

本文全文线上首发由
上海电机系统节能工程技术
研究中心有限公司
支持

陈臣鹏,赵鑫,毕贵红,陈仕龙,谢旭.
基于Kmeans-VMD-LSTM的短期风速预测.
电机与控制应用,2021,48(12):85.



SEARI **NCMS**
上電科 上科電機

www.nems.com.cn

掌握电机行业制造核心技术,
辐射智能制造产业发展



· 业务范围 ·



异步电机装配线

上海电机系统节能工程技术研究中心有限公司 www.nems.com.cn

地址：上海市武宁路505号 手机：18918357509 电话：021-62574990-436

传真：021-62163904

邮箱：wangcj@seari.com.cn

基于 Kmeans-VMD-LSTM 的短期风速预测

陈臣鹏, 赵 鑫, 毕贵红, 陈仕龙, 谢 旭
(昆明理工大学 电力工程学院, 云南 昆明 650500)

摘要: 短期风速具有间歇性、波动性、非线性和非平稳性等特点, 具有高度的复杂性, 预测难度较大。风速信号可以看成是由复杂度较低、规律较强的简单信号耦合而成, 所以可利用分解方法使之分为多尺度的波动分量, 降低分量复杂度, 增强其规律性, 可以提高其预测精度。因此, 为了提高神经网络的学习效率, 采用 Kmeans 算法对原始风速数据进行相似日聚类; 其次, 使用 VMD 分解风速序列, 提取多尺度规律; 最后, 由于 LSTM 神经网络捕捉长时间依赖的序列的波动规律的能力较强, 使用 LSTM 神经网络对分解后的风速分量进行预测, 将各分量预测值叠加得到最终预测结果。通过大量试验和不同方法之间的比较表明, 基于 Kmeans-VMD-LSTM 的组合预测模型可以有效提高风速短期预测的准确率。

关键词: 风速短期预测; Kmeans 聚类; VMD 分解; LSTM 神经网络

中图分类号: TM 614 文献标志码: A 文章编号: 1673-6540(2021)12-0085-09

doi: 10.12177/emca.2021.118

Short-Term Wind Speed Prediction Based on Kmeans-VMD-LSTM

CHEN Chenpeng, ZHAO Xin, BI Guihong, CHEN Shilong, XIE Xu
(School of Electric Power Engineering, Kunming University of Science and Technology,
Kunming 650500, China)

Abstract: Short-term wind speed is intermittent, fluctuating, nonlinear and non-stationary, and has a high degree of complexity, which is difficult to predict. The wind speed signal can be seen as coupled from simple signals with low complexity and strong regularity, so the decomposition method can be used to make it divided into multi-scale fluctuating energy, reduce the component complexity and enhance its regularity, which can improve its prediction accuracy. Therefore, to improve the learning efficiency of the neural network, the Kmeans algorithm is used to cluster the original wind speed data on similar days. Secondly, the wind speed sequence is decomposed using VMD to extract the multiscale regularity. Finally, because the LSTM neural network is more capable of capturing the fluctuation regularity of the long-dependent sequence, the decomposed wind speed components are predicted by using the LSTM neural network, and the final prediction results are obtained by superimposing the predicted values of each component. The combination prediction model based on Kmeans-VMD-LSTM can effectively improve the accuracy of short-term wind speed prediction as shown by a large number of experiments and comparisons between different methods.

Key words: short-term wind speed prediction; Kmeans clustering; VMD decomposition; long short-term memory (LSTM) neural network

0 引言

风力发电作为可再生能源发电方式之一, 呈

现出高增长的发展趋势。但风电的波动性和不稳定性使风电并网时电力系统产生大量不确定波动, 极大影响电能质量, 危害电力系统的稳定运

收稿日期: 2021-09-24; 收到修改稿日期: 2021-10-22

作者简介: 陈臣鹏(1997—), 男, 硕士研究生, 研究方向为数据分析和风速预测。

毕贵红(1968—), 男, 博士, 教授, 研究方向为人工智能在电力系统中的应用。(通信作者)

行,对风电场输出的风电功率进行预测是有效解决该问题的方法之一,而风速预测是风电功率预测的基础,因此对风速精确预测能够为电网调度部门提供调度依据,提高电力系统对风电的消纳能力^[1],保证电力系统的安全稳定运行。

风速预测可按超短期、短期和中长期等不同预测时长划分。风速在超短期内由于采样间隔较短,与短期相比风速表现出较好的规律性,风速的超短期预测技术较为成熟。而短期风速的非线性和波动性特点更为突出,规律性较弱,预测难度较大。目前国内外在短期风速预测方面主要利用统计的方法来拟合原始风速数据与实际风速数据间的非线性关系,主要有支持向量机法、经验模式分解法、卡尔曼滤波法等^[2]。传统的统计方法直接利用原始风速数据建立的预测模型预测精度并不理想,为了解决这一弊端,不少学者提出了利用信号分解的方法挖掘风速样本深层的规律性特征,在单一模型的基础上提出了基于统计方法的组合预测模型。文献[3]将原始信号利用经验模态分解(EMD)分解为24个模态分量,再与长短期记忆(LSTM)神经网络结合的预测方法取得不错的预测效果。论文[4-5]为了进一步挖掘原始数据的内在规律性特征,利用变分模态分解(VMD)后,分别利用门控循环网络(GRU)和双向LSTM构建了预测模型,取得了较高的预测精度。

