

基于 WRF 数值模式的 SDAE-SVR 风速预测模型研究

陈巧特¹, 符冉迪^{1*}, 何彩芬²

(1. 宁波大学 信息科学与工程学院, 浙江 宁波 315211; 2. 镇海区气象局, 浙江 宁波 315202)

摘要: 风速预测是风力预报中的核心与基础, 采用天气研究和预报(Weather Research and Forecasting, WRF)模式进行风力预报往往存在风速预测误差较大的问题. 为了提高风速预测精度, 提出了一种基于深度学习和支持向量回归(Support Vector Regression, SVR)相结合的风速预测模型. 该模型以 WRF 模式预报输出的多种气象变量为基础, 结合气象自动观测站传感器的实测风速, 引入堆栈降噪自动编码(Stacked De-noising Auto-Encoder, SDAE)深度网络来学习样本数据中隐含的深度特征, 然后将该深度网络最后一层输出的深度特征置入回归器 SVR 中, 利用 SVR 良好的回归预测性能对 WRF 模式预报的未来 1 h 风速进行预测订正. 结果表明: 所建立的 SDAE-SVR 风速预测模型具有较高的风速预测精度, 在对典型日的 WRF 模式预报未来 1 h 风速的预测订正中, 其平均百分比误差与均方根误差仅为 8.28% 与 $0.8066 \text{ m}\cdot\text{s}^{-1}$.

关键词: 天气研究和预报模式; 支持向量回归; 堆栈降噪自动编码; 深度学习; 风速预测

中图分类号: TP391

文献标志码: A

文章编号: 1001-5132 (2020) 02-0047-07

为了保障经济活动的安全进行, 气象部门需要对风力等级做出准确的预报. 风力等级的量化受风速大小的影响, 而影响风速的因素众多, 如地形、温度、气压、湿度等^[1], 因而增大了风速预测的难度. 目前, 根据输入数据的特点, 可以将风速预测模型分为采用和不采用数值天气预报数据两类. 在采用数值天气预报数据中, 常用支持向量回归(Support Vector Regression, SVR)和第五代 Penn-State/NCAR 中尺度模式(Fifth-Generation Penn-State/NCAR Mesoscale Model, MM5)^[2-3].

由于现阶段天气研究和预报(Weather Research and Forecasting, WRF)模式受物理参数化方案不完善、分辨率低和地形不精确等因素的影响, 导致风速的预报结果误差较大, 因此需要对 WRF 模式进行修正, 以提高风力预报的准确度. 文献[4]基于支持向量回归构建了多因子的风速预测模型, 利用 WRF 模式预报中众多风速属性的气象变量和历史风速建模, 较好地解决了 WRF 模式预报中大风预测偏小、小风预测偏大的误差问题. 文献[5]利用

极限学习机(Extreme Learning Machine, ELM)算法对 WRF 模式预报风速进行预测订正, 该算法的数学模型简单, 具有计算复杂度小的特性, 并且提高了风速预测的精度. 但是, 这些研究中预测模型均采用浅层的机器学习模型, 泛化性能一般, 导致风速预测的精度难以进一步提高.

本文将深度学习思想引入 WRF 模式的风速预测订正中, 利用堆栈降噪自动编码(Stacked De-noising Auto-Encoder, SDAE)^[6]深度网络模型来挖掘样本数据中隐含的深度特征, 将训练完成的 SDAE 网络与回归器 SVR 相连接, 利用 SDAE 网络输出的深度特征对 SVR 进行训练, 最后将训练好模型用于对 WRF 模式输出的未来 1 h 风速的预测订正, 以期提高 WRF 模型对风速的预报精度.

1 风速预测模型 SDAE-SVR

1.1 自动编码器原理

自动编码器(Auto-Encoder, AE)是一种具有对称结构的神经网络^[7], 其内部结构如图 1 所示. AE

收稿日期: 2019-03-04.

