

基于改进循环神经网络的配电网超短期功率预测方法

赵振兵¹, 强一凡¹, 李 信², 肖 娜², 李 坚³, 席嫣娜⁴, 石 颖¹

(1.华北电力大学电气与电子工程学院,河北 保定 071003;2.国网冀北电力有限公司信息通信分公司,北京 100053;
3.国网冀北电力有限公司,北京 100054;4.国网北京市电力公司,北京 100031)

摘 要:针对传统单向循环神经网络在配电网超短期功率预测领域存在的预测曲线失形、模型过拟合现象以及预测精度不高和收敛速度慢等问题,提出基于小波变换和自注意力机制的双向循环神经网络改进模型。通过双向结构学习功率数据的前向和逆向规律提高模型预测精度;通过小波变换分摊整体功率预测难度以及改善过拟合和加快模型收敛速度;通过自注意力机制把握模型隐藏层维度关系进一步提高预测精度。算例证明改进模型可以有效改善上述问题,改进模型与传统单向模型相比,在有功预测场景中,MAE 提升了 50.1%,MAPE 提升了 43.3%,RMSE 提升了 51.1%;在无功预测场景中,MAE 提升了 60.5%,MAPE 提升了 63.8%,RMSE 提升了 60.1%。

关 键 词:配电网;功率预测;循环神经网络;小波变换;自注意力机制

DOI:10.19781/j.issn.1673-9140.2022.05.016 中图分类号:TM71 文章编号:1673-9140(2022)05-0144-11

Ultra-short-term power prediction method of distribution network based on improved recurrent neural network

ZHAO Zhenbing¹, QIANG Yifan¹, LI Xin², XIAO Na², LI Jian³, XI Yanna⁴, SHI Ying¹

(1.School of Electrical and Electronic Engineering, North China Electric Power University, Baoding 071003, China;2.State Grid Jibei Information & Telecommunication Company, Beijing 100053, China;3.State Grid Jibei Electric Power Company Limited, Beijing 100054, China;4.State Grid Beijing Electric Power Company, Beijing 100031, China)

Abstract: The traditional one-directional neural network has some problems in the field of ultra-short-term power prediction in distribution networks, such as the out-of-shape curve prediction, the over-fitting phenomenon of the model, low prediction accuracy and slow convergence speed, etc. Thus, an improved bi-directional recurrent neural network model is proposed based on the wavelet transform and self-attention mechanism to overcome these problems. Firstly, the forward and reverse laws of the power data are studied by the bi-directional network to improve the prediction accuracy of the model. Afterward, the wavelet transform is employed to reduce the overall difficulty of power prediction. Consequently, the model overfitting is reduced, and the convergence speed is increased in the meantime. In the end, the self-attention mechanism is adopted to grasp the hidden layer dimensional relationship of the model to further improve the prediction accuracy. An example shows that the proposed improved model can eliminate the existing problems effectively. Compared with the traditional model, the MAE increased by 50.1%, MAPE increased by

收稿日期:2022-03-02;修回日期:2022-05-20

基金项目:国家重点研发计划(2020YFF0305800);国家电网有限公司科技项目(520201210025)

通信作者:石 颖(1998—),女,硕士研究生,主要从事深度学习方面研究;E-mail:syngbwq@163.com

43.3%, RMSE increased by 51.1%; in the reactive dataset, dataset MAE increased by 60.5%, MAPE increased by 63.8%, and RMSE increased by 60.1%.

Key words: distribution network; power prediction; recurrent neural network; wavelet transform; self-attention

智能配电网引入大量分布式电源、电动汽车以及柔性负荷,虽然增加了配电网的供电能力和灵活性,但是也带来了配电网供电可靠性、波动性等挑战^[1]。比如功率波动等问题不但限制线路的电力配送能力,还易造成电力安全事故,这对电网整体调控带来新的不稳定因素^[2]。因此如何实时准确预测配电网功率,对配电网运维和调控等有着重要意义。

根据电网调度的应用要求,超短期功率预测一般是未来 5 min 至 1 h 的功率预测,即超短期是利用较新功率信息进行预测,并能够在线跟踪电网变化。而基于数据驱动方式的人工智能(artificial intelligence, AI)技术在解决配电网超短期功率预测方面问题具有潜在的技术优势,尤其是深度学习(deep learning, DL)中的循环神经网络(recurrent neural network, RNN)擅长应对时序预测问题,其原因是该系列模型每时刻的输出不仅由该时刻输入决定,还由上一刻隐藏层(输出)决定,即模型预测值不仅根据实际已知值做预测,还联合过去预测值做预测。近年来有专家利用深度学习在电网紧急控制^[3]和电网设备状态检测^[4]等方面进行了研究,并取得了一定成效,并在配电网功率预测相关的领域也做了一些探索^[5]。结合以上对循环神经网络的介绍以及配电网超短期功率预测领域深度模型应用较少的现状,下面就循环神经网络在电网短期发电预测和负荷预测领域中的相关改进做具体介绍。

文献[6]提出了利用双重注意力机制改进传统门控循环单元(gated recurrent unit, GRU)的短期负荷预测方法,削弱了各输入特征对电网负荷情况的影响和增强了递归神经网络捕获负荷数据长时依赖,算例结果表明相比以往模型,其在预测精度都有不同程度的提升;文献[7]在传统 GRU 的基础上融合卷积神经网络(convolutional neural network, CNN),提高模型对原始数据的特征提取和降维能力,并引入 dropout 技术减少模型中的过拟合现象,算例结果证明了相比 LSTM 和 GRU,其提高了预测准确度和运算速度;文献[8]在 GRU 和