结合上述方法的优点,本文提出了一种基于K均值聚类(Kmeans)、VMD分解、根据样本熵重构分量和LSTM网络结合的风速预测方法。首先利用Kmeans对原始风速数据进行分类,初步找出规律相似的日聚类;进一步利用VMD的非递归性优点,充分提取集合中的风速信息,通过试验分解出合适层数的风速分量。再根据各分量的样本熵值进行分量重构,在保证其规律性的前提下减少后续的计算量;随后通过试验搭建LSTM神经网络,对分解出的风速分量进行预测;最后将各个子分量的预测结果重构合成最终的风速预测结果。仿真试验表明本文提出的预测模型比传统的复合模型有着更高的预测精度。

1 基于 Kmeans 和 VMD 的信号分解

1.1 Kmeans 算法

Kmeans 算法利用数据间的某种相似度将特
— 86 —

征相似的样本自动归到一个类别中,实现对数据的聚类划分。其基本步骤如下:

步骤1,随机选取K个点,作为样本的聚类中心点,然后计算其他样本到聚类中心点的欧式距离,将其归为离某个中心点最近的那个类别中,形成初始分类,如下:

$$d(X, Y) = \sqrt{\sum (x_i - y_i)^2}, i = 1, 2, \dots, n \quad (1)$$

式中: x_i 为样本 X 中的第 i 个变量, y_i 为样本 Y 的第 i 个变量。

步骤2,确定某个评价聚类结果优劣的准则函数。Davies-Bouldin 指数(DBI)用于衡量聚类后各类别间的相似度,如下:

$$DBI = \frac{1}{K} \sum_{i=1}^K \max_{j \neq i} \left(\frac{S_i + S_j}{M_{ij}} \right) \quad (2)$$

式中: K 为类别数; S_i 和 S_j 分别为样本 i 和样本 j 到相应类别聚类中心距离的平均值,即类内平均距离; M_{ij} 表示第 i 类与第 j 类中心的距离。

步骤3,给定某个初始分类,用迭代算法不断寻找合适的 K 个中心点,使准则函数 DBI 最小化,即各类别的相似性尽可能小,得到合适的聚类结果。

Kmeans 算法能够处理规律性较弱的原始数据,削弱原始风速不确定性的影响,提取原始风速数据的初步特征,形成具有一定规律性的初始分类。

1.2 VMD 分解

VMD 是一种非平稳信号自适应分解估计方法,可将原始复杂信号分解为若干个调幅调频子信号。每个模态具有不同中心频率的有限带宽,目标是使每个模态的估计带宽之和最小,分解所得的不同分量代表了原始信号不同尺度的特征^[6-8]。VMD 能够对同类别、同时间段内的风速数据进行分解,降低风速序列的复杂度,进一步得到频率不同、但规律性更强的风速子序列。

1.3 样本熵

样本熵是一种基于近似熵的优化算法,可以用于度量时间序列的复杂度。序列的复杂程度越高,熵值就越大^[9],序列的复杂程度低,熵值就越小。通过计算分解所得的各分量的熵值,根据熵值曲线将熵值接近的分量进行叠加,重构得到新的分量。对比样本熵值,能够寻找复杂度相

似的风速子序列,在减小后续试验计算量的同时保留了风速序列的规律性。

1.4 LSTM 神经网络

LSTM 网络是循环神经网络(RNN)的其中一种。与传统神经网络相比,RNN 在隐含层增加了反馈连接,即隐含层结点之间不再是独立的,而是互相连接的,并且隐含层的输入同时包括了输入层的输出和上一时刻隐含层的输出。利用这种结构,网络对过去的数据产生记忆状态,并建立不同时段数据之间的依赖关系,因此能更好地处理时间序列问题。但 RNN 也存在一定弊端,RNN 在进行跨时间步长的反向传播时,会因为序列的时间过长而出现梯度消失或爆炸的问题,进而严重影响长时间序列的预测。LSTM 通过引入记忆单元取代传统 RNN 的隐含节点,解决了 RNN 在处理长时间序列时产生的梯度消失或爆炸问题,能够实现长时间、跨时间步长的可靠预测。

LSTM 神经网络由一组称之为记忆块的循环子网构成,每个记忆块包含一个或多个自连接的记忆细胞及 3 个乘法控制单元—输入门、输出门和遗忘门组成,提供着类似于读、写、重置的功能。图 1 所示是标准的 LSTM 神经网络模型结构,标准 LSTM 神经网络模型是一种特殊的 RNN 类型,在每一个重复的模块中有 4 个特殊的结构,以一种特殊的方式进行交互。在图 1 中,每一条黑线传输着一个向量,深色的圈将定义域上的每一点的函数值分别进行运算。“细胞状态”是 LSTM 神经网络模型的核心思想,其类似于传送带。信息在传送带上运行时,只有一些少量的线性交互,因此能够保证流传时信息的不变性^[10]。