宁波大学学报(理工版)网址: <http://journal.lg.nbu.edu.cn/>

基金项目: 国家自然科学基金(61471212); 浙江省自然科学基金(LY16F010001); 宁波市自然科学基金(2016A610091, 2017A610297).

第一作者: 陈巧特(1994-), 男, 湖北黄冈人, 在读硕士研究生, 主要研究方向: 风速预测. E-mail: 864309372@qq.com

*通信作者: 符冉迪(1971-), 男, 浙江宁波人, 副教授, 主要研究方向: 数字图像处理. E-mail: furandi_nbu@163.com

通过编码过程将原始的输入映射到隐含层,再由解码过程将隐含层的特征重构出原始的输入. 计算输出与输入之间的重构误差,如果重构误差的范围较小,可以认为得到的隐含层特征是输入在另一种空间的特征表示,利用该方式可以提取输入数据的特征.




图1 自动编码器内部结构示意图^[8]

若有一无标签的风速预测输入样本集 $X = \{x^i | 1 \leq i \leq N\}$, N 为该样本的总个数, x^i 为样本集中的第 i 个样本, 其中 x 是 m 维特征向量. 设 $H = \{h^i | 1 \leq i \leq N\}$ 表示隐含层特征向量集合, 则 h^i 表示第 i 个输入样本对应的隐含特征向量, h 是 n 维特征向量, AE 的编码过程可表示为:

$$H = g(X) = \sigma(WX + b), \quad (1)$$

式中: W 表示连接输入层和隐含层间的权值矩阵; b 为偏置矩阵; σ 表示 Sigmoid 激活函数.

解码过程是利用编码器得到的隐含层特征向量重构出输入的过程, 属于编码器的逆运算. 设 $\hat{X} = \{\hat{x}^i | 1 \leq i \leq N\}$ 表示重构的输出向量集合, $\hat{x}^i$ 表示第 i 个样本对应的输出向量, AE 的解码过程可表示为:

$$\hat{X} = f(H) = \sigma(W'H + b'), \quad (2)$$

式中: W' 表示连接输入层与隐含层间的权值矩阵; b' 为偏置矩阵.

AE 为了实现有效的提取特征, 通常需要最小化一个损失函数, 该损失函数一般包括模型的经验风险和结构风险, 最小化损失函数过程即为求解最优模型过程^[10]. 本文的损失函数表示为:

$$L(\theta) = \frac{1}{N} \sum_{i=1}^N \|x^i - \hat{x}^i\|^2 + \frac{\lambda}{2} (\|W\|^2 + \|W'\|^2), \quad (3)$$

式中: $\theta = (W, W', b, b')$, 其中第 1 项为均方差项; 第 2 项为 L_2 正则项; λ 为权重的约束项, 目的在于减少权重的幅度.

1.2 SDAE 网络及其训练策略

自动编码器是神经网络中一种常见的基本单元, 虽然其在数据映射过程中保留了原始输入数据的信息, 但是并不能完全保证所提取的特征是对输入数据的一种有效表示, 原因是 AE 可能只是近似地复制了原始输入或者简单地提取了一些可以改变重构误差却不重要的信息. 为了从原始数据中获取鲁棒性较强的特征表示, 文献[9]提出了降噪自动编码器(De-noising Auto-Encoder, DAE), DAE 是在 AE 的基础上提出的一种改进算法, 其结构如图 2 所示.




图2 降噪自动编码结构示意图

由图2可以看出, DAE 除了有编码和解码过程外, 还有在编码之前进行随机的损坏处理过程, 即使输入的数据部分受损, 使用受损数据来训练网络模型, 然后从受损的输入中重构出“纯净”的输出. 常见的损坏处理方式有: 添加各向同性的高斯噪声、遮蔽噪声和椒盐噪声.