CNN 基础上使用了注意力机制,算例结果证明了改进模型提高了预测精度;文献[9]在传统长短时记忆网络模型(long-short term memory, LSTM)基础上使用了双向过程(bi-directional, Bi)对基于天气过程动态划分的各风电子集群进行发电功率预测,算例结果证明相比反向传播算法(back propagation, BP)、CNN 和 LSTM,其能够取得更高的短期风电发电功率预测精度,有效平衡实际发电与预测发电之间的偏差;文献[10]针对如何精准地预测配电网空间电力负荷这一问题,提出基于降噪自编码器、奇异谱分析(singular spectrum analysis, SSA)和传统 LSTM 神经网络,在数据预处理阶段通过奇异谱分析分解时间序列为高低频分量的时间序列,之后预测阶段采用不同的 LSTM 分别对低、高频分量进行预测,并将 2 种分量预测结果进行叠加得出目标年负荷预测值,算例结果证明采用了 SSA 更准确地把握了符合发展变化的规律性,侧面提高了负荷预测精度。

基于以上对传统单向循环神经网络(RNN、LSTM 和 GRU)的各种改进优化的阐述和启发以及现有的传统单向循环神经网络在配电网超短期功率预测领域应用的诸多问题,本文提出基于小波变换和自注意力机制的双向循环神经网络改进模型,其可以改善传统单向循环神经网络存在过拟合、预测精度不高和收敛速度慢等问题^[11-12],同时三项改进的融合是不可分割的。然后使用某市有功、无功 2 种场景数据进行实验,对现有的几种不同改进进行不同程度的测试。最后通过模型指标对比证明不同改进的优劣,同时证明三项改进模型的有效性和可靠性,这为配电网应对波动性数据的运维和调控提供更加精确可靠的数据支持。

1 相关工作

1.1 传统单向模型的预测原理

单向循环神经网络仅需要时序数据一直输入

下去,模型就会根据所有以往数值做滚动预测,一直到配电网例行电力检修。单向 RNN^[13]、LSTM^[14]和 GRU^[15]的时序展开如图 1 所示。




图 1 单向 RNN/LSTM/GRU 网络时序展开

Figure 1 RNN/LSTM/GRU Timing expansion diagram

图 1 中, I_t 为第 t 时刻输入的向量, O_t 为第 t 时刻输出的向量, W 为每个时刻点之间的权重矩阵, U, V 为线性变换参数矩阵, S_t 为第 t 时刻网络所保留的向量, 将参与到 $t+1$ 的计算中。

1.2 双向结构模型的预测原理

在时序预测和双向结构中, 每一个训练序列向前和向后分别是 2 个循环神经网络, 且这 2 个网络都连接着一个输出层, 该结构能够提供给输出层输入序列中每一个点完整的过去和未来的上下文信息, 使得该双向结构在正逆向计算方向充分考虑了上下文信息, 可以有效地提高预测精度, 避免模型过拟合现象。双向结构由正向、逆向共 2 个方向的单层构成, 但需注意的是双向结构在做单向时序预测时, 预测的点必须对于当前模型输入来说是“未知”的, 不然会出现“未来值反向计算时贡献了预测的未来值”的问题, 这一问题本文通过改变模型的预测策略加以修正。结合单向循环神经网络的时序展开图, 双向模型的内部时序展开流程如图 2 所示。




图 2 Bi-RNN/LSTM/GRU 时序展开

(从左往右为正向, 从右往左为逆向)

Figure 2 Bi-RNN/LSTM/GRU timing expansion diagram (Left to right is forward, right to left is reverse)

图 2 中, h_t 上标有从左向右箭头的符号代表 t 时刻的正向中间向量, 而标有从右往左箭头的符号代表 t 时刻逆向中间向量, 2 个方向的向量将最终通过前后拼接的方式生成 t 时刻的输出。图 2 中的圆圈代表输入向量和中间向量参与内部计算。

1.3 小波变换

使用小波变换^[16]具体是利用小波基将原始时序数据通过变换得到和原始长度不同的不同近似和细节分量。经此变换将原始数据序列分解, 对并行数据预测, 从而降低直接对时序数据预测的难度。最后将各分量预测值按时序位置相加得到最终预测值。通过此方法, 改善了模型直接训练原始数据时的过拟合现象以及提高了模型的预测精度和加快收敛速度。小波变换流程如图 3 所示。




图 3 小波变换流程

Figure 3 Wavelet transform flowchart

由于 Mallat 算法中输入序列为有限长, 滤波器系数与输入序列卷积时会出现轮空^[17]的现象, 造成运算误差。因此有必要对原始信号进行边界延拓, 减小边界误差, 本实验中采用了补零法。同时通过实际实验发现采用补零法边界延拓造成的误差每个样本不超过 MAE 和 RMSE 指标最小分度值千分之一。结合预测数据的长度在 1 500 以内, 可认为本文中小波变换造成的变换误差可以忽略不计。

1.4 自注意力机制

注意力机制^[18](Attention)最初主要用于自然语言处理等任务, 其关注目标场景所需要的特征。比如不同语种间翻译时从一句话中筛选出需要的几个关键词构建翻译框架。自注意力机制是注意力机制的变体, 其减少了对外部信息的依赖, 更擅长捕捉数据或特征的内部相关性, 且能够并行处理输入, 一个输出会考虑所有输入的影响, 提高了模型的信息记忆能力。本文使用自注意力机制主要目的是注重不同时刻隐藏层对当前时刻的贡献关系, 将不同时刻隐藏层的输出结果全部利用起来, 即更好把握模型中间隐藏层维度之间的关系, 从而提高模型预测精度。

