

基于卷积神经网络特征提取的风电功率爬坡预测

景惠甜, 韩 丽, 高志宇

(中国矿业大学电气与动力工程学院, 江苏省徐州市 221116)

摘要: 为提高风电功率爬坡预测的准确性,提出了一种基于卷积神经网络、长短期记忆网络和注意力机制的风电功率爬坡预测方法。首先,针对风电功率爬坡发生次数少、特征复杂、预测模型难以对小样本爬坡事件有效学习的问题,使用卷积神经网络对风电功率序列进行特征提取。然后,使用长短期记忆网络建立预测模型,解决风电功率的长时依赖问题,并在模型中加入注意力机制对长短期记忆网络单元的输出生成进行加权,从而加强风电特征的学习,提高爬坡预测准确度。仿真验证表明,模型对风电功率爬坡预测有较高的准确性。

关键词: 风电功率爬坡预测; 卷积神经网络; 长短期记忆网络; 注意力机制; 风电爬坡

0 引言

近年来,随着环境污染的加重和化石能源的日益减少,开发新的替代能源成为研究热点。其中,风能以其高效清洁的特点获得了国内外的青睐。但是,风能具有很强的随机性和间歇性^[1-2],尤其是当发生长时间的极端气象天气,爬坡事件极易发生。风电爬坡是指一段时间内,风电功率发生大幅度的波动,风电爬坡使电力系统维持功率和频率的稳定更加困难,给风电的并网和调度带来了巨大的挑战^[3-7]。为了减少爬坡事件对系统的影响,需要对爬坡预测的方法进行研究。目前,最常见的爬坡预测方法是基于历史数据进行预测^[8-9]。为了提升预测的精度,也有研究将气象预测数据和统计模型相结合^[10-11]。由于风能的特性受多种因素的影响,简单的预测方法无法准确捕捉爬坡特性,这就要求不断研究新的方法以更加准确地获取风电的爬坡特征^[12-14]。

深度学习网络具有强大的深度特征提取能力,其中,长短期记忆(long short-term memory, LSTM)网络^[15-18]和卷积神经网络(convolutional neural network, CNN)在风电功率预测方面已经有了很广泛的应用^[19-20],所以本文采用了以CNN为基础的深度学习模型进行特征提取和爬坡预测。特征提取的本质是通过一个特定的评价标准衡量一个给定特征子集的优良性。通过特征选择,原始特征集合中的冗余

特征和不相关特征被除去,而有用特征得以保留。CNN在图像识别方面有强大的功能,其中特征提取层的参数可以通过训练数据学习得到,避免了人工提取特征,其同一特征图的神经元可以共享权值,从而可以减少网络参数。CNN善于挖掘数据局部特征,具有极强的适应性^[19]。注意力机制(attention mechanism, AM)最早用在图像处理领域,每个输入是具有相应注意力的权重,这些注意力权重在输出后进行重新计算,使得网络的注意力能随着输入的推移而改变,在模型训练时让神经网络高度关注某些信息。由于风电爬坡场景少,其特征信号容易淹没在大量其他特征中,采用AM来加强对爬坡特征的学习,能有效提高预测模型精度。现有的AM需要人为设置打分函数^[21-22],难以适应对复杂风电信号中爬坡特征的学习。为此,本文通过全连接层直接构造AM,AM的权重在对风电信号学习过程中通过训练得出,以加强风电爬坡的特征。

本文提出了基于CNN和LSTM的风电功率爬坡预测方法,针对风电爬坡特征难以提取及学习的难题,提出用AM来强化对风电爬坡特征的学习,并针对AM权重须人为设置的局限,提出采用全连接层构造AM的权重,保证对爬坡特征的有效学习。仿真验证表明,本文提出的模型有较好的特征提取和预测能力。

1 风电功率爬坡事件

风电功率爬坡事件主要指长时间极端天气引起的短时间内风电功率发生大幅度的变化。当出现强烈低压系统(或气旋)、低空急流、雷阵雨、阵风或类

收稿日期: 2020-02-27; 修回日期: 2020-06-17。
上网日期: 2020-12-28。
国家自然科学基金资助项目(61703404)。

似的长期极端气象事件时,会造成风电场一段时间内功率骤增,发生上爬坡事件;当出现相对气象事件或风速较高超过切出风速,部分风机陆续退出运行时,风电场一段时间内功率骤降,发生下爬坡事件^[23-26]。风电功率的急剧变化对电网造成很大的不利影响,如频率失稳等。