SDAE 网络则是将多个 DAE 叠堆在一起组成一种新的深度网络模型, 该模型的顶层可以与分类器或回归器相连, 从而能够实现有监督的学习任务. SDAE 的结构如图 3 所示, 其训练过程包括了无监督和有监督训练.




图3 SDAE 网络结构图

无监督训练: 首先使用输入样本集训练第 1 个 DAE, 得到参数 (W_1, W'_1, b_1, b'_1) 和本层映射的隐含层特征, 即:

$$H(1) = \sigma(W_1 X + b_1), \quad (4)$$

然后使用第 1 层 DAE 输出的隐含层特征 $H(1)$ 作为输入来训练第 2 层 DAE, 得到参数 (W_2, W'_2, b_2, b'_2) 和该层的隐含层特征, 使用相同的训练方法训练之后的每一层, 通过这种策略可以获得网络整体的参数。

有监督训练: 在结束无监督训练后, SDAE 网络执行有监督的微调训练(图 3)。在 SDAE 最后一层添加一个全连接层作为回归层, 该层输出 1 个节点, 该节点对应预测的风速, 使用实测风速作为标签, 并采用反向传播算法对网络进行微调 and 梯度下降算法进行权值更新^[10-11]。

1.3 支持向量回归

选用全连接层作为模型的回归器, 仅使用 Sigmoid 函数作为深度特征的预测函数, 结果发现其预测效果一般。因此, 在风速预测订正阶段, 选用回归领域表现良好的 SVR 算法作为 SDAE 模型的回归器。SVR 算法是建立在统计学理论上为解决回归问题的一种机器学习方法, 采用结构风险最小化原则, 不但考虑了训练样本的拟合性, 而且考虑了训练样本的复杂性^[12]。SVR 算法的决策函数可表示为:

$$f(x_d) = \langle w_s, \varphi(x_d) \rangle + b_s, \quad (5)$$

式中: $f(x_d)$ 为预测的风速; x_d 表示 SDAE 模型输入的深度特征向量; w_s 表示权重; $\varphi(x_d)$ 为非线性映射函数; b_s 为偏置。

为了获取最优的 w_s 和 b_s , 可以通过最小化式(6)来实现。

$$R(f) = \frac{1}{2} \|w_s\|^2 + C \frac{1}{N} \sum_{k=1}^N (y_k - f(x_d))^2, \quad (6)$$

式中: 第 1 项为 L_2 正则项; 第 2 项为均方误差项, 其中 y_k 为实测风速值, C 为惩罚因子。

引入 Lagrange 方程后, 可得回归函数形式为:

$$f(x_d) = \sum_{k=1}^N (\bar{\alpha}_k - \bar{\alpha}_k^*) K(x_d, x_k) + b_s, \quad (7)$$

式中: $\bar{\alpha}_k, \bar{\alpha}_k^* \geq 0, k=1, 2, \dots, N$ 为 Lagrange 乘子; $K(x_d, x_k)$ 为核函数。

由于径向基函数相对其他核函数具有参数较少的优点, 所以采用径向基函数作为 SVR 核函数, 其表达式为:

$$K(x_d, x_k) = \exp \left\{ -\frac{\|x_d - x_k\|^2}{2\delta^2} \right\}. \quad (8)$$

2 SDAE-SVR 模型的风速预测订正流程

SDAE-SVR 模型风速预测订正流程如图 4 所示, 主要包括以下几个步骤。




图 4 基于 SDAE-SVR 模型的风速预测订正流程

步骤 1 分别从自动观测站传感器处采集实测风速数据和对应的 WRF 模式中的预报数据。

步骤 2 对采集的数据进行预处理操作, 如数据清洗, 数据标准化和归一化等。

步骤 3 将采集的数据样本划分为训练样本和测试样本, 训练样本主要用于训练 SDAE 网络和 SVR, 测试样本主要用于评估 SDAE-SVR 风速预测订正模型, 并用于计算 WRF 模式风速预测订正的误差。