2 基于小波变换和自注意力机制的双向深度模型

本文根据深度学习模型一般训练的原理和过程^[19],再结合使用的双向结构、小波变换和自注意力机制进而确定本文模型的训练、验证和预测方式。在数据预处理和划分数据集阶段之间加入小波分解,继而在模型训练和验证以及模型实际功率预测阶段将每个分量预测的结果相加得到最终的功率值,最后计算性能指标得到改进后的模型效果。改进模型上文训练、验证和预测方式如图 4 所示。

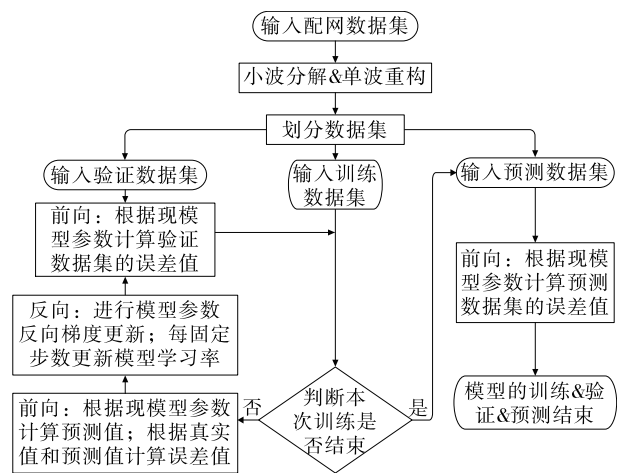


图 4 改进模型的训练、验证和预测方式(单小波分量)

Figure 4 Improved model training, validation and prediction methods (single wavelet component)

1) 配网功率数据的预处理。由于有些数据暂时无法采集、获取这些数据时配网检修从而未获取数据,或者是因为人为因素导致部分信息丢失,从而造成了数据空值的产生;在数据采集、输入过程中出现失误,测量误差等人为因素外,个别数据描述偶然事件,表现出离群性,因此产生了异常值。由于配网数据以天呈现周期性,因此在实验中剔除对一天内出现空值和异常值的数据进行整天数据的剔除,所以预处理包括空值和异常值剔除、数据归一化等数据处理方法。最终提取段时间内某设备或线路的有功、无功功率的数据。

2) 配网功率数据的小波变换。利用小波分解将时序功率数据首先进行多阶离散小波分解,之后对每条频率分量做单波重构,得到多条与分解前的相同时序长度但不同频率分量的功率数据。

3) 配网功率数据的数据集划分。即将数据集分为训练集、验证集和测试集,同时将数据塑形为深度模型的输入格式和输出格式。为了规避双向结构做单向预测问题,本文给出“组预测”的预测策略,即使用连续的输入输出键值对进行神经网络的输入和输出,但只对组中最后一个键值对做预测,因此程序实际在利用深度模型对不同输入输出的键值组进行训练、验证和预测是采用循环结构。之后分配好的数据集的键值对张量维度如下:

$$\langle \text{input}; \{S_{\text{Len}}, G_{\text{Size}}, B_{\text{Size}}, I_{\text{Size}}\}, \text{output}; \{S_{\text{Len}}, G_{\text{Size}}, B_{\text{Size}}, O_{\text{Size}}\} \rangle \quad (1)$$

式中 S_{Len} 为需要预测的点数,也等于模型计算误差的样本数量,也等于组预测循环的次数; G_{Size} 为本文中组预测的组长度,为符合短期预测策略,本文为 2; B_{Size} 为每次模型进行参数更新的样本数,本文为 1; I_{Size} 为模型需要根据多少时刻数量的现有值进行预测未来值; O_{Size} 为模型需要根据现有值进行预测多少时刻未来值。

4) 深度预测模型搭建。该模型首先由 2 层双向的门控循环单元构成。2 层门控循环单元网络的隐含层维度不同,第 1 层维度和第 2 层维度变换由上到下:

$$\text{Input}; I_{\text{Size}}, H; H_{\text{Size}} * 2, \text{Output}; H_{\text{Size}} * 4 \quad (2)$$

$$\text{Input}; H_{\text{Size}} * 4, H; H_{\text{Size}}, \text{Output}; H_{\text{Size}} * 2 \quad (3)$$

式(2)、(3)中 H_{Size} 为单个循环神经层的基础隐藏层维度。之后将输出的隐含层张量通过预设超参数的 3 次张量线性变换得到 3 个维度预设的自注意力机制的 Q 、 K 、 V 张量,再通过自注意力机制的计算方法得到自注意力输出。计算方法如下:

$$\text{Attention}(Q, K, V) =$$

$$\text{softmax}((Q \cdot K^T) / \sqrt{d_k}) \cdot V \quad (4)$$

$$\text{softmax}(x) = e^x / \sum_{x=1}^j e^x \quad (5)$$

式(4)首先通过 Q 与 K 的转置相乘将其变为特征值自注意力张量,再利用 softmax 进行特定维度归一化,在此之前使用不同的线性变换目的是为了提最后形成张量的泛化能力,同时之后为了防止 Q 和 K 向量维度较大时,导致点积结果过大,归一化张量梯度很小的不足,需要进行缩放操作减轻影

响,之后将 \mathbf{V} 张量与特征值自注意力张量相乘进行特征值的注意和重组得到 Attention 特征值重组张量,最后将 Attention 特征值重组张量再通过逆线性变换作为自注意力输出,其中 d^k 为经过线性变换 $\mathbf{Q}, \mathbf{K}, \mathbf{V}$ 张量的特征维度。式(5)为归一化公式,其中 x 为进行维度归一化的张量,最终 x 的特定维度的值会被限制在 $[0, 1]$ 之间。