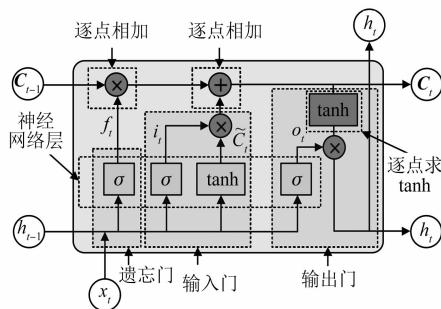


图 1 标准的 LSTM 神经网络模型结构

在 LSTM 神经网络模型中,第一步是遗忘门的运算,通过遗忘门层实现。遗忘门层读取当前

输入 x_t 和前一神经元信息 h_{t-1} ,由 f_t 来决定信息的保留或丢弃,输出的 1 和 0 分别表示信息的“完全保留”和信息的“完全丢弃”。

f_t 表达式为

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (3)$$

第二步是输入门运算,这一步由 Sigmoid 层和 tanh 层组成。前者作为“输入门层”决定着即将更新的值 i_t ,后者则创建一个新的候选值向量 \tilde{C}_t 加入到状态中^[11]。

i_t, \tilde{C}_t 表达式为

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (4)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (5)$$

第三步是细胞状态计算,将 C_{t-1} 更新为 C_t 。将上一状态与 f_t 作乘积运算,把需要舍弃的信息舍弃掉,随后加上 $i_t * \tilde{C}_t$,得到新的候选值,根据决定更新每个状态的程度进行变化^[12]。

C_t 表达式为

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (6)$$

第四步是输出门运算,该输出会根据细胞的状态,首先运行 Sigmoid 层用于确定所需输出细胞状态的准确部分。再把细胞状态通过 tanh 层处理,得到位于 $[-1, 1]$ 区间内的值,随后让其和 Sigmoid 层的输出作乘积运算,最后会输出所需保留的部分^[13]。

o_t, h_t 表达式为

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (7)$$

$$h_t = o_t * \tanh(C_t) \quad (8)$$

传统的神经网络预测模型类似于模式识别,样本中包含了不同的模式,训练时难以挖掘样本与模式间的时序联系。LSTM 神经网络能够捕捉样本间的时序关联,在样本训练时加入时序性关联,将之前发生的事与随后发生的事联系起来,再据此得出结论,因此能够挖掘样本在时间上的相关性信息。在风速预测方面,LSTM 神经网络能够对历史输入、当前输入和历史输出进行加权学习,进而实现对历史输入、历史输出的记忆功能,适合对于时间依赖的短期风速波动模式的捕获。

2 Kmeans-VMD-LSTM 预测模型

2.1 预测模型

为充分削弱风速的非线性,降低短期风速预

测的难度并提高预测精度, 提出一种考虑 Kmeans、VMD、样本熵的组合分解模式与 LSTM 神经网络结合的组合预测模型来预测短期风速。具体流程如图 2 所示。

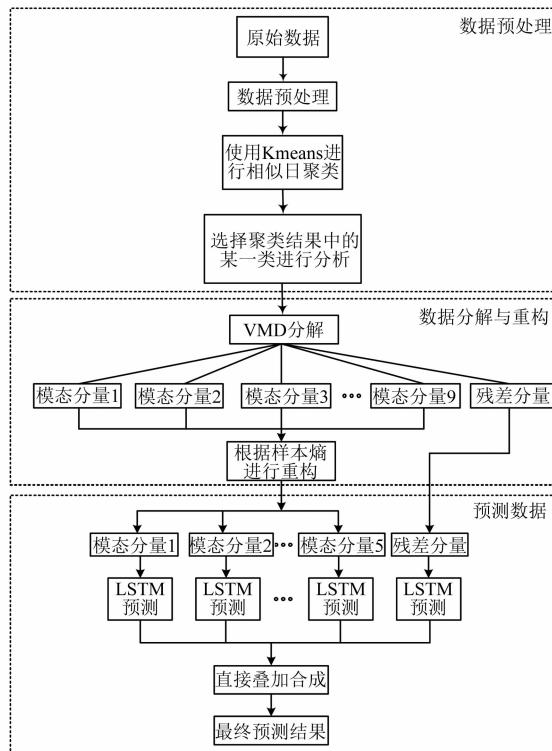


图 2 组合预测模型简图

数据预处理。 使用 Kmeans 算法对原始风速数据进行相似日聚类, 选择聚类结果的某一类相似日为代表进行后续分析。

数据分解与重构。 使用 VMD 算法将上述选取的某类相似日数据分解为若干个模态分量和 1 个残差分量, 分别计算各个分量的样本熵值。比较各分量的样本熵值, 将熵值接近的分量相加, 重构得到新的若干个分量。

预测数据。 将每个分量均划分为训练集和测试集, 将训练集输入神经网络进行训练, 将测试集数据输入训练完成的神经网络中得到若干个分量的预测值, 最后将若干个预测值直接相加得到最终的风速预测值。