步骤 4 该步骤为模型训练过程。先将训练样本输入到 SDAE 网络中进行训练, 此时 SDAE-SVR 模型的超参数需要预先确定; 训练好的 SDAE 网络有 2 种信息需要利用, 一种是 SDAE 网络最后一层输出的深度特征信息, 另一种是 SDAE 的网络参数。本文在该网络顶层加入回归器 SVR, 利用 SDAE 输出的深度特征来训练 SVR。训练完毕后保存回归器参数, 用于后续的回归测试, 图 4 中的虚线箭

头表示固定参数过程。

步骤 5 测试阶段 将测试样本输入至已经训练好的 SDAE 网络中, 并提取 SDAE 网络最后一层输出的深度特征, 将该深度特征输入回归器 SVR 中得到回归预测结果, 根据预测结果完成风速预测订正。

3 实验结果与分析

3.1 实验样本数据

实验数据源于宁波象山某锚地 2015 年 7 月 1 日至 9 月 30 日(台风活跃期)的数据, 该数据包括实测风速数据与对应的 WRF 模式预报数据(采样间隔为 1 h)。选取气象变量未来 1 h 的风速、降水量、温度、风向、相对湿度、露点温度和大气压强, 并结合前 1 h 的实测历史风速作为 SDAE-SVR 模型的输入进行逐小时的风速预测订正。为了平衡各项特征参数、减少模型的计算量和误差, 需要将数据归一化到[0, 1]。7 月 1 日至 9 月 30 日一共有 2 160 组采样点, 选取每月最后 3 d 数据作为本文模型的单月风速订正测试样本, 选取 8 月 7 日至 10 日 4 d 数据作为典型日(包含台风期和非台风期)数据样本进行模型对比, 得到实验的训练样本数为 1 800 组, 测试样本数为 360 组。

3.2 SDAE-SVR 模型的超参数设定

SDAE 网络的训练学习率采用[0, 1]区间以 0.1 为间隔的数值作为备选参数, 使用二分法查找学习率, 以模型收敛至局部最小且最快的参数作为最优参数。SDAE 网络的层数和隐含层节点个数决定着网络结构的复杂程度, 其中隐藏层节点数根据经验公式确定, 即 $n_o = 2n_i + 1$, n_o 为要确定的隐含层节点个数, n_i 为输入的节点数。网络层数的确定是以固定其他各项参数为基础, 逐层进行添加, 直至预测准确率下降, 返回准确率最高的设定层数。SDAE 中引入降噪过程的噪声函数为各向同性的高斯噪声函数, 其噪声比例依据经验^[10]设为原输入数据的二折, 该数据过大会导致产生无效的编码特征。

SVR 中惩罚因子 C 和控制半径 δ 决定了最终的风速回归预测的性能。本文采用网格搜索法进行参数寻优: 首先进行粗网格搜索, 根据整体误差最小的原则使用留一法初步确定合适的 C 和 δ ; 再

进行细网格搜索, 重复细网格搜索过程, 直至参数达到设定的精度为止。经过参数调优, 该模型的超参数见表 1。

表 1 SDAE-SVR 模型的超参数

超参数	数值
SDAE 网络的训练学习率	0.6
输入层节点数	8
输出层节点数	1
第 1 层隐含层节点数	17
第 2 层隐含层节点数	35
第 3 层隐含层节点数	71
噪声比例	0.2
SVR 的惩罚因子 C	187.6
SVR 的控制半径 δ	0.120 3