最后将其输出与双层输出的隐含层向量残差相加输入最后的全连接层,得到最终的深度模型输出功率预测值。全连接层张量隐含层维度变换为

$$\text{Input: } H_{\text{Size}} * 2, \text{Output: } O_{\text{Size}} \quad (6)$$

5) 配网预测模型的训练与验证。将不同分量的训练和验证数据集按顺序输入基于自注意力机制和小波分解的双向深度预测模型,进行模型的训练和验证。将输出值与真实值利用不同的误差函数比较计算误差。结束时绘制不同分量损失值的变化曲线,该曲线体现了模型的过拟合程度、收敛速度、预测精度。衡量模型预测性能指标选取的 4 个性能指标:平均绝对值误差函数 M_{AE} 、平均相对绝对值误差 M_{APE} 、均方根误差 R_{MSE} 和拟合系数 R^2 系数, M_{AE} 表示预测值与真实值之间绝对误差的平均值,其值越小,表明模型的预测精确度越高; M_{APE} 表示预测值与真实值之间绝对误差之间的平均值的百分比数值,其值越小,表明模型的预测精确度越高; R_{MSE} 表示预测值与真实值偏差的平方与观测次数 n 比值的平方根,其值越小,表明预测值与真实值之间的偏差越小,预测模型的回归效果更好; R^2 越大,表明模型的拟合效果越好,其中 R^2 系数结果仅作参考。

6) 配网功率预测模型的实际预测。将预测数据集输入训练和验证后的模型,最后使用不同误差函数计算预测模型的误差值,这些值体现了改进模型在实际场景下的预测性能。

还需说明的是,在处理训练数据集时要进行模型参数的更新优化,而处理验证和预测数据集则不用。本算例模型参数优化采用 Adam 算法^[20],对于不同小波分量的数据采用不同的学习率和不同的隐藏层维度。除此以外,模型的超参数中的学习率采用步进更新,以防止因学习率过大在训练后期模型过拟合。预测结束时绘制不同模型损失值的变换曲线,该曲线体现了模型的过拟合程度、收敛速

度、预测精度。最终实现的模型训练结构和网络结构如图 5 所示。

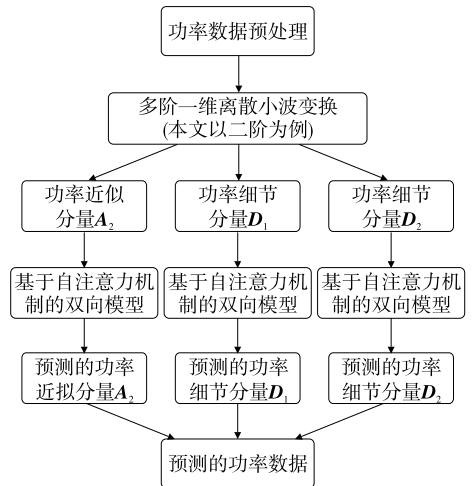


图 5 改进模型网络结构

Figure 5 Improved model structure diagram

3 算例分析

3.1 数据集的介绍和划分

实验数据集采用某市 2021 年 3 月和 4 月上半月的配电网中电能表采集到的有功、无功数据集。下面就数据集分别做详细介绍。

数据集文件格式:每个 xlsx 文件包含一天内某市部分电能表按配电网规划划分的有功、无功数据。每个区域电能表采到的数据分为有功数据和无功数据,通过 data_type 字段区分,电能表之间通过电能表标识区分。每个 xlsx 文件中根据对应的电能表和功率类型每天采集到 96 点数据(对应每 15 min)表格头部部分示例如表 1 所示。

表 1 有功、无功数据集示例表头

Table 1 Active power and reactive power datasets example table header

电能表标识	data_type	HH:MM
55800000048282649	无功	Value/NULL
558000000047040420	无功	Value/NULL
558000000049695429	有功	Value/NULL
558000000048284187	无功	Value/NULL

该数据集存在空值和错误值,因此在数据预处理阶段需要数据剔除的步骤。关于归一化问题,本文对于所采用的电能表功率数据数值大致处于 $[-3, 3]$,所以决定不采用归一化策略。根据数据

集描述,本文用 3 个数据点(45 min)来预测未来 1 个数据点(15 min)。将 3 月上半月、3 月下半月和 4 月上半月数据划分为等份的训练集、验证集和预测集,每份数据集大约 1 500 个样本。

3.2 模型超参数设置和优化

1)传统单向模型(下称“传统模型”)超参数设置。根据相关研究工作和前期实验,首先将初始学习率设置为 0.01;基础隐藏维度最终确定为 32,其优化方式如表 2 所示($E_{\text{epoch}}=400$);为了确定合适的调整步长,避免频繁调整学习率,将学习率调整步长间隔设置为 100;最终学习率调整参数调整为 0.6,其是通过保持初始学习率、隐藏层维度和调整步长间隔不变的控制变量法选择指标效果较好的原则得到的,而不出现明显的过拟合曲线。总训练步长为 1 200,在预训练中传统模型指标曲线在步长 400 才收敛,设置高训练步长使模型对比结果有足够的稳定性。此外有功和无功场景下模型超参数相同,改进模型同理。

表 2 有功、无功场景中步长 M_{AE} 随隐藏层维度变化

Table 2 Change table of step length M_{AE} with hidden layer dimension in active and reactive scenarios