文献[24]给出了定义爬坡事件的5个表征量,如附录A图A1所示。

- 1)幅度变化 ΔP_r ,风电功率的变化值。
- 2)持续时间 Δt ,大幅功率波动持续时间。
- 3)爬坡率 $\Delta P_r/\Delta t$,风电功率变化速率。
- 4)开始时间 t_0 ,既可以定义为爬坡事件开始的时间,也可以定义为爬坡事件的中段时间。
- 5)爬坡方向,功率增大为上爬坡,减小为下爬坡。

本文采用文献[24]给出的爬坡定义:

$$|P_{t+\Delta t} - P_t| > P_{\text{threshold}} \quad (1)$$

式中: P_t 和 $P_{t+\Delta t}$ 分别为 t 和 $t+\Delta t$ 时刻的风电功率; $P_{\text{threshold}}$ 为功率阈值。 $P_{t+\Delta t} - P_t > P_{\text{threshold}}$ 表示发生了上爬坡, $P_{t+\Delta t} - P_t < -P_{\text{threshold}}$ 表示发生了下爬坡,具体内容见附录A图A2。

2 基于CNN特征提取的风电预测

2.1 基本原理

2.1.1 CNN基本原理

提取风电信号的深层特征对于风电功率爬坡预测具有非常重大的意义。CNN可以模仿人类的视觉感知机制,从而有效地提取原始图像的特征。CNN通常是由卷积层、池化层和全连接层组成。其中,卷积层是CNN最重要的部分。CNN将传统神经网络中至少一层的常规矩阵乘法替换为卷积,即CNN是对传统神经网络的改进。在卷积层中,采用滤波器对输入进行卷积操作,每个滤波器的实质是一个较小的矩阵,在卷积操作之后可得到相应的特征图。CNN可以自动创建滤波器,并建立稠密、完备的特征向量,被已有研究证实了是提取数据深层特征的一种非常可靠的方法。在同一个卷积层中,除了权值是共享的之外,各个神经元之间没有联系。因此,相对于有相同层数和神经元个数的多层感知机,CNN的效率更高。每个卷积层都可以用式(2)来表示^[20]:

$$h_{ij}^k = f((W^k * x)_{ij} + b_k) \quad (2)$$

式中: x 为卷积层的输入向量; h_{ij}^k 为位置为第 i 行、第 j 列的卷积层输出向量; f 为激活函数; W^k 为连接到第 k 个特征图的卷积核的权重矩阵; b_k 为该特征图

的偏置向量;*表示卷积运算。

附录A图A3为一维卷积运算,输入为 $x_1, x_2, \dots, x_6$,一维卷积后得到的特征图为 c_1, c_2, c_3, c_4 ,输入和特征图通过不同颜色的线条连接,相同颜色的线条代表权重是共享的,图中只需要3个权重值即可执行卷积运算。因为权重的数目相比全连接结构少,CNN的训练就相对容易,从而可以有效提取重要特征。

本文模型采用了3个卷积层,每层分别包含4,16,32个滤波器,故而每层可以分别输出4,16,32个特征图。

池化层是CNN的另一个特殊的层,可以通过将网络特定位置的输出替换为附近数据的统计量而保留主要特征,同时减少下一层的参数和计算量,防止过拟合。池化的方法主要包括最大池化和平均池化,最大池化可以得到邻域内的最大值,即可以得到经卷积特征提取后最重要的特征,同时最大池化也对卷积层提取到的数据特征进行了降维,减少后续LSTM层数据输入个数,有效地减少计算量,所以本文选取了最大池化。

在CNN中,每个卷积核所对应的卷积层其实就是用于判断输入特征的系统,但是对于要判断特征的系统的运行法则是不清楚的,所以通过误差反向传播的方式不断调整卷积核的参数,使得在训练后调整参数的卷积核能够完成当前卷积层判断输入特征的工作。当所有的单个卷积层都能够有效完成特征判断的任务时,由一定数量卷积层所组成的复杂系统的CNN就能完成所需的复杂特征的提取。

对于图像识别来说,附近的像素有很强的关联性,同样地,对风电功率时间序列,时间上邻近的功率点 also 具有很强的相关性。虽然CNN是一个前馈神经网络,但它的卷积层可以提取附近和相关的输入元素的关系,这样的特点可以用来建立风电的特征提取模型。综上所述,当附近的数据点有很强的相互关系时,CNN可以捕捉到局部趋势和局部变量的特征,因此可以用来提取附近时段的风电功率的特性,如爬坡特性。