3.3 误差评价指标

为了有效地评价不同模型对 WRF 模式预报风速的预测订正性能, 误差评价函数选用平均绝对误差 E_{MAE} 、平均百分比误差 E_{MAPE} 和均方根误差 E_{RMSE} , 各指标的计算公式为:

$$E_{MAE} = \frac{1}{N} \sum_{t=1}^N |y_t - \hat{y}_t|, \quad (9)$$

$$E_{MAPE} = \frac{1}{N} \sum_{t=1}^N \left| \frac{y_t - \hat{y}_t}{y_t} \right| \times 100\%, \quad (10)$$

$$E_{RMSE} = \sqrt{\frac{1}{N} \sum_{t=1}^N (y_t - \hat{y}_t)^2}, \quad (11)$$

式中: y_t 和 $\hat{y}_t$ 分别表示真实值和预测值, 其中 N 为样本总数。

3.4 WRF 模式风速预报误差分析

将 WRF 模式预报风速值与自动观测站的真实风速数值进行误差对比, 真实风速值和 WRF 模式预报值对比结果如图 5 所示, 相对误差(真实值与 WRF 模式预报值之差)的频数分布如图 6 所示。

从图 5 可看出, WRF 模式预报值与真实值变化趋势大致相近, 但存在一定的偏差, 在大风处整体预报值偏小, 对小风天气预报的细节描绘较差, 预报值在真实值上下波动。

从图 6 可看出, 相对误差的波动范围主要在 $-1.5 \sim 4.5 \text{ m} \cdot \text{s}^{-1}$, WRF 模型预报的风速整体偏小, 表明 WRF 模式预报风速能在一定程度上反应真实的风速分布特征, 但需要进一步订正, 才能实现风速精准化预测。





图5 WRF 模式预报风速与真实风速对比



1 为 $-3.5 \sim -1.5$; 2 为 $-1.5 \sim 0.5$; 3 为 $0.5 \sim 2.5$;
4 为 $2.5 \sim 4.5$; 5 为 $4.5 \sim 6.5$; 6 为 $6.5 \sim 8.5$; 7 为 $8.5 \sim 10.5$.

图6 真实风速与 WRF 模式预报风速相对误差分布

3.5 SDAE-SVR 模型的风速订正效果分析

针对 WRF 模式整体风速预测偏小, 精准度不高的问题, 本文利用训练好的 SDAE-SVR 模型对该模式输出的风速预报进行预测订正, 订正前后的误差结果见表 2。

表2 应用 SDAE-SVR 模型风速订正前后的误差比较

月份	WRF 预报风速结果			SDAE-SVR 模型订正后结果		
	$E_{MAE}/$ ($m \cdot s^{-1}$)	$E_{RMSE}/$ ($m \cdot s^{-1}$)	$E_{MAPE}/$ %	$E_{MAE}/$ ($m \cdot s^{-1}$)	$E_{RMSE}/$ ($m \cdot s^{-1}$)	$E_{MAPE}/$ %
7	3.5893	4.4009	49.25	0.6899	0.8418	6.38
8	2.4125	3.5863	43.37	0.6115	0.8268	8.43
9	2.2028	2.9968	37.60	0.5985	0.8066	8.28
均值	2.7348	3.6613	43.41	0.6333	0.8251	7.70

从表 2 可看出, SDAE-SVR 模型的误差均小于 WRF 模式的误差。SDAE-SVR 模型 7 月到 9 月平均绝对误差 E_{MAE} 减小至 $0.7 m \cdot s^{-1}$ 以内, 3 个月的 E_{MAE} 均值为 $0.6333 m \cdot s^{-1}$, 比 WRF 模式下降了 $2.1015 m \cdot s^{-1}$; 每月的均方根误差 E_{RMSE} 降低至 $0.85 m \cdot s^{-1}$ 以内, 均值同比下降了 $2.8362 m \cdot s^{-1}$, 3 个月的平均百分比误差 E_{MAPE} 均值由 43.41% 下降至 7.70% ,

明显提高了预报精度。

3.6 实验对比分析

本文采用浅层模型与深层模型来进行风速预测订正的实验对比。浅层模型采用文献[4]中 SVR 和文献[5]中极限学习机(ELM); 深层模型除上述所提模型外, 引入了 SAE-SVR 模型。SAE 网络属于未引入降噪过程的堆栈自动编码器, 文献[6]使用 SAE-SVR 模型实现了对时间序列的准确预测。使用训练样本训练各个模型, 模型训练完毕后, 以典型日为测试样本进行 0~96 h 的逐小时预报, 各模型对典型日的预测订正后结果如图 7~10 所示。