隐藏层维度	有功 M_{AE}/kW	无功 $M_{\text{AE}}/\text{kvar}$
8	0.078 13	0.055 46
12	0.077 24	0.052 81
16	0.077 02	0.044 95
20	0.077 09	0.044 90
24	0.076 90	0.044 85
28	0.076 77	0.044 79
32	0.076 36	0.044 77
36	0.076 97	0.044 80
40	0.077 23	0.044 91
44	0.076 72	0.044 94
48	0.076 95	0.055 33

2)3 项改进模型(下称“改进模型”)超参数设置,仅对改动部分说明。小波参数设置:由于功率数据的样本量较多,考虑到对数据进行压缩处理,以尽可能支撑更多数据,最终选择消失矩阵中的常用小波基函数 db2,分解阶数为 2,防止阶数过大导致计算量激增。

对传统模型改进后,由于增加了新的模型结

构,需适当增大初始学习率,所以将 A_2 和 D_2 分量初始学习率设置为 0.012; D_1 分量初始学习率:0.01;对于变化较平稳的近似分量 A_2 采用稍小的隐藏层维度 12,为使波形变化加快,将学习率参数调整为 0.72,自注意力维度:24(注意长期的维度);对于变化波动较大的细节分量 D_1 采用更大的隐藏层维度 16,使数据波形缓慢变化,将学习率参数调整为 0.5,自注意力维度:8(注意近期的维度);对于细节分量 D_2 采用比 D_1 (较波动)更大的隐藏层维度:32,其波形需缓慢变化,将学习率参数调整为 0.7,自注意力维度:8(注意近期的维度)。

3.3 各模型性能结果及改进分析

需要说明的是结果评价指标 M_{AE} 、 R_{MSE} 在表格中的数值结果是描述有功功率的 kW 单位和无功功率的 kvar, M_{APE} 为百分比, R^2 为 $(-\infty, 1]$ 的实数。

首先介绍传统模型的功率预测结果,即未加入双向结构、小波变换和自注意力机制模型。选取 4 月上半月数据进行模型预测性能的评估,并将结果绘制成时间图,如图 6 所示。结合图 6,传统模型在数值平稳时间点都能进行较好的预测,但它们在预测峰值时刻的数据上却表现很差;而在无功预测结果(如图 7 所示)中,传统模型甚至连最基本的走势都无法判断。同时 4 种指标在预测集中或多或少出现不同程度的过拟合,除此以外在无功场景中的 M_{APE} 指标(如图 8 所示)一直在 20% 以上,且在迭代前期, M_{APE} 波形出现波动较大的情况,分析主要是由于本实验预测的数值较小,范围为 $[-3, 3]$,哪怕较小值的误差也会产生不小的 M_{APE} 误差,同样说明了传统模型在此场景下预测能力表现效果不佳,迭代前期不能稳定的收敛。最后在图 8 中以波形波动




图 6 4 月上半月有功功率传统模型预测曲线(1 d)

Figure 6 Active power prediction curve of traditional model in the first half of April (1 d)




图 7 4 月上半月无功功率传统模型预测曲线(1 d)

Figure 7 Reactive power prediction curve of traditional model in the first half of April (1 d)

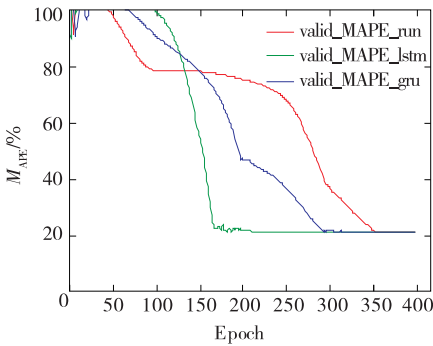


图 8 无功功率传统模型验证集 M_{APE} 变化曲线

Figure 8 Variation curve of reactive power traditional model verification set M_{APE}

大的形式呈现出来,同时也可看出传统模型的收敛速度和预测精度都比较差。结合上述分析,可以认为传统模型在配电网超短期功率预测领域确实存在如本文中提到的预测曲线失真、模型过拟合现象、预测精度不高以及收敛速度慢等问题,即在配电网超短期功率预测领域表现不佳。

接着介绍基于小波变换和双向结构两项改进的模型预测结果,如图 9~11 所示。

结合图 9~11 和预测集 4 项指标值(见表 3、4),基于小波变换和双向结构的改进后的模型大幅度提高了模型的精度和收敛速度。以 RNN 为为例,在有功预测集上 M_{AE} 下降了 44.1%; M_{APE} 由 5.531 61% 下降到了 3.462 20%; R_{MSE} 下降了 48.7%; R^2 由负值变为正值。预测曲线也近似贴合原始功率曲线,能够抓取绝大多数峰值数据;同时无功预测集中 M_{AE} 下降了 55.7%; M_{APE} 由 25.334 30% 下降到 9.499 86%; R_{MSE} 下降了 60.6%; R^2 也由负值变为正值。预测曲线也近似贴合原始功率曲线;预测集

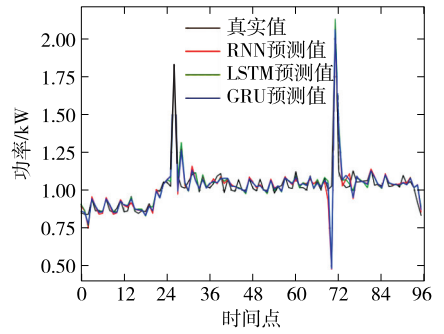


图 9 4 月上半月有功功率基于小波变换的双向模型预测曲线(1 d)

Figure 9 Active power based on wavelet transform in the first half of April bidirectional model prediction curve (1 d)




图 10 4 月上半月无功功率基于小波变换的双向模型预测曲线(1 d)

Figure 10 Reactive power based on wavelet transform in the first half of April bidirectional model prediction curve (1 d)