2.1.2 LSTM网络基本原理

LSTM网络在循环神经网络的基础上增加了单元状态 c ,保存长期的状态,成功解决了循环神经网络训练时梯度消失和爆炸的缺陷。

已知输入序列为 $X = [x_1, x_2, \dots, x_T]$, T 为输入序列的长度。递归隐层按照时刻 $t = 1, 2, \dots, T$ 依次计算3个门和记忆单元的激活值。 t 时刻的计算式如下^[19]。

输入门:

$$i_t = \sigma(W_{ix}x_t + W_{ih}h_{t-1} + W_{ic}c_{t-1} + b_i) \quad (3)$$

式中: W_{ix} 为输入门与输入向量的权重矩阵; W_{ih} 为输入门与上一时刻中间状态向量 h_{t-1} 的权重矩阵; W_{ic} 为输入门与上一时刻记忆单元 c_{t-1} 的权重矩阵; b_i 为输入门的偏置向量; σ 为 Sigmoid 非线性函数。

忘记门:

$$f_t = \sigma(W_{fx}x_t + W_{fh}h_{t-1} + W_{fc}c_{t-1} + b_f) \quad (4)$$

式中: W_{fx} , W_{fh} , W_{fc} 分别为忘记门与 x_t , h_{t-1} , c_{t-1} 的权重矩阵; b_f 为忘记门的偏置向量。

记忆单元:

$$c_t = f_t c_{t-1} + i_t \phi(W_{ch}h_{t-1} + W_{cx}x_t + b_c) \quad (5)$$

式中: W_{cx} , W_{ch} 分别为记忆单元与 x_t , h_{t-1} 的权重矩阵; ϕ 为双曲正切函数; b_c 为记忆单元偏置向量。

输出门:

$$o_t = \sigma(W_{ox}x_t + W_{oh}h_{t-1} + W_{oc}c_{t-1} + b_o) \quad (6)$$

式中: W_{ox} , W_{oh} , W_{oc} 分别为输出门与 x_t , h_{t-1} , c_{t-1} 的权重矩阵; b_o 为输出门偏置向量。

隐层输出:

$$h_t = o_t \phi(c_t) \quad (7)$$

本文采用的 LSTM 层包含 64 个神经元, 输入为 32 个向量, 输出为 64 个向量, 激活函数为线性整流函数(rectified linear unit, ReLU), 定义如下^[20]:

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

式中: x 为 ReLU 的输入变量。

具体的模型参数见附录 A 表 A1。

2.1.3 AM 基本原理

注意力是一个相似性的量度, 当前的输入与目标状态越相似, 当前输入的权重就会越大, 说明当前的输出越依赖于当前的输入。注意力的本质是加权求和。假设有 m 个 d 维的特征向量 h_i ($i = 1, 2, \dots, m$), 整合这 k 个特征向量的信息, 整合后的向量设为 h^* (一般也是 d 维), 一个简单的方法是这 k 个向量点乘取平均, 得到新的向量, 更合理的方法是加权平均, 即:

$$h^* = \sum_{i=1}^k \alpha_i h_i \quad (9)$$

式中: α_i 为权重。AM 的目的就是得出一个合理的 α_i 。

α_i 的求取一般分 2 个步骤:

1) 设计一个打分函数 g , 针对每个 h_i ($i = 1, 2, \dots, k$), 计算出一个分数 s_i , 打分依据是 h_i 与所关注对象的相关程度, 越相关所得 s_i 值越大。

2) 对所得的 k 个分数 s_i , 通过 softmax 函数, 得到最后的权重 α_i , 即:

$$\alpha_i = \text{softmax}(s_i) \quad (10)$$

本文采取的 AM 通过在 LSTM 层和神经元个数为 1 的全连接层之间增加节点数和 LSTM 层单元数相同的全连接层来构造, 即:

$$\alpha = \sigma(W_a h_t + b_a) \quad (11)$$

式中: h_t 为当前时刻 LSTM 层的输出向量; W_a 为注意力权重矩阵; b_a 为注意力偏置向量。

LSTM 层每个神经元的输出对当前网络的输出的重要程度是不同的, 网络结构中的 AM 负责自动学习注意力权重, 可以用来衡量 LSTM 层输出对于网络输出的重要程度, 即用 LSTM 层输出和网络输出作为 AM 的输入, 进而学习 α_i 关于两者的函数, 而通过学习得到的 α_i 可以反映两者的相关性。

2.2 CNN-LSTM-AM 模型

本文提出的 CNN-LSTM-AM 模型以风电功率时间序列作为网络的输入。参考自然语言中词向量的表示方法, 将某一时刻的风电功率值以单个向量的形式输入, 再用滑动时间窗口的方式依次将输入的时间序列数据生成特征图从而进行后续的计算, 充分发挥 CNN 模型的潜在特征提取优势, 从而挖掘数据中蕴含的更多有效信息。