通过观察各个模型的预测订正结果(图 7~10)可以看出, SVR、ELM、SAE-SVR 和 SDAE-SVR 都能对 WRF 模式预报的风速进行订正, 但是 SVR




图7 SVR 模型对典型日风速的预测订正结果




图8 ELM 模型对典型日风速的预测订正结果




图9 SAE-SVR 模型对典型日风速的预测订正结果




图 10 SDAE-SVR 模型对典型日风速的预测订正结果

模型在风速突变处拟合效果较差, ELM 模型在大风处存在预测值连续偏小问题, 虽然 SAE-SVR 模型没有出现较大偏差, 但与本文 SDAE-SVR 模型相比, 订正效果稍差. 各模型的风速预测订正误差结果和训练时长见表 3.

表 3 不同模型的风速预测订正误差结果和训练时长

模型	$E_{MAE}/(m \cdot s^{-1})$	$E_{RMSE}/(m \cdot s^{-1})$	$E_{MAPE}/\%$	训练时长/s
SVR	1.076 2	1.693 2	13.46	902
ELM	1.140 1	1.537 0	12.57	716
SAE-SVR	0.800 9	1.057 2	10.03	1 526
SDAE-SVR	0.598 5	0.806 6	8.28	1 557

各模型训练均在同一台计算机上完成, 各项误差指标反映的是模型的预测订正性能, 而训练时长则反映了模型计算的复杂度. 其中, SDAE-SVR 模型在对典型日的风速预测订正中的各项误差指标均为最小值, 风速预测订正精度最高. 本文模型与浅层模型 SVR 和 ELM 相比, 指标 E_{MAPE} 分别降低了 5.18% 和 4.29%, 指标 E_{MAE} 和 E_{RMSE} 也有较大幅度的下降. SAE-SVR 模型与本文模型相似, 其风速预测订正性能同样优于浅层模型, 但是各项误差指标略高于本文模型. 因此, 从预测精度看, 引入降噪过程的 SDAE 模型提取的深度特征要优于 SAE 模型, 其鲁棒性更强, 更适合用于 SVR 模型训练与回归预测. 从计算的复杂度看, 深层模型的训练时长比浅层模型更久, 其中浅层模型 SVR 和 ELM 的训练时长分别为 902 s 和 716 s, 而本文模型耗时最长, 为 1 557 s. 究其原因是 SAE-SVR 没有引入降噪过程, 其运算复杂度稍低, 训练耗时为 1 526 s. 综上表明, 深层模型复杂度要高于浅层模型, 但获得了更高的预测精度, 而引入降噪过程在提高复杂度的同时, 预测精度也有所提升.

4 结论

针对在使用 WRF 模式预报风速过程中存在预报风速精度较低的问题, 提出了一种基于 WRF 数值模式的深度网络模型 SDAE-SVR, 通过实验得出以下结论:

(1) WRF 模式预报的风速虽然与真实风速间存在一定偏差, 但其预报风速的整体趋势与真实风速大致相近; 然而仍需进行订正才能实现日常风速的准确预报.

(2) 堆栈降噪自动编码网络 SDAE 在引入降噪过程后, 其性能要优于传统的堆栈自动编码网络 SAE, 且能获得更强的鲁棒性.

(3) 浅层模型在风速预测中的精度要低于深层模型. SDAE 和 SVR 的结合模型, 有效汲取了深度模型学习良好的特征, 又获得了支持向量回归在回归预测上的优良性能.