图 11 无功功率双向模型验证集 M_{APE} 变化曲线-A₂ 近似分量

Figure 11 Reactive power bidirectional model verification set M_{APE} variation curve-A₂ approximate component

中的指标过拟合现象得到明显改善(LSTM 和 GRU,RNN 最终也在步长 400 收敛), A_2 近似分量的 M_{APE} 指标如图 11 所示,其反弹相较平稳。这些预测结果图像说明基于小波变换和双向循环神经

网络模型的功率预测能力得到很大地加强,改善了传统模型的不足之处。此外本阶段使用了小波变换和双向结构,这时模型结构变得较为复杂,因此在同一硬件条件下,模型求解时间分别变为原来 3 倍/每样本每次训练和增加了 0.52 ms/每样本每次训练,但结合结果图可以认为两项改进带来的性能提升确实非常值得的。

由于使用双向结构和小波变换后的模型预测集表现曲线已到达足够精度以及模型 4 种误差曲线收敛相对稳定。因此之后对现有的几种不同改进的模型的 4 种性能指标不再绘制预测曲线,而将它们作对比绘制指标对比表,如表 3、4 所示,其中加粗的结果为在同一数据集中基于同一基础模型采用不同改进策略综合最优的一组结果。

表 3 有功数据集下传统模型及改进模型的性能指标对比

Table 3 Comparison of performance metrics of traditional and improved models with active datasets

传统模型	双向结构	小波变换	自注意力	M_{AE}/kW	$M_{APE}/\%$	R_{MSE}/kW	R^2
RNN	—	—	—	0.068 25	5.531 61	0.163 85	-1.436 72
	✓	—	—	0.068 44	5.553 65	0.162 57	-1.316 87
	—	✓	—	0.041 32	3.755 55	0.084 86	0.777 05
	—	—	✓	0.067 76	5.517 86	0.162 44	-1.007 42
	✓	✓	—	0.038 15	3.462 20	0.084 06	0.792 01
	—	✓	✓	0.040 40	3.622 52	0.091 75	0.734 07
	✓	—	✓	0.069 69	5.622 66	0.172 05	-0.526 48
CNN	✓	✓	✓	0.034 01	3.123 61	0.080 30	0.820 38
	—	—	—	0.067 48	5.451 14	0.162 54	-1.436 77
CNN+小波变换	—	—	—	0.041 85	3.826 53	0.090 23	0.765 04
LSTM	—	—	—	0.068 27	5.524 99	0.163 66	-1.456 88
	✓	—	—	0.068 69	5.556 65	0.163 05	-1.487 90
	—	✓	—	0.040 08	3.627 75	0.088 70	0.759 98
	—	—	✓	0.068 01	5.506 41	0.162 82	-1.347 18
	✓	✓	—	0.036 55	3.328 08	0.087 12	0.776 25
	—	✓	✓	0.041 05	3.714 67	0.087 97	0.762 25
	✓	—	✓	0.071 35	5.729 84	0.196 84	-0.792 43
CNN	✓	✓	✓	0.034 09	3.165 28	0.078 61	0.809 90
	—	—	—	0.068 05	5.501 55	0.163 35	-1.380 21
CNN+小波变换	—	—	—	0.037 25	3.390 88	0.085 15	0.789 05
GRU	—	—	—	0.068 62	5.553 10	0.162 99	-1.466 40
	✓	—	—	0.067 68	5.475 98	0.162 47	-1.352 14
	—	✓	—	0.041 02	3.730 75	0.087 78	0.765 36
	—	—	✓	0.068 25	5.524 50	0.162 66	-1.387 90
	✓	✓	—	0.037 36	3.328 08	0.083 27	0.797 52
	—	✓	✓	0.039 83	3.606 19	0.090 41	0.751 67
	✓	—	✓	0.069 95	5.740 60	0.164 30	-0.743 83
CNN	✓	✓	✓	0.034 30	3.116 60	0.080 99	0.803 40
	—	—	—	0.069 06	5.601 25	0.162 92	-1.318 60
CNN+小波变换	—	—	—	0.039 79	3.620 02	0.087 33	0.772 69

表 4 无功数据集下传统模型及改进模型的性能指标对比

Table 1 Comparison of performance metrics of traditional and improved models with reactive datasets

传统模型	双向结构	小波变换	自注意力	M_{AE}/kvar	$M_{APE}/\%$	R_{MSE}/kvar	R^2
RNN	—	—	—	0.055 02	25.334 30	0.085 16	-0.259 19
	✓	—	—	0.055 12	25.406 88	0.082 83	-0.667 17
	—	✓	—	0.025 79	9.489 88	0.033 66	0.861 26
	—	—	✓	0.050 76	23.702 39	0.078 47	-0.558 45
	✓	✓	—	0.024 36	9.499 86	0.033 53	0.864 51
	—	✓	✓	0.025 55	9.813 21	0.033 91	0.859 72
	✓	—	✓	0.055 51	26.185 28	0.083 64	-0.965 95
CNN	✓	✓	✓	0.017 29	6.574 11	0.029 00	0.899 67
	—	—	—	0.055 12	25.097 58	0.083 37	-0.541 41
CNN+小波变换	—	—	—	0.028 62	11.113 06	0.037 60	0.827 02
LSTM	—	—	—	0.054 24	24.638 23	0.084 46	-0.346 04
	✓	—	—	0.055 05	24.841 69	0.083 36	-0.463 13
	—	✓	—	0.028 05	12.447 47	0.038 35	0.854 82
	—	—	✓	0.051 24	24.717 57	0.079 92	0.097 19
	✓	✓	—	0.024 47	11.127 09	0.037 68	0.861 55
	—	✓	✓	0.026 29	11.362 34	0.037 66	0.856 81
	✓	—	✓	0.058 00	28.338 91	0.086 62	-1.991 33
CNN	✓	✓	✓	0.025 72	11.136 91	0.037 06	0.860 01
	—	—	—	0.054 64	24.656 26	0.083 35	-0.251 57
CNN+小波变换	—	—	—	0.025 34	9.834 29	0.036 31	0.831 03
GRU	—	—	—	0.055 48	25.658 71	0.084 56	-0.153 12
	✓	—	—	0.055 54	26.103 97	0.084 18	-0.029 77
	—	✓	—	0.026 91	11.282 24	0.035 66	0.857 73
	—	—	✓	0.051 45	24.802 94	0.079 98	0.100 86
	✓	✓	—	0.025 06	10.452 90	0.035 52	0.861 12
	—	✓	✓	0.027 40	11.588 65	0.036 27	0.857 14
	✓	—	✓	0.054 93	25.061 18	0.083 93	-0.544 88
CNN	✓	✓	✓	0.022 04	9.583 60	0.035 27	0.876 00
	—	—	—	0.056 11	26.509 59	0.085 56	-0.074 35
CNN+小波变换	—	—	—	0.026 24	11.062 41	0.037 45	0.850 41