2.2 预测结果评估指标

为评估风电预测的误差, 本文使用平均绝对误差(MAE)、平均绝对百分比误差(MAPE)以及均方根误差(RMSE)对试验预测结果进行评估。MAE 和 RMSE 反应绝对误差, 不同测试数据来源

的预测方法的绝对误差没有可比性, 但对电网调度部门具有重要意义。MAPE 是相对误差, 可以用于比较基于不同数据来源的预测方法。3 种误差的表达式如下所示:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |P_i - \hat{P}_i| \quad (9)$$

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{P_i - \hat{P}_i}{\bar{P}_i} \right| \times 100 \quad (10)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - \hat{P}_i)^2} \quad (11)$$

式中: P_i 为实际值; \hat{P}_i 为预测值; \bar{P}_i 为实际数据的平均值。

3 算例及试验结果分析

3.1 数据聚类

为了验证本文所提出预测模型的准确性, 本文选用西班牙 Sotavento 风电场的实测数据(P_i , $i=1, 2, \dots, n$), 采样间隔为 1 h, 对全年进行采样, 一共采样了 $n = 8760$ (365×24) 个数据。使用 Kmeans 算法对 365 天, 每天 24 h 的原始风速数据进行相似日聚类。考虑数据长度, 为了确定合理的聚类数 K 值, K_{\max} 设为 10, K 的取值范围为 [2, 10], 利用式(2)计算得到相应的 DBI 值, 如图 3 所示。由图 3 可知, 当 $K=4$ 时, $\text{DBI}=0.5159$, 故将聚类数 K 值设为 4 最合适。

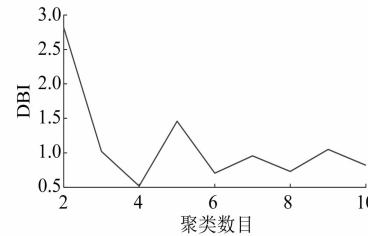


图 3 根据 DBI 确定 K 值

将 356 天分成 4 类相似日。在同一个类别中的数据样本有很高的相似度。分类结果如图 4 所示, 正方形散点代表第一类相似日, 共计 114 d, 星形散点为第二类相似日, 共计 52 d。三角形散点为第三类相似日, 共计 94 d。菱形散点为第四类相似日, 共计 105 d。图 5(a) 为未进行聚类划分的原始风速样本, 图 5(b) 为聚类划分后的第一类 114 d 风速相似日。

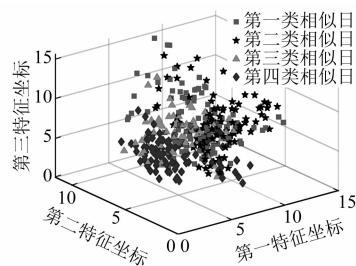


图 4 Kmeans 结果

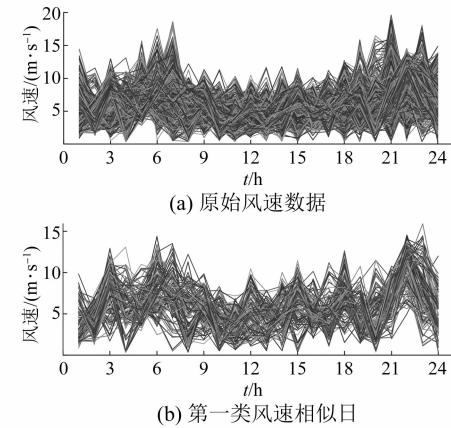


图 5 聚类前后的风速图

3.2 数据分解与重构

3.2.1 数据分解

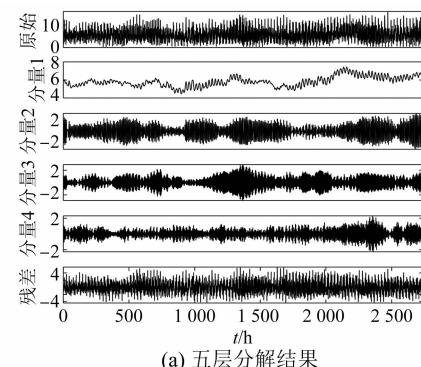
为了便于分析不同分解与重构层数对最终预测结果的影响,本文将第一类相似日 2 736 组($114 \text{ d} \times 24 \text{ h}$)数据分别分解为 10 层子分量和 5 层子分量,不同子分量代表了相似日不同尺度的特征。