风电爬坡的特征信号容易淹没在大量随机紊乱的数据中, 普通模型很难建立从风电数据输入到爬坡识别输出的映射关系, 模型的精度必然不高, 所以本文通过 3 个部分对风电功率的爬坡特性进行提取和加强。

风电功率信号经 CNN 识别后提取出的爬坡特征作为 LSTM 层的输入, LSTM 层所特有的 3 个门和记忆单元可以对 CNN 提取到的爬坡特征进行进一步的筛选, 使重要的特征通过记忆单元得到保留, 不重要的特征通过忘记门进行遗忘, 最后通过 AM 对 LSTM 层的输出进行加权, 进一步突出重要的特征。

爬坡数据相当于模式突变, 发生次数又较少, 预测模型无法对其有效学习, 必然不能有效判断。若未经 CNN 识别, 风电数据直接输入 LSTM 层, 风电爬坡的特征信号容易淹没在大量其他特征中, 通过 CNN 爬坡特征被清晰准确地提取出来, 因而使爬坡识别更为准确。所以, 利用 CNN 识别是本文方法取得较好识别效果的关键。

由于风电功率较强的随机性, 导致多步预测困难且准确性普遍不高, 在风电功率实时预测中, 下一个采样点的结果是未知的, 是否发生长时间功率爬坡无法确定, 所以预测选相邻的时间点更为准确。

卷积层特征提取的过程见附录 A 图 A4。本文

主要研究发生爬坡时CNN对于数据的处理能力,即当数据发生突变时,CNN所提取到的特征图,所以截取该段数据进行有针对性的说明。图1(a)、(b)和(c)分别是由3个卷积层处理后得到的数据绘制成的图像,横轴代表按采样时间顺序排列的样本点,样本点之间的时间间隔相同,纵轴代表该时刻归一化的风电功率值。




图1 卷积层输出
Fig. 1 Output of convolutional layers

由图1可知,在发生下爬坡事件的样本附近,3个卷积层输出的特征均发生了突变,其中第1个卷积层由于滤波器的个数较少,导致提取到的特征不够全面,从而第1,4个滤波器未提取到特征,第3个滤波器提取到的特征不准确(图1(a))。通过对16个滤波器提取到的特征进行对比后发现,在经过第2个卷积层的特征提取后,基本每个卷积层都能很好地提取到特征(图1(b))。经过第3个卷积层的特征提取后,虽然在发生爬坡的样本附近提取到的特征也发生了突变,但是输出的特征没有能很好地跟随原始样本的变化趋势,通过图1(b)和(c)的对比发现,原始数据在样本区间[210,230]是下降趋势,图1(b)整体也呈下降趋势,但图1(c)中除了发生突变的位置外,数据的趋势较为平稳,说明3个卷积层足够可以捕捉发生爬坡时风电的特性。

综上所述,当附近的数据点有很强的相互关系时,CNN可以捕捉到局部趋势和局部变量的特征,因此可以用来提取附近时段的风电功率爬坡特性。

由附录A图A5可以看出,假设当前的输出为 y_t ,通过训练的方式,让模型自动学习重要的值,可以算出每一个输入(即由LSTM单元组成的隐藏层的输出)与当前输出 y_t 的关联度,比较重要的输入会通过较大的权重 α 得到加强,在风电功率爬坡预测输出时会占较大的比重,同时不重要的会被减弱,从而在一定程度上提高了预测的准确性。

图2所示为AM的部分权重,通过对所有权重进行比较,可以得到大部分样本点第63个权重最大,说明LSTM的第63个神经元的输出最为重要,也就是说,网络输出和LSTM层的第63个神经元输出关联度最大。




图2 注意力层权重
Fig. 2 Weights of attention layer

用全连接层构造AM,将LSTM层的输出作为AM层的输入,计算权重,将权重与LSTM层的输出相乘得到最后全连接层的输入,最终经过全连接层

输出结果。

综上所述,本文首先对原始的风电功率序列进行了深层特征提取。池化层的输出作为LSTM层的输入,LSTM层的输出作为AM层的输入,通过训练得到AM层的权重后,与LSTM层的输出相乘,为LSTM层的输出分配权重。梯度下降法作为优化函数,通过全连接层得到输出,进而得到预测结果。模型具体结构见附录A图A6。图中 n 为每次输入模型的风电功率时间序列长度, P_{t-n} 为 $t-n$ 时刻的风电功率数值。