参考文献:

- [1] Kim Y J, Jeong M A, Son N R. Forecasting of short-term wind power generation based on SVR using characteristics of wind direction and wind speed[J]. The Journal of Korean Institute of Communications and Information Sciences, 2017, 42(5):1085-1092.
- [2] 叶小岭, 顾荣, 邓华, 等. 基于 WRF 模式和 PSO-LSSVM 的风电场短期风速订正[J]. 电力系统保护与控制, 2017, 45(22):48-54.
- [3] 邓华, 张颖超, 顾荣, 等. 基于 PCA-RBF 的风电场短期风速订正方法研究[J]. 气象科技, 2018, 46(1):10-15.
- [4] 钱斌凯, 何彩芬, 金炜, 等. 基于支持向量机的多因子风速预测[J]. 宁波大学学报(理工版), 2018, 31(3):14-19.
- [5] 张颖超, 肖寅, 邓华. 基于 ELM 的风电场短期风速订正技术研究[J]. 气象, 2016, 42(4):466-471.
- [6] 崔江, 唐军祥, 龚春英, 等. 一种基于改进堆栈自动编码器的航空发电机旋转整流器故障特征提取方法[J]. 中国电机工程学报, 2017, 37(19):5696-5706; 5847.
- [7] Cho K, Courville A, Bengio Y. Describing multimedia content using attention-based encoder-decoder networks[J]. IEEE Transactions on Multimedia, 2015, 17(11):1875-1886.
- [8] 侯文擎, 叶鸣, 李巍华. 基于改进堆叠降噪自编码的滚动轴承故障分类[J]. 机械工程学报, 2018, 54(7):87-96.
- [9] Vincent P, Larochelle H, Lajoie I, et al. Stacked denoising autoencoders: Learning useful representations in a deep

- network with a local denoising criterion[J]. Journal of Machine Learning Research, 2010, 11(12):3371-3408.
- [10] Mi X W, Liu H, Li Y F. Wind speed forecasting method using wavelet, extreme learning machine and outlier correction algorithm[J]. Energy Conversion and Management, 2017, 151:709-722.
- [11] Wang J J, Zhang W, Wang J Z, et al. A novel hybrid approach for wind speed prediction[J]. Information Sciences, 2014, 273(18):304-318.
- [12] Santamaria-Bonfil G, Reyes-Ballesteros A, Gershenson C. Wind speed forecasting for wind farms: A method based on support vector regression[J]. Renewable Energy, 2015, 85:790-809.

Wind speed forecasting model of SDAE-SVR based on WRF numerical pattern

CHEN Qiaote¹, FU Randi^{1*}, HE Caifen²

(1.Faculty of Electrical Engineering and Computer Science, Ningbo University, Ningbo 315211, China;

2.Zhenhai Meteorological Observatory, Ningbo 315202, China)

Abstract: Wind speed forecasting is essential for wind forecasting. Using the Weather Research and Forecast (WRF) pattern in wind speed forecasting constantly comes up with some problematic issues with it. To tackle the problem in order to improve the accuracy of wind speed prediction, a forecasting model combining deep learning with Support Vector Regression (SVR) is proposed in this paper. The input data for the model is collected based on the various meteorological variables generated from the WRF pattern, and are combined with the real wind speed collected from the sensor of automatic meteorological observation. Stacked De-noising Auto-Encoder (SDAE) deep network is constructed to learn the intrinsic data characteristic, then the last layer of the deep network output characteristics is fed into SVR, and the good regression forecasting performance of the SVR is used to correct the future 1h wind speed forecasting of the WRF pattern. The experimental results show that the established SDAE-SVR wind speed forecasting model performs with higher accuracy in correcting the future 1h wind speed prediction of WRF pattern for typical days, and the mean average percentage error as well as root-mean-square error are limited within the range of 8.28% and $0.806\text{ m}\cdot\text{s}^{-1}$.

Key words: weather research and forecasting pattern; support vector regression; stacked denoising auto-encoder; deep learning; wind speed forecasting

(责任编辑 史小丽)