(1) 将第一类相似日分解为 5 层子分量。

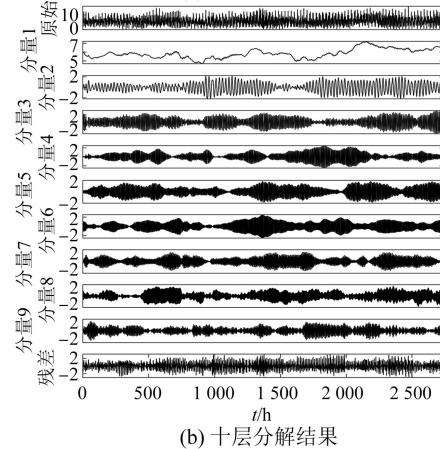
将第一类相似日数据用 VMD 分解成 4 个模态分量。第 5 个分量为残差分量,由原始数据减去前 4 个分量所得。如图 6(a)所示,第一行为原始未分解的风速数据,第 2 行~第 5 行分别代表 VMD 分解后从低频到高频排列的 4 个模态分量,最后一行为残差分量。

(2) 将第一类相似日分解为 10 层子分量。

将第一类相似日数据用 VMD 分解成 9 个模态分量。第 10 个分量为残差分量,由原始数据减去前 9 个分量所得。图 6(b)所示,第一行为原始未分解的风速数据,第 2 行~第 10 行分别代表 VMD 分解后从低频到高频排列的 9 个模态分量,最后一行为残差分量。



(a) 五层分解结果



(b) 十层分解结果

图 6 第一类相似日分解结果

3.2.2 数据重构

为简化预测模型,提高预测模型的预测效率,需要分别计算上述 5 个子分量和 10 个子分量样本熵值,结果如表 1 和表 2 所示。将熵值相近的分量叠加合成,最终重构出数量更少的新分量,以减小分量数。设置相似容限 $r = 0.6E_{\text{std}}$ 和嵌入维数 $m=2$ 。图 7 为重构前的各模态分量的熵值。

表 1 分解成 5 个子分量的样本熵值

模态分量	熵值
分量 1	0.090 2
分量 2	0.876 0
分量 3	1.133 1
分量 4	1.115 9
残差	0.571 5

图 8(a)所示,重构后的分量 A1 为重构前的模态分量 1;重构后的分量 A2 为重构前的模态分量 2、模态分量 3 和模态 4 三者相加的和;重构后的分量 A3 为重构前的残差分量。

表 2 分解成 10 个子分量样的本嫡值

模态分量	嫡值	模态分量	嫡值
分量 1	0.030 4	分量 6	1.065 3
分量 2	0.286 5	分量 7	1.137 7
分量 3	0.876 2	分量 8	0.964 5
分量 4	0.946 0	分量 9	0.599 7
分量 5	1.149 1	残差	0.250 7

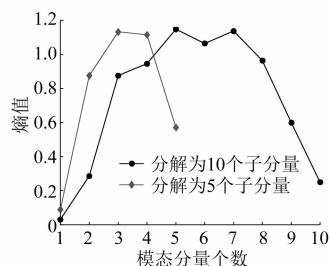


图 7 重构前各分量样本嫡值

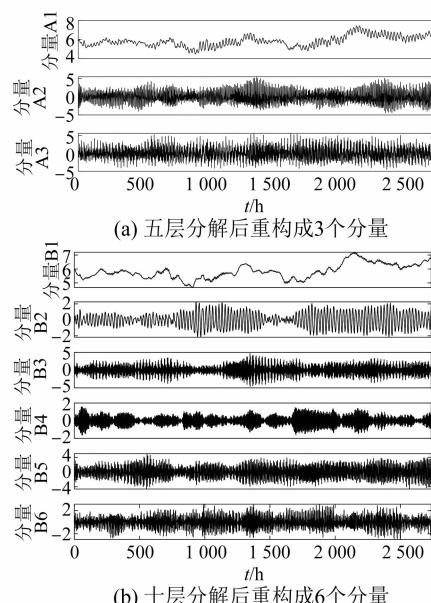


图 8 重构后的子分量

图 8(b)所示,重构后的分量 B1 为重构前的模态分量 1;重构后的分量 B2 为重构前的模态分量 2;重构后的分量 B3 为重构前的模态分量 5、模态分量 6 和模态分量 7 三者相加的和;重构后的分量 B4 为重构前的模态分量 9;重构后的分量 B5 为重构前的模态分量 3、模态分量 4 和模态分量 8 三者相加的和;重构后的分量 B6 为重构前的残差分量。

— 90 —

3.3 模型的构建与预测

3.3.1 Kmeans-VMD-AdaBoost-BP 预测模型

为了选择更优的 VMD 分解与重构层数以及对比预测结果,本文首先构建了 Kmeans-VMD-AdaBoost-BP (AdBP) 预测模型。

AdaBoost 算法具备串行集成学习的优点,通过弱预测器的相互依赖关系并按照一定权重组合成为强预测器。使用集成学习 AdaBoost 算法将若干个 BP 预测器经过结合策略构成一个强预测器,进而提高神经网络的预测精度。本文构建的 AdBP 预测模型包含了 10 个弱预测器,弱预测器网络结构为 24—10—24。输入层为 24 个维度,隐含层包含 10 个节点,输出层为 24 个维度,可实现输入前 1 天 24 h 的风速值,输出后 1 天 24 h 的风速值。对聚类后第一类风速的后 3 天即第 112 天、第 113 天和第 114 天进行预测。预测过程如下:

预测第 112 天:用第 1 天~第 110 天的数据作为 AdBP 神经网络的训练输入数据,用第 2 天~第 111 天的数据作为 AdBP 神经网络的训练输出数据;训练完成后,输入第 111 天的数据,经过 AdBP 神经网络得出第 112 天的预测值。

预测第 113 天:用第 1 天~第 111 天的数据作为 AdBP 神经网络的训练输入数据,用第 2 天~第 112 天的数据作为 AdBP 神经网络的训练输出数据;训练完成后,输入第 112 天的数据,经过 AdBP 神经网络得出第 113 天的预测值。

预测第 114 天:用第 1 天~第 112 天的数据作为 AdBP 神经网络的训练输入数据,用第 2 天~第 113 天的数据作为 AdBP 神经网络的训练输出数据;训练完成后,输入第 113 天的数据,经过 AdBP 神经网络得出第 114 天的预测值。

将重构后的 A1~A3 3 个分量和 B1~B6 6 个分量分别按照以上的预测步骤进行预测,将预测所得的第 112 天、113 天和第 114 天的 3 个子分量和 6 个子分量分别相加合成最终的 3 天预测值。图 9(a)为 2 种分解与重构方式下 AdBP 的预测结果与实际值的对比。计算 2 种分解重构方式下 AdBP 预测值与实际值的绝对误差,如图 9(b)所示。

计算不同数据分解和重构方式下模型的预测误差,结果如表 3 所示,比较 2 种分解重构方式的预测结果,MAE 减小了 0.726 6, MAPE 减小了 10.998%, RMSE 减小了 0.823, 故后续预测模型均

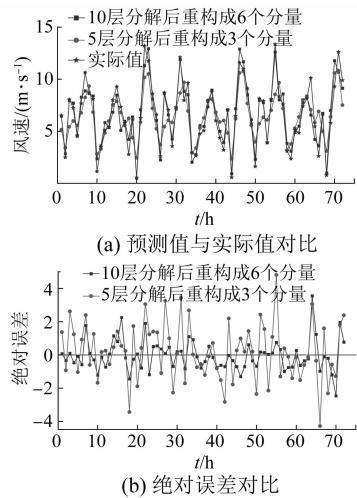


图 9 2 种分解与重构方式的预测对比

采用这一分解与重构方式。

表 3 分解与重构差异的误差对比

模型	VMD	重构	弱预	隐含	MAE	MAPE/%	RMSE
	分解	后分	测器	层层			
	层数	量数	个数	数			
Kmeans-	5	3	10	1	1.4027	21.2332	1.7506
VMD-							
AdBP	10	6	10	1	0.6761	10.2352	0.9276

3.3.2 Kmeans-VMD-LSTM 预测模型

在 Kmeans-VMD-AdBP 模型确定了风速相似且聚类和 VMD 分解层数的基础上, 利用 LSTM 神经网络来提取各分量的波动时序特征, 并对各分量进行预测, 各分量预测结果的总和得到风速预测值。

预测模型中 LSTM 神经网络层数和网络中神经元的个数影响着模型的预测精度。为确定合适的 LSTM 神经网络结构, 本文分别将 LSTM 神经网络层数设置为 1 层、2 层、3 层和 4 层, 将 LSTM 神经网络中的神经元个数分别设置为 100 个、200 个、300 个和 400 个。LSTM 神经网络神经元之间相互连接, 隐含层不仅要接受当前输入的 24 h 的时序特征, 还要建立当前输出与过去数天风速之间的关系。合适的神经元个数能够更好地建立不同时段风速之间的依赖关系。通过改变网络结构进行一系列对比试验, 选取更佳的网络结构。

将重构后的 6 个分量(B1~B6)的前 111 天划为训练集, 后 3 天作为测试集。随着训练过程的进行, 模型复杂度增加, 为防止模型训练的过拟

合, 需要加入随机失活(Dropout)层, 该层按照给定的几率随机的将输入的元素设置为 0。预测模型中包含了 24 维的序列输入层、LSTM 层、随机失活层、全连接层和 24 维输出层。模型中, 求解器设置为 Adam, 初始学习率为 0.005, 进行 2 000 轮训练。为了提高网络训练速度和预测的准确率, 在 125 轮训练后通过乘以下降因子 0.2 来降低学习率, 并将随机失活层中的元素失活概率设为 20%。为防止梯度爆炸, 设定梯度阈值为 1。

试验结果如表 4 所示, 由表 4 可知, 当 LSTM 神经网络层数相同时, 随着神经元个数的增加, 模型的预测结果与实际值的误差逐渐减小; 当 LSTM 神经元个数相同, 随着 LSTM 层数的增加, 模型的预测精度也逐步提高。但随着 LSTM 神经网络层数和神经元的继续增加, 模型会表现出过拟合现象。与 100 个、300 个和 400 个神经元节点相比, 200 个神经元能够捕捉过去合适的天数的风速数据, 更精确的建立了过去数天与当前输出的关系, 且未出现过拟合现象。