3 仿真研究

为验证模型的科学性和可靠性,本文采用了ELIA网站^[27]和NREL网站的风电功率数据作为数据集。式(1)中, $P_{\text{threshold}}$ 取3%的装机容量,用ELIA数据验证时, Δt 取15 min,用NREL数据验证时, Δt 取5 min。

本文采用Python作为编程语言,编译环境为JetBrains PyCharm 2018, RAM为4 GB,处理器为Intel Core i5-8250U。

3.1 模型预测性能评估

选取4个季度,每个季度2 000个样本对模型进行测试,50%作为训练集,50%作为测试集。

本次采用min-max标准化将原始数据进行线性变换,将数据大小约束在 $[0,1]$ 。为了测试模型的预测效果,选取了3个标准,分别为平均绝对百分比误差(mean absolute percentage error, MAPE)、平均绝对误差(mean absolute error, MAE)、均方根误差(root mean square error, RMSE)^[16]。

根据表1中ELIA预测结果,4个季度中反向传播神经网络^[28](back propagation neural network, BPNN)、埃尔曼神经网络(Elman neural network, ENN)的预测MAPE都大于CNN-LSTM-AM模型, RMSE和MAE结论相同,且本文模型4个季度模型预测MAPE均在6%以下。其中, ENN 4个季度的预测MAPE超过了10%,说明ENN在风电预测方面的精确度低,且CNN, LSTM, AM单独预测时的MAPE均大于组合模型,从而说明了本文模型预测风电功率有很好的精度。

根据附录A表A2中NREL预测结果,4个季度CNN-LSTM-AM模型的MAPE均在其余对比模型之下,且低于6%, AM除了第1季度外,其余季度MAPE均在10%以上, ENN第2季度MAPE甚至超过了20%,进一步说明了本文所提出模型在风电功率预测方面有良好的精度。

表1 ELIA不同方法预测误差对比
Table 1 Forecast error comparison of ELIA between different algorithms

算法	季度	MAPE/%	RMSE	MAE
CNN-LSTM-AM	第1季度	4.91	44.97	35.48
	第2季度	4.64	37.47	24.44
	第3季度	5.35	37.31	25.78
	第4季度	4.68	61.92	48.42
BPNN	第1季度	6.20	62.13	44.81
	第2季度	9.12	73.61	47.68
	第3季度	11.30	82.91	55.69
	第4季度	6.38	96.42	68.68
ENN	第1季度	11.96	120.40	86.38
	第2季度	15.59	117.78	81.49
	第3季度	18.10	134.36	88.99
	第4季度	11.10	166.82	119.34
CNN	第1季度	8.04	72.87	58.11
	第2季度	7.93	55.73	41.84
	第3季度	6.40	43.37	30.80
	第4季度	5.93	76.81	61.28
LSTM	第1季度	9.15	85.79	66.07
	第2季度	9.72	71.93	51.26
	第3季度	11.48	75.35	55.25
	第4季度	7.13	97.42	73.66
AM	第1季度	11.86	102.04	85.67
	第2季度	12.50	84.72	65.87
	第3季度	14.73	90.42	70.92
	第4季度	9.80	127.43	101.54

3.2 模型爬坡预测性能评估

本文选取了4个季度验证模型对爬坡的提取能力,并与BPNN, ENN, CNN, LSTM以及包含AM的神经网络的爬坡预测能力作对比,正确率、漏报率、误报率以及错报率^[29]见表2。从表2中可以看到本文模型的错报率均小于等于0.1%,对比模型的错报率大部分都在0.1%之上,且模型的漏报率均在2%以下,误报率均在5%以下。和单个模型的爬坡预测相比, CNN-LSTM-AM模型有效减少了单个模型爬坡预测的错报率,且第3季度和第4季度的准确率均有所提升,其中第4季度相比CNN, LSTM, AM爬坡预测正确率分别提升了8.2%, 5.7%, 5.6%。综合表1和表2可以看出,虽然第1, 2季度CNN-LSTM-AM模型爬坡预测正确率有所下降,但第1季度最大下降不超过3.6%,第2季度不超过1%,而且对于点预测的误差, CNN-LSTM-AM模型4个季度的MAPE均小于单个模型点预测的MAPE,所以从综合的角度来看, CNN-LSTM-AM组合模型的性能优于单个模型的性能。

表2 ELIA不同算法爬坡指标对比
Table 2 Ramp indices comparison of ELIA
between different algorithms

