

DOI: 10.7667/PSPC170765

基于稀疏编码的短期风电功率时间序列预测

李军, 於阳

(兰州交通大学自动化与电气工程学院, 甘肃 兰州 730070)

摘要: 针对短期风电功率时间序列, 提出一类基于字典的稀疏编码预测方法。为构建预测模型, 将历史风电功率时间序列数据组成具有时延的输入-输出数据对, 其输入与输出数据向量以原子形式分别构成两个字典, 无需模型的训练阶段。针对待预测的时延输入数据向量, 使用 l_1 范数或弹性网络正则化的稀疏分解凸优化算法计算稀疏编码的权值, 进一步借助历史输出数据所构成的字典, 以得到相应的预测输出。与此同时, 还分析了将测试数据实时加入字典, 并维持字典容量不变的三种自适应更新策略, 以进一步提升模型的预测精度。为了验证该方法的有效性, 将不同的稀疏编码方法首先应用于 Santa Fe 混沌时间序列预测中, 其次, 将其分别应用于短期风电功率间接预测中, 在同等条件下, 与 SVM 方法进行了比较。结果表明, 不同的稀疏编码方法均取得了很好的预测效果, 其中基于弹性网络正则化的稀疏编码方法具有较高的预测精度, 显示出其有效性。

关键词: 稀疏编码; 算法; 弹性网络正则化; 风电功率; 预测

Short-term wind power time series prediction based on sparse coding method

LI Jun, YU Yang

(School of Automation & Electrical Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China)

Abstract: Aiming at short-term wind power time series, a class of dictionary-based sparse coding prediction method is proposed. The historical wind power time series data are composed to the time-lagged input-output data pairs to build the prediction model, while the two dictionaries are respectively constructed by regarding the all input and output data vectors as atoms, without the training phase of the model. For the time-lagged test input data vectors need predicting, convex optimization algorithms with l_1 norm or elastic net regularization using sparse decomposition technology are applied to calculate the weights by sparse coding. Furthermore, by the dictionary which is constructed using the historical output data, the corresponding predicted outputs are obtained. Simultaneously, adaptive dictionary updating strategies are given, where test data is successively added to the dictionary in real time while maintaining the dictionary size by using three algorithms, so as to further improve the prediction accuracy of the model. In order to verify the effectiveness of this method, different sparse coding methods are firstly applied to the prediction of Santa Fe chaotic time series, and then applied to the indirect prediction for short-term wind power respectively. Under the same condition, compared with the SVM method, experimental results show that different sparse coding methods have achieved good prediction results, and the sparse coding methods using elastic net regularization have higher prediction precision and show their effectiveness.

This work is supported by National Natural Science Foundation of China (No. 51467008).

Key words: sparse coding; algorithm; elastic net regularization; wind power; prediction

0 引言

近些年来, 可再生能源尤其是风能已引起越来越多的关注, 得到了广泛的应用。然而, 由于风能

资源的随机性与间歇性, 风能的高度渗透所导致的不确定性影响, 其在电力系统运行中易产生“不利效应”。为避免或降低风电并网的这种“不利效应”, 精确、可靠的风电功率预测是必要的^[1-2]。短期风电功率预测^[3-6]能够规避由于风电机组装机容量容量的增大而带来的风电功率波动性影响, 是能源领域非常重要的研究方向之一。

基金项目: 国家自然科学基金项目资助(51467008); 兰州交通大学优秀科研团队项目资助(201701)

风电功率的预测方法通常分为物理方法、统计方法等。传统的统计方法是诸如Persistence模型、自回归积分滑动平均(ARIMA)模型、Kalman滤波等线性回归模型的预测方法^[2]。更先进的一类统计方法,如神经网络^[4]、支持向量机^[5-6]等,在风电功率的短期预测中已取得了许多成功应用。

目前,稀疏表示(Sparse Representation, SR)^[7]作为一种先进的机器学习方法,已在图像去噪、图像恢复等领域中得到广泛应用。SR方法由字典学习和稀疏编码两部分构成,其中,稀疏编码通常是指采用少量的基向量加权和的形式对数据信号进行建模。文献[8-9]给出一种基于字典的稀疏编码及基于字典更新的稀疏编码方法,成功应用于时间序列预测或在线预测中。文献[10]给出一种稀疏编码方法,并应用于智能电网的家居电力需求预测中。文献[11]则给出一种基于字典学习的SR方法,将其应用于网络动态过程预测中,效果较好。鉴于稀疏编码方法在混沌时间序列预测及负荷预测中的成功应用,将其应用于短期风电功率预测中也应该是可行的。

考虑到弹性网络正则化^[12]对回归精度的影响,在文献[8-9]的基础上,本文给出一种基于弹性网络正则化的稀疏编码方法,并将不同的稀疏编码方法应用于风电功率短期预测中,在同等条件下,与现有的SVM方法进行比较,以验证本文方法的有效性。

1 信号的稀疏编码及求解

对于一组数据或信号向量,如果想减小表示的冗余度,常用的方法是主元分析,这可看作是一种紧致表示,即编码。紧致编码是通过减少信号的表示维数来减少冗余的。如果能找到一个坐标系,使得原数据在此坐标系中只有少数分量不为零,就可做到稀疏编码。