表 4 不同 LSTM 网络结构的误差对比

模型	VMD	重构	LSTM	神经	MAE	MAPE/%	RMSE
	分解	后分	网络	元个			
	层数	量数	层数	数			
Kmeans-	10	6	1	100	0.7196	10.8926	0.8343
	10	6	2	100	0.6960	10.5355	0.8618
	10	6	3	100	0.4960	7.5090	0.6299
	10	6	4	100	0.5005	7.5771	0.6226
	10	6	1	200	0.4916	7.4423	0.6214
	10	6	2	200	0.4775	7.2276	0.5998
	10	6	3	200	0.3933	5.9540	0.5098
	10	6	4	200	0.5151	7.7975	0.6329
	10	6	1	300	0.8820	13.3520	1.2137
	10	6	1	400	0.9993	15.1265	1.3353

故本文搭建的 Kmeans-VMD-LSTM 和 VMD-LSTM 模型均选择 3 层 LSTM 神经网络, 神经元个数选择 200 个。最终构建的 LSTM 预测网络结构如图 10 所示。

3.3.3 误差对比分析

为了比较, 构建了未经过聚类的 VMD-LSTM 预测模型, 该 VMD-LSTM 模型直接将原始风速数据进行 VMD 分解与样本熵重构。Kmeans-VMD-LSTM、VMD-LSTM 预测模型选取相同的 LSTM 神经网络结构, 对相同的 3 天风速分别进行预测。

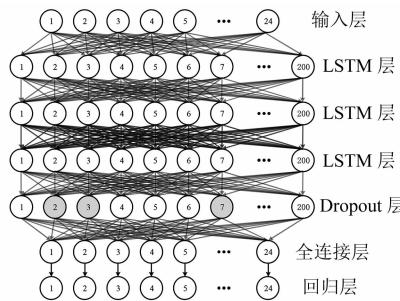


图 10 LSTM 网络最终结构

两个模型的预测结果与实际值对比如图 11(a)所示,Kmeans-VMD-LSTM 的预测曲线与实际值的拟合度更高。计算对比 2 个预测模型与实际值的绝对误差,结果如图 11(b)所示。分析 2 个模型的预测精度差异,模型的误差如表 5 所示,经计算得 Kmeans - VMD - LSTM 对比 VMD - LSTM ,

MAE 减小了 0.499 9, MAPE 减小了 7.569 1%, RMSE 减小了 0.630 7。

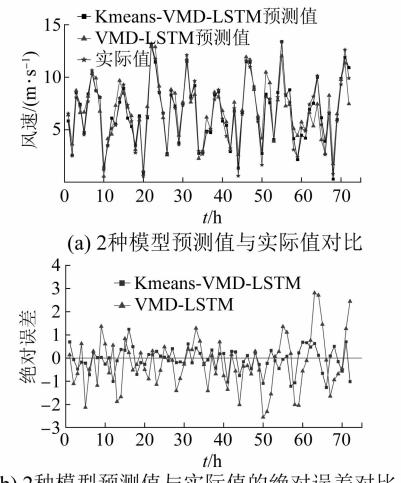


图 11 各模型对比结果

表 5 不同模型的误差对比

模型	VMD 分解层数	重构后分量数	LSTM 网络层数	神经元数	MAE	MAPE/%	RMSE
Kmeans-VMD-LSTM	10	6	3	200	0.393 3	5.954 0	0.509 8
VMD-LSTM	10	6	3	200	0.893 2	13.523 1	1.140 5

经试验对比说明 Kmeans 能够高效挖掘原始风速的特征,降低原始风速的复杂程度;结合 LSTM 预测网络后,有着更强的时序信号处理能力,能够更充分地挖掘时序信息,有着更高的时序性数据的的预测精度,在风速短期预测领域更具有优势。

为了进一步衡量本文提出的 Kmeans-VMD-LSTM 预测模型的预测精度及误差特性,本文也选取了其他文献中的模型进行对比。

分别用基于经验模态分解的最小二乘支持向量机模型 (EEMD-LSSVM^[14])、基于 EMD 的 Elman 神经网络模型 (EMD-Elman^[15]) 和本文所建立的 Kmeans-VMD-LSTM 预测模型进行对比分析。4 个模型的输入输出维数均为 24 维,采样间隔均为 1 h,预测均为未来 1 天的数据。误差比较结果如表 6 所示。

由表 6 可看出,本文所提出的预测模型的各项误差均比文献 [14-15] 的小,因此在实际的应用中,针对短期风速预测 Kmeans-VMD-LSTM 预测模型能够达到高的预测精度。

表 6 本文方法与其他文献对比结果

模型	MAE	MAPE/%	RMSE
EEMD-LSSVM ^[14]	0.728 0	12.080 0	—
EMD-Elman ^[15]	0.930 0	20.600 0	1.240 0
Kmeans-VMD-AdBP	0.676 1	10.235 2	0.927 6
Kmeans-VMD-LSTM	0.393 32	5.954 00	0.509 85

4 结语

提出基于 Kmeans、VMD、样本熵重构和 LSTM 神经网络的组合风速预测模型,通过大量仿真试验,得出以下结论:

(1) 使用 Kmeans 对原始风速数据聚类划分,使得同一类别中的相似日的对象具有高相似性,针对不同的相似日类别进行具体分析,挖掘影响风速变化的潜在因素,提高风速预测精度。

(2) 将风速序列分解出合适的层数,寻找出更能反映风速变化特性的多层模态分量,降低风速随机性、突发性和波动性的影响,从而使预测精度进一步提高。

(3) 利用 LSTM 神经网络能够反映时序性序

列这一特点,本文构建的 Kmeans-VMD-LSTM 预测模型比其他 2 种模型的预测精度有着极大的提升,可为后续电网的调度运行和解决风电消纳问题提供参考。

【参考文献】

- [1] 陈锴. 促进风电消纳的电力系统经济调度研究 [D]. 徐州:中国矿业大学, 2020.
- [2] 魏忻, 石强, 符文熹, 等. 考虑 CEEMDAN 样本熵和 SVR 的短期风速预测 [J]. 水电能源科学, 2020, 38(11): 207.
- [3] 刘建华, 李锦程, 杨龙月, 等. 基于 EMD-SLSTM 的家庭短期负荷预测 [J]. 电力系统保护与控制, 2019, 47(6): 40.
- [4] 吴宇杭, 温步瀛, 江岳文, 等. 基于变分模式分解和深度门控循环网络的风速短期预测模型 [J]. 电网与清洁能源, 2018, 34(12): 59.
- [5] 邢恩恺. 基于改进 VMD 预处理与双向 LSTM 的风功率预测研究 [D]. 吉林:东北电力大学, 2019.
- [6] 李宏, 褚丽鑫, 刘庆强, 等. SG-VMD-SVD 的信号去噪方法研究 [J]. 吉林大学学报(信息科学版), 2021, 39(2): 158.
- [7] 张妍, 韩璞, 王东风, 等. 基于变分模态分解和 LSSVM 的风电场短期风速预测 [J]. 太阳能学报, 2018, 39(1): 194.
- [8] 张容畅. 含风力发电和储能系统的电力系统经济调度研究 [D]. 徐州:中国矿业大学, 2019.
- [9] 郑近德, 陈敏均, 程军圣, 等. 多尺度模糊熵及其在滚动轴承故障诊断中的应用 [J]. 振动工程学报, 2014, 27(1): 145.
- [10] 耿志远, 黄晴. 深度学习在移动无线网络中的应用 [J]. 电子商务, 2018(9): 13.
- [11] 邱浩, 赵学军, 张自力. 基于 LSTM-Adaboost 模型的商品期货投资策略研究 [J]. 南方金融, 2018(8): 62.
- [12] 夏春晓. 基于 Tensorflow 的航道智能服务系统研究 [D]. 大连:大连海事大学, 2019.
- [13] 范磊, 卫志农, 李慧杰, 等. 基于变分模态分解和蝙蝠算法-相关向量机的短期风速区间预测 [J]. 电力自动化设备, 2017, 37(1): 93.
- [14] 章国勇, 伍永刚, 张洋. 基于集成经验模态分解和量子细菌觅食优化的风速预测模型 [J]. 太阳能学报, 2015, 36(12): 2930.
- [15] 陶齐宇, 余传锦, 李永乐, 等. 基于经验值分解及 Elman 神经网络的桥址区风速预测 [J]. 灾害学, 2017, 32(4): 85.

(上接第 84 页)

- [3] 孙丽玲, 李和明, 许伯强. 基于多回路数学模型的异步电动机内部故障瞬变过程 [J]. 电力系统自动化, 2004, 28(23): 35.
- [4] 马宏忠, 张志艳, 张志新, 等. 双馈异步发电机定子匝间短路故障诊断研究 [J]. 电机与控制学报, 2011, 15(11): 50.
- [5] WU Q, NANDI S. Fast single-turn sensitive stator inter-turn fault detection of induction machines based on positive and negative sequence third harmonic components of line currents [C]//2008 IEEE Industry Applications Society Annual Meeting, 2008.
- [6] ARKAN M, KOSTIC-PEROVIC D, UNSWORTH P J. Modeling and simulation of induction motors with inter-turn faults for diagnostics [J]. Electric Power Systems Research, 2015, 75(1): 57.
- [7] DEVANNEAUX V, DAGUES B, FAUCHER J, et al. An accurate model of squirrel cage induction machines under stator faults [J]. Mathematics and Computers in Simulation, 2003, 63(3): 377.
- [8] 杨志峰, 翟超, 李小兵. 感应电机定子绕组缺相故障诊断的仿真与研究 [J]. 大电机技术, 2007, 17(5): 25.
- [9] 董建园, 段至善, 熊万里. 异步电动机定子绕组故障分析及诊断方法 [J]. 中国电机工程学报, 1999, 19(3): 26.
- [10] 赵路杰. 复杂工况条件的感应电机故障诊断研究 [D]. 上海:上海交通大学, 2020.
- [11] 陈金刚. 笼型三相异步电动机绕组烧毁故障分析 [J]. 防爆电机, 2019, 54(3): 47.