综合考虑有功和无功的 2 种场景对比,可以认为小波变换改进相对传统模型有巨大提升,自注意力和双向结构改进提升次之。相比于只加入双向结构或自注意力机制(求解时间增加了 4.3 ms/每样本每次训练),改进的模型指标效果有时反而变差,在小波变换改进基础上加入双向结构或自注意力机制,3 种基本单向模型性能指标都有正向提升,

分析认为是小波变换平滑了数据的波动,分解了直接预测的难度和改善了过拟合现象,为其他 2 项改进铺平道路。因此本文中这 3 项改进在“组预测”的策略下是不可分割的,即本文为双向结构和自注意力机制在循环神经网络的融合提供了一种新的预测策略。根据模型预测集的结果指标,其中改进模型中 RNN 相比其他 2 种模型,在 2 种场景都表现

出不错成绩,原因是对于有规律的预测小特征维度问题,内部结构不需要像 LSTM 和 GRU 复杂即可完成实际需求。从表 4 中还可以看出,在现有 CNN 改进系列同样证明了“组策略”下若单项改进提升不明显,则可以通过小波变换来实现多重提升的思路。

4 结语

本文提出了基于小波变换和自注意力机制的双向循环神经网络在配电网超短期功率预测领域应用的改进模型,并且根据有功和无功数据集对现有的改进循环神经网络模型进行了不同程度的对比,证明了本文提出 3 项改进的有效性和可靠性。

1)展示传统模型在配电网超短期功率预测中的不足,即模型相较改进后出现的过拟合现象、非常差的预测精度和缓慢的收敛速度;证明了传统深度模型在配电网超短期功率预测领域应用的差距。

2)展示改进模型改善了传统模型存在的问题,根据 2 张对比表可以得出小波变换改善相比最大,自注意力和双向结构次之。同时在“组预测”的策略下,小波变换能较好地缓解单独使用双向结构或自注意力机制的负优化的问题,即本文为双向结构和自注意力机制在循环神经网络的融合提供了一种新的预测策略。

3)改进模型可用于实际的配电网超短期功率预测。为配电网应对波动性功率变化提供运维和调控的较为可靠的数据指导,从而维持配电网系统的稳定运行。下一步研究可以针对不同小波分量采用不同改进模型进行研究以及小波变换和其他改进之间的参数设置是如何相互影响的。

参考文献:

[1] 黄伟,刘琦,杨舒文,等.基于主动配电系统供电能力的安全态势感知方法[J].电力自动化设备,2017,37(8):74-80.
HUANG Wei, LIU Qi, YANG Shuwen, et al. Security situation awareness based on power-supply ability model of active distribution system[J]. Electric Power Automation Equipment, 2017, 37(8): 74-80.

[2] 杨肖虎,罗剑波,郁琛,等.适应大规模新能源并网的电

力系统备用配置及优化综述[J].电力工程技术,2020,39(1):10-20+63.

YANG Xiaohu, LUO Jianbo, YU Chen, et al. Review of power system reserve configuration and optimization for large-scale renewable energy integration[J]. Electric Power Engineering Technology, 2020, 39(1): 10-20+63.

[3] 刘威,张东霞,王新迎,等.基于深度强化学习的电网紧急控制策略研究[J].中国电机工程学报,2018,38(1):109-119+347.

LIU Wei, ZHANG Dongxia, WANG Xinying, et al. A decision making strategy for generating unit tripping under emergency circumstances based on deep reinforcement learning[J]. Proceedings of the CSEE, 2018, 38(1): 109-119+347.

[4] 江秀臣,盛戈皞.电力设备状态大数据分析的研究和应用[J].高电压技术,2018,44(4):1041-1050.

JIANG Xiuchen, SHENG Gehao. Research and application of big data analysis of power equipment condition [J]. High Voltage Engineering, 2018, 44(4): 1041-1050.

[5] 冷华,陈鸿琳,李欣然,等.基于功率或电量预测的智能配电网统计线损同期化方法[J].电力系统保护与控制,2016,44(18):108-114.

LENG Hua, CHEN Honglin, LI Xinran, et al. A method for synchronous line loss statistics of distribution network based on load or electricity consumption forecasting[J]. Power System Protection and Control, 2016, 44(18): 108-114.