算法	季度	正确率/%	漏报率/%	误报率/%	错报率/%
CNN-LSTM-AM	第1季度	93.7	1.5	4.8	0
	第2季度	96.5	1.8	1.6	0.1
	第3季度	99.0	0.4	0.6	0
	第4季度	99.4	0.5	0.1	0
BPNN	第1季度	93.0	2.5	4.4	0.1
	第2季度	93.5	1.5	4.4	0.6
	第3季度	92.0	2.3	5.6	0.1
	第4季度	96.3	0.1	3.6	0
ENN	第1季度	93.4	2.1	4.0	0.5
	第2季度	95.9	1.4	2.0	0.7
	第3季度	92.2	2.5	5.1	0.2
	第4季度	95.5	0.2	4.3	0
CNN	第1季度	95.7	1.9	2.4	0
	第2季度	97.0	1.7	1.2	0.1
	第3季度	96.4	0.2	1.7	0
	第4季度	91.2	4.9	3.9	0
LSTM	第1季度	95.7	2.5	1.8	0
	第2季度	96.9	2.1	0.7	0.3
	第3季度	96.4	2.4	1.1	0.1
	第4季度	93.7	5.1	1.1	0.1
AM	第1季度	97.3	2.6	0.1	0
	第2季度	97.5	2.2	0.1	0.2
	第3季度	96.4	2.3	1.2	0.1
	第4季度	93.8	5.2	0.9	0.1

从附录A表A3中可以看到,4个季度中CNN-LSTM-AM的准确率比BPNN,ENN都高,且错报率均在2%以下,BPNN的错报率最高达到了7.4%。和单个模型的爬坡预测指标相比,CNN-LSTM-AM模型减少了单个模型的错报率,其中,和LSTM,AM相比,4个季度的漏报率均有所下降。

从附录A表A4可以看到加入CNN后,由于CNN的权重共享以及最大池化,CNN-LSTM-AM模型的运行速度明显高于LSTM模型的运行速度。表A4运行的时间包含了窗口提取、归一化的数据预处理的时间。一般来说,离线训练后,在线上进行预测,风电调度周期一般为2h,实时调度的时间尺度为5~15 min^[30],在仅计入预测时间的情况下,最长的预测时间不超过0.5s,因而预测的速度完全可以满足风电场的调度管理。

采用CNN正向计算一次所花费的时间可代表

模型特征提取的效率。从附录A表A5可以看到在不计数据导入和归一化的时间的情况下,CNN正向运行一次的时间均小于0.1s,计入数据导入和归一化时间的情况下,运行时间不超过0.2s,说明模型提取特征的效率较高。

从以上分析可以看出,本文所提预测方法的爬坡预测性能指标较对比方法均有改善,从而表明了所提出模型在风电功率爬坡事件预测方面的可行性和有效性。

选取第4季度ELIA数据进行对比。功率预测对比见附录A图A7,爬坡指标对比见附录A图A8。节选350个数据对各个爬坡指标进行分析。图A8(a)表示实际的爬坡,向上的箭头表示上爬坡,向下的箭头表示下爬坡,图A8(b)、(c)和(d)分别代表CNN-LSTM-AM,BPNN和ENN的爬坡预测。可以看到在前350个样本点中,CNN-LSTM-AM模型仅有5个误判点,而BPNN和ENN的误判点分别达到了18个和21个,明显高于CNN-LSTM-AM模型,且3个模型均无错判。在样本区间[150,200]内,原始风电功率数据较为平缓,但BPNN和ENN的爬坡预测变化较为剧烈,因而发生了较多次的误判,导致误判率升高,而本文模型的预测输出相对平缓,因而误判次数低,从而说明本文模型有很好的爬坡预测能力。

4 结语

本文首先用CNN对风电功率信号进行深层特征提取,很好地捕捉了风电功率的爬坡事件。然后,加入了LSTM网络解决风电功率的长时依赖问题。最后,加入AM对LSTM层的输出进行加权处理,加强了网络输出的重要部分,使得模型对爬坡预测的准确性得到进一步的提升。本文中所提出的模型很好地学习了风电功率的深层特性,对处理波动性较强的风电功率序列有较好的效果。

本文仅对模型的正向传播过程进行分析并提取了中间过程,未结合风电信号本身的特性对反向传播的优化算法进行改进,并且仅采用了风电功率数据进行预测。未来的研究可以引入反向优化算法和多变量预测,从而进一步提高模型对风电爬坡的预测能力。

