测试数据集, 从原始数据集中选取不同的部分来生成对应的时间序列数据集。通过使用与训练集不同的测试集, 可以有效地检验模型的泛化性, 确保模型在实际应用中具有较高的可靠性和准确性。

## 2.4 实验结果

本文的实验结果评价指标使用回归任务的常用评价指标: 均方误差损失 (mean squared error, MSE)、平均绝对误差 (mean absolute error, MAE) 和  $R^2$  (coefficient of determination) 来分析模型的回归预测效果。MAE、MSE、 $R^2$  和提升性能百分比的计算公式如下:

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

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (8)$$

$$R^2 = 1 - \frac{S_{res}}{S_{tot}} \quad (9)$$

$$P = \left( \frac{MAE_{lstm} - MAE_{cnnlstm}}{MAE_{lstm}} \right) \times 100\% \quad (10)$$

式中:  $n$  是样本数量,  $y_i$  是第  $n$  个样本的实际值,  $\hat{y}_i$  是模型预测的值,  $S_{res}$  是残差平方和,  $S_{tot}$  是总平方和。 $R^2$  的值范围通常在 0 ~ 1 之间, 值越接近 1 意味着模型的预测能力越好<sup>[10]</sup>。

LSTM 和 CNN-LSTM 模型实验参数如表 1 所示, 预测结果如图 3、图 4 所示。

表 1 实验结果

预测模型	MAE/min	MSE/min	$R^2$ /max
LSTM	0.018 073	0.060 1	0.923 6
CNN-LSTM	0.010 152	0.043 3	0.965 5

通过对表 1 的分析, 可以明显观察到, 加入 CNN 的 LSTM 网络在 MAE 和 MSE 两个指标上都显示出了更低的数值, 这表明了模型预测的准确度得到了显著提升。此外, 模型的  $R^2$  (决定系数) 值更接近 1, 这意味着模型对数据变化的解释能力更强, 预测结果与实际情况的一致性更高。

从图 3 和图 4 中可以清楚地看到, 在单独使用 CNN 与将 CNN 和 LSTM 结合使用的情况下, CNN-LSTM 模型的预测曲线与实际值的曲线拟合度更高, 显示出了更好的一致性和准确度。




图 3 CNN-LSTM 预测图




图 4 LSTM 预测图

## 3 结语

本研究旨在利用混合神经网络模型, 精确预测光伏逆变器的未来温度, 通过巧妙地融合卷积神经网络 (CNN) 和长短期记忆网络 (LSTM), 充分发挥了两者在处理空间特征和时间序列数据上的优势。通过分析历史数据, 该模型能够有效预测出逆变器的温度变化, 为光伏逆变器的温度管理提供了一个高效的工具。实验结果表明, 该模型在测试集上保持了与训练集一致的表现, 具有良好的泛化能力, 成功降低了预测结果与实际值之间的平均绝对误差 (MAE), 显示出了其在精确预测方面的潜力。未来的研究将更深入地探索和

(下转第 176 页)



## 4 结语

首届全国数据工作会议提出坚持数据要素市场化配置改革这条主线,数据要素市场化配置改革是当前中国数字经济发展的重要方向,其核心在于通过政策和市场机制的优化使得数据资源能更高效地流通并创造更大的经济价值。本文深入探讨了推进数据要素市场化配置改革的重要性及其在新发展格局下的多方面意义,分析了数据要素在促进数字经济发展及赋能实体经济转型中的重要作用,并针对当前市场化配置中存在的问题,如顶层制度设计不优、数据运营模式不规范、配套产业基础薄弱、人才技术储备不足以及数据安全问题等,提出了一系列推进改革的建议,包括建立完善的政策理论体系、形成统一的市场生态体系、完善资金支持和平台支撑体系、构建人才保障体系和完善治理监管体系等,旨在加速释放数据要素价值,推动经济社会高质量发展。

## 参考文献:

- [1] 孙克.数据要素价值化发展的思考[J].信息通信技术与政策,2021(6):63-67.

(上接第164页)

实验更为复杂和创新的网络架构,以及不同的序列长度和预测时间范围的组合,以进一步优化和提升模型的预测能力。通过引入先进的神经网络技术,如注意力机制、图卷积网络等,以及进行广泛的参数调优工作,期望能显著提高模型对未来情况预测的准确性,为时间序列预测领域带来更多的创新和突破。

## 参考文献:

- [1] 吴永洪,张智斌.基于贝叶斯优化的CNN-GRU短期电力负荷预测[J].现代电子技术,2023,46(20):125-129.
- [2] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural computation, 1997, 9(8): 1735-1780.
- [3] 杨凯,唐卫东,刘诚,等.基于LSTM循环神经网络的大地电磁波噪声抑制[J].物探与化探,2022,46(4):925-933.
- [4] 唐清苇,向月,代佳琨,等.基于CNN-LSTM的风电场发电功率迁移预测方法[J].工程科学与技术,2024,56(2):91-99.
- [5] 杨喆,邓立宝,狄原竹,等.超密集异构无线网络中基于移动轨迹预测的网络切换算法[J].电子与信息学报,2023,45(12):4280-4291.
- [6] 付浩,王圣达,姜山,等.基于ARMA-LSTM的光功率预测方法[J].光通信技术,2019,43(1):20-23.

- [2] 俞林.发展数字经济应抓住数据要素市场化这个关键[J].智慧中国,2021(8):40-41.
- [3] 纪玉山,代栓平,杨秉瑜,等.笔谈:发展新质生产力推动我国经济高质量发展[J].工业技术经济,2024,43(2):3-28.
- [4] 房毓菲.推动协同治理健全数据治理体系[J].中国信息界,2023(1):44-47.

## 【作者简介】

林庆(1979—),男,山东烟台人,硕士,正高级工程师,烟台市大数据中心副主任,研究方向:数据分析应用。

徐向辉(1994—),男,河南郑州人,硕士,烟台市大数据中心职员,研究方向:数据分析应用。

王正美(1990—),女,山东临沂人,硕士,临沂市费县石井镇副镇长,研究方向:数据分析应用。

(收稿日期:2024-07-12)

- [7] 易灵芝,黄其森,刘文翰,等.基于分治策略的NP-MLSTM非侵入式负荷辨识方法[J].电力系统及其自动化学报,2021,33(10):112-118.
- [8] 黄志坚,张成,王慰慈.基于回归深度卷积网络的船舶图像与视频检测[J].上海海事大学学报,2019,40(4):83-88.
- [9] 顾永跟,钟浩天,吴小红,等.不平衡数据下预算限制的联邦学习激励机制[J].计算机应用研究,2022,39(11):3385-3389.
- [10] 卓然,王晓雨,王博,等.微型色谱柱制备及其GC谱线分离性能的优化[J].微纳电子技术,2021,58(5):433-438+451.

## 【作者简介】

周星泽(1991—),男,河北南宫人,硕士,工程师,研究方向:新能源项目管理、生产管理。

宋丽媛(1994—),女,甘肃张掖人,硕士,中级工程师,项目主管,研究方向:新能源。

李晓方(1989—),男,陕西华县人,本科,信息工程师,研究方向:油气田数字化与智能化融合发展。

刘昊(1998—),男,山东潍坊人,硕士,研究方向:深度学习、大数据技术。

(收稿日期:2024-05-21)