[6] 李正浩,李孟凡.基于深度学习的智能型负荷预测方法的研究[J].智慧电力,2020,48(10):78-85+112.

LI Zhenghao, LI Mengfan. Smart load forecasting method based on deep learning[J]. Smart Power, 2020, 48(10): 78-85+112.

[7] 牛哲文,余泽远,李波,等.基于深度门控循环单元神经网络的短期风功率预测模型[J].电力自动化设备,2018,38(5):36-42.

NIU Zhewen, YU Zeyuan, LI Bo, et al. Short-term wind power forecasting model based on deep gated recurrent unit neural network[J]. Electric Automation Equipment, 2018, 38(5): 36-42.

[8] 赵兵,王增平,纪维佳,等.基于注意力机制的 CNN-GRU 短期电力负荷预测方法[J].电网技术,2019,43(12):4370-4376.

ZHAO Bing, WANG Zengping, JI Weijia, et al. A short-term power load forecasting method based on attention

- mechanism of CNN-GRU[J]. Power System Technology, 2019, 43(12): 4370-4376.
- [9] 杨子民, 彭小圣, 郎建勋, 等. 基于集群动态划分与 BLSTM 深度学习的风电集群短期功率预测[J]. 高电压技术, 2021, 47(4): 1195-1203.
YANG Zimin, PENG Xiaosheng, LANG Jianxun, et al. Short-term wind power prediction based on dynamic cluster division and BLSTM deep learning method [J]. High Voltage Engineering, 2021, 47(4): 1195-1203.
- [10] 肖白, 肖志峰, 姜卓, 等. 基于降噪自编码器、奇异谱分析和长短期记忆神经网络的空间电力负荷态势感知[J]. 中国电机工程学报 2021, 41(14): 4858-4867.
XIAO Bai, XIAO Zhifeng, JIANG Zhuo, et al. Spatial load situation awareness based on denoising autoencoder, singular spectrum analysis and long short-term memory neural networks[J]. Proceedings of the CSEE, 2021, 41(14): 4858-4867.
- [11] 王婧骅, 张娟, 赵婉茹, 等. 基于时间序列的分布式光伏电站发电数据采集方法[J]. 电网与清洁能源, 2022, 38(6): 137-142.
WANG Jinghua, ZHANG Juan, ZHAO Wanru, et al. A method for collecting power generation data of distributed photovoltaic power station based on time series [J]. Power System and Clean Energy, 2022, 38(6): 137-142.
- [12] 谢小瑜, 周俊煌, 张勇军. 深度学习在泛在电力物联网中的应用与挑战[J]. 电力自动化设备, 2020, 40(4): 77-87.
XIE Xiaoyu, ZHOU Junhuang, ZHANG Yongjun. Application and challenge of deep learning in ubiquitous power internet of things[J]. Electric Power Automation Equipment, 2020, 40(4): 77-87.
- [13] BENGIO Y, SIMARD P, FRASCONI P. Learning long-term dependencies with gradient descent is difficult [J]. IEEE Transactions on Neural Networks, 1994, 5(2): 157-66.
- [14] 陈铁, 陈卫东, 李咸善, 等. 基于 EMD 和 GCT 的变压器油中溶解气体预测[J]. 高压电器, 2022, 58(4): 70-79.
CHEN Tie, CHEN Wedong, LI Xianshan, et al. Dissolved gas prediction in transformer oil based on EMD and GCT[J]. High Voltage Apparatus, 2022, 58(4): 70-79.
- [15] CHO K, VAN MERRIENBOER B, GULCEHRE C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation [C]// Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing, Doha, Qatar, 2014.
- [16] 胡翀, 徐斌, 甄超, 等. 基于电压暂降监测数据的敏感负荷非侵入式识别方法[J]. 中国电力, 2021, 54(8): 35-42+51.
HU Chong, XU Bin, ZHEN Chao, et al. A non-invasive identification method for sensitive load based on voltage sag monitoring data[J]. Electric Power, 2021, 54(8): 35-42+51.
- [17] 吕新华, 武斌, 攸阳, 等. 小波变换 Mallat 算法实现中的边界延拓研究[J]. 天津理工大学学报, 2006, 22(2): 14-17.
LU Xinhua, WU Bin, YOU Yang, et al. Border extension in the implementation of Mallat algorithm[J]. Journal of Tianjin University of Technology, 2006, 22(2): 14-17.
- [18] 谢小瑜, 周俊煌, 张勇军, 等. 基于 W-BiLSTM 的可再生能源超短期发电功率预测方法[J]. 电力系统自动化, 2021, 45(8): 175-184.
XIE Xiaoyu, ZHOU Junhuang, ZHANG Yongjun, et al. W-BiLSTM based ultra-short-term generation power prediction method of renewable energy[J]. Automation of Electric Power Systems, 2021, 45(8): 175-184.
- [19] 王伟, 张彦龙, 翟登辉, 等. 基于 OpenCV+SSD 深度学习模型的变电站压板状态智能识别[J]. 电测与仪表, 2022, 59(1): 106-112.
WANG Wei, ZHANG Yanlong, ZHAI Denghui, et al. Intelligent identification of substation pressure plate state based on OpenCV+SSD deep learning model[J]. Electrical Measurement & Instrumentation, 2022, 59(1): 106-112.
- [20] 彭曙蓉, 黄士峻, 李彬, 等. 基于深度学习分位数回归模型的充电桩负荷预测[J]. 电力系统保护与控制, 2020, 48(2): 44-50.
PENG Shurong, HUANG Shijun, LI Bin, et al. Charging pile load prediction based on deep learning quantile regression model[J]. Power System Protection and Control, 2020, 48(2): 44-50.