附录见本刊网络版(<http://www.aeps-info.com/aeps/ch/index.aspx>),扫英文摘要后二维码可以阅读网络全文。

参考文献

- [1] ZHANG G, LIU H, ZHANG J, et al. Wind power prediction based on variational mode decomposition multi-frequency combinations[J]. Journal of Modern Power Systems and Clean Energy, 2019, 7(2): 281-288.
- [2] 蔡游明,李征,蔡旭.计及控制时间窗内功率波动的风电场群无功电压分层优化控制[J].电工技术学报,2019,34(6):1240-1250.
CAI Youming, LI Zheng, CAI Xu. Voltage hierarchical optimal control of a wind farm cluster in account of voltage fluctuation in control time window[J]. Transactions of China Electrotechnical Society, 2019, 34(6): 1240-1250.
- [3] 叶林,路朋,滕景竹,等.考虑风电功率爬坡的功率预测-校正模型[J].电力系统自动化,2019,43(6):49-56.
YE Lin, LU Peng, TENG Jingzhu, et al. Power prediction and correction model considering wind power ramping events [J]. Automation of Electric Power Systems, 2019, 43(6): 49-56.
- [4] 马欢,李常刚,刘玉田.风电爬坡事件对系统运行充裕性的影响评估[J].电力系统自动化,2017,41(4):41-47.
MA Huan, LI Changgang, LIU Yutian. Assessing impact of wind power ramp events on operation adequacy of power systems [J]. Automation of Electric Power Systems, 2017, 41 (4) : 41-47.
- [5] 张旭,代悦,张东英,等.基于合作博弈的风电爬坡控制策略[J].电力系统自动化,2019,43(15):42-48.
ZHANG Xu, DAI Yue, ZHANG Dongying, et al. Cooperative game based ramping control strategy for wind power [J]. Automation of Electric Power Systems, 2019, 43(15): 42-48.
- [6] CUI M, ZHANG J, WANG Q, et al. A data-driven methodology for probabilistic wind power ramp forecasting [J]. IEEE Transactions on Smart Grid, 2019, 10(2): 1326-1338.
- [7] 马欢,李常刚,刘玉田.风电爬坡事件多级区间预警方法[J].电力系统自动化,2017,41(11):39-47.
MA Huan, LI Changgang, LIU Yutian. Multi-level early warning method for wind power ramp events[J]. Automation of Electric Power Systems, 2017, 41(11): 39-47.
- [8] TAYLOR J W, YU Keming. Using auto-regressive logit models to forecast the exceedance probability for financial risk management[J]. Journal of the Royal Statistical Society Series A - Statistics in Society, 2016, 179(4): 1069-1092.
- [9] TAYLOR J W. Probabilistic forecasting of wind power ramp events using autoregressive logit models[J]. European Journal of Operational Research, 2017, 259(2): 703-712.
- [10] PINSON P, MADSEN H. Ensemble-based probabilistic forecasting at Horns Rev [J]. Wind Energy, 2009, 12 (2) : 137-155.
- [11] 欧阳庭辉,查晓明,秦亮,等.基于相似性修正的风电功率爬坡事件预测方法[J].中国电机工程学报,2017,37(2):572-580.
OUYANG Tinghui, ZHA Xiaoming, QIN Liang, et al. Wind power ramps prediction method based on amendment of similar events[J]. Proceedings of the CSEE, 2017, 37(2): 572-580.
- [12] OUYANG Tinghui, ZHA Xiaoming, QIN Liang, et al. Prediction of wind power ramp events based on residual correction[J]. Renewable Energy, 2019, 136: 781-792.
- [13] DORADO-MORENO M, NAVARIN N, GUTIÉRREZ P A, et al. Multi-task learning for the prediction of wind power ramp events with deep neural networks[J]. Neural Networks, 2020, 123: 401-411.
- [14] OUYANG T, HUANG H, HE Y. Ramp events forecasting based on long-term wind power prediction and correction [J]. IET Renewable Power Generation, 2019, 13 (15) : 2793-2801.
- [15] HUANG Y, LIU S, YANG L. Wind speed forecasting method using EEMD and the combination forecasting method based on GPR and LSTM[J]. Sustainability, 2018, 10(10): 3693-3707.
- [16] HU Y, CHEN L. A nonlinear hybrid wind speed forecasting model using LSTM network, hysteretic ELM and differential evolution algorithm[J]. Energy Conversion and Management, 2018, 173: 123-142.
- [17] YU C, LI Y, BAO Y, et al. A novel framework for wind speed prediction based on recurrent neural networks and support vector machine [J]. Energy Conversion and Management, 2018, 178: 137-145.
- [18] LÓPEZ E, VALLE C, ALLENDE H, et al. Wind power forecasting based on echo state networks and long short-term memory[J]. Energies, 2018, 11(3): 526-547.
- [19] OEHMCKE S, ZIELINSKI O, KRAMER O. Input quality aware convolutional LSTM networks for virtual marine sensors [J]. Neurocomputing, 2018, 275: 2603-2615.
- [20] LIU H, MI X, LI Y. Smart deep learning based wind speed prediction model using wavelet packet decomposition, convolutional neural network and convolutional long short term memory network [J]. Energy Conversion and Management, 2018, 166: 120-131.
- [21] LÓPEZ P R, DORTA D V, PREIXENS G C, et al. Pay attention to the activations: a modular attention mechanism for fine-grained image recognition [J]. IEEE Transactions on Multimedia, 2020, 22(2): 502-514.
- [22] LI X, ZHANG W, DING Q. Understanding and improving deep learning-based rolling bearing fault diagnosis with attention mechanism[J]. Signal Processing, 2019, 161: 136-154.
- [23] CUI M, FENG C, WANG Z, et al. Statistical representation of wind power ramps using a generalized gaussian mixture model [J]. IEEE Transactions on Sustainable Energy, 2018, 9(1): 261-272.
- [24] FERREIRA C, GAMA J, MATIAS L, et al. A survey on wind power ramp forecasting[R/OL]. (2010-12-01) [2020-06-01]. <http://www.dis.anl.gov/pubs/69166.pdf>.
- [25] 张东英,代悦,张旭,等.风电爬坡事件研究综述及展望[J].电网技术,2018,42(6):1783-1792.
ZHANG Dongying, DAI Yue, ZHANG Xu, et al. Review and prospect of research on wind power ramp events [J]. Power System Technology, 2018, 42(6): 1783-1792.
- [26] CAO Y, WEI W, WANG C, et al. Probabilistic estimation of wind power ramp events: a data-driven optimization approach [J]. IEEE Access, 2019, 7: 23261-23269.
- [27] ELIA. Wind-power generation data [EB/OL]. (2019-01-01) [2020-06-01]. <http://www.elia.be>.