信号的稀疏编码通过对超完备字典中基向量的线性组合,以紧致、高效的方式表示原信号,且大多数字典基向量的权值趋于零,权值非零的字典基向量被选择用于表示原信号。信号向量 $\mathbf{x} \in \mathbf{R}^q$ 的稀疏表示为

$$\mathbf{x} = \sum_{i=1}^N \alpha_i \phi_i \quad (1)$$

式中,基向量 ϕ_i 为字典 Ψ 中的元素,也称之为原子,

$$\Psi = \{\phi_1, \phi_2, \dots, \phi_N\}.$$

显然,无论取何种字典形式的构成,由于其超完备性会导致式(1)分解不是唯一的,即一些原子能够被来自同一字典的其它原子的线性组合所表示。

通过求解稀疏向量 α 的 l_0 范数优化问题可获得

式(1)的近似逼近,即

$$\min_{\alpha} \|\alpha\|_0 \quad \text{s.t.} \quad \|\Psi\alpha - \mathbf{x}\|_2^2 \leq \varepsilon \quad (2)$$

式中: $\|\alpha\|_0 = \lim_{\rho \rightarrow 0} \sum_i |\alpha_i|^\rho$ 是 α 中非0元素个数;

$\|\alpha\|_2^2 = \sum_i \alpha_i^2$ 是 α 的二次范数。

若限制 α 中非零系数的数目,可将式(2)描述为 M -稀疏优化问题,即

$$\min_{\alpha} \|\Psi\alpha - \mathbf{x}\|_2^2 \quad \text{s.t.} \quad \|\alpha\|_0 \leq M \quad (3)$$

式中, M 是 α 中的非零系数的最大数目个数。

应用拉格朗日乘子,式(2)转换为

$$\min_{\alpha} \frac{1}{2} \|\Psi\alpha - \mathbf{x}\|_2^2 + \lambda \|\alpha\|_0 \quad (4)$$

式中,拉格朗日乘子 $\lambda > 0$,在重构误差与稀疏度方面起到折衷作用。

式(2)一式(4)均为NP-hard问题,求解策略主要有贪婪算法和松弛算法两大类,本文以松弛算法的求解为基础。为使信号的表示稀疏化,假设 α 的先验分布服从Laplacian分布^[13],即

$$p(\alpha | \beta) = \prod_{i=1}^N \frac{\beta}{2} \exp\{-\beta|\alpha_i|\} = \left(\frac{\beta}{2}\right)^N \exp\{-\beta\|\alpha\|_1\} \quad (5)$$

式中: $\|\alpha\|_1 = \sum_i |\alpha_i|$ 是 α 的 l_1 范数;超参数 $\beta > 0$ 。

此时, α 的最大后验估计(MAP) $\hat{\alpha}$ 为

$$\hat{\alpha} = \arg \min_{\alpha} \left\{ \|\Psi\alpha - \mathbf{x}\|_2^2 + 2\sigma^2 \beta \|\alpha\|_1 \right\} \quad (6)$$

令 $\lambda_1 = 2\sigma^2 \beta$,式(6)变形为

$$\hat{\alpha} = \arg \min_{\alpha} \left\{ \|\Psi\alpha - \mathbf{x}\|_2^2 + \lambda_1 \|\alpha\|_1 \right\} \quad (7)$$

式(7)的 l_1 范数正则化问题求解称为Lasso(Least absolute shrinkage and selection operator)及其变形问题的求解^[14]。从信号的稀疏表示来看,式(7)可使用BPDN(Basis Pursuit De-Noising)方法^[15-16]求解。

若给出权值之和等于1的额外约束,将使得稀疏编码的求解成为方差有效(variance-efficient)的权值求解问题^[17]。即式(7)的优化问题可变形为

$$\hat{\alpha} = \arg \min_{\alpha} \left\{ \|\Psi\alpha - \mathbf{x}\|_2^2 + \lambda_1 \|\alpha\|_1 \right\} \quad \text{s.t.} \quad \sum_{i=1}^N \alpha_i = 1 \quad (8)$$

式(2)一式(4)的松弛算法求解就是将 l_0 范数松弛为 l_1 范数问题进行求解, l_1 范数是 l_0 范数的最优凸近似,满足 l_0 范数问题求解的稀疏性。因此,式(8)是式(4)的 l_1 范数表达形式,同理,考虑权值之和等于1的额外约束,式(2)、式(3)的 l_1 范数表达形式分别由如下的式(9)、式(10)表示。

$$\hat{\alpha} = \arg \min_{\alpha} \|\alpha\|_1 \quad \text{s.t.} \quad \|\Psi\alpha - \mathbf{x}\|_2^2 \leq \varepsilon \quad \text{and} \quad \sum_{i=1}^N \alpha_i = 1 \quad (9)$$

$$\hat{\alpha} = \arg \min_{\alpha} \|\Psi \alpha - \mathbf{x}\|_2^2 \quad \text{s.t.} \quad \|\alpha\|_1 \leq \delta \quad \text{and} \quad \sum_{i=1}^N \alpha_i = 1 \quad (10)$$

式中, 参数 δ 限制 α 中的系数绝对值之和的大小。

通常, 式(8)一式(10)的 l_1 正则化问题的求解可通过Lasso问题求解完成, 作为一种针对线性回归问题的收缩选择方法, Lasso通过限制求解系数的绝对值之和, 通过LARS算法^[18]求解。

在 l_1 范数问题求解中可考虑引入弹性网络(Elastic Net, EN)正则化项。作为一种新的正则化收缩和变量选择方法, EN正则化项是一种岭回归正则化项与Lasso的凸组合表达。因此, 加入EN正则化项后, 式(8)一式(10) Lasso优化问题变形为

$$\begin{cases} \hat{\alpha} = \arg \min_{\alpha} \left\{ \|\Psi \alpha - \mathbf{x}\|_2^2 + \lambda_1 \|\alpha\|_1 + \frac{\lambda_2}{2} \|\alpha\|_2^2 \right\} \\ \text{s.t.} \quad \sum_{i=1}^N \alpha_i