- [28] 丁明,张超,王勃,等.基于功率波动过程的风电功率短期预测及误差修正[J].电力系统自动化,2019,43(3):2-9.
DING Ming, ZHANG Chao, WANG Bo, et al. Short-term forecasting and error correction of wind power based on power fluctuation process[J]. Automation of Electric Power Systems, 2019, 43(3): 2-9.
- [29] 唐振浩,孟庆煜,曹生现,等.基于小波深度置信网络的风电爬坡预测方法[J].太阳能学报,2019,40(11):3213-3220.
TANG Zhenhao, MENG Qingyu, CAO Shengxian, et al. Wind power ramp prediction algorithm based on wavelet deep belief network[J]. Acta Energaie Solaris Sinica, 2019, 40(11): 3213-3220.
- [30] PAPAVALIOU A, MOU Y, CAMBIER L, et al. Application of stochastic dual dynamic programming to the real-

time dispatch of storage under renewable supply uncertainty[J]. IEEE Transactions on Sustainable Energy, 2018, 9(2): 547-558.

景惠甜(1996—),女,硕士研究生,主要研究方向:风电功率预测算法。E-mail:754704445@qq.com

韩 丽(1977—),女,通信作者,博士,教授,主要研究方向:电力系统运行调度、微电网控制和电气设备故障诊断。E-mail:dannyli717@163.com

高志宇(1996—),男,硕士研究生,主要研究方向:电力系统运行调度。E-mail:942934092@qq.com

(编辑 吴崇昊)

Wind Power Ramp Forecast Based on Feature Extraction Using Convolutional Neural Network

JING Huitian, HAN Li, GAO Zhiyu

(School of Electrical and Power Engineering, China University of Mining and Technology, Xuzhou 221116, China)

Abstract: To improve the accuracy of wind power ramp forecast, a method based on long short-term memory (LSTM) network, convolutional neural network (CNN) and attention mechanism (AM) is proposed. Wind power ramp event rarely occurs and has complex characteristics, and it is difficult for forecast model to effectively learn from small number of ramp event samples. So CNN is used to extract features in wind power time series. And the LSTM network is used to build forecasting model to solve the long-term dependence of wind power. Then AM is added to the model to weight outputs of LSTM network units to strengthen the learning of wind power features, thus improving the accuracy of ramp forecast. The simulation results show that the forecasting model has high accuracy on wind power ramp forecast.

This work is supported by National Natural Science Foundation of China (No. 61703404).

Key words: wind power ramp forecast; convolutional neural network (CNN); long short-term memory (LSTM) network; attention mechanism (AM); wind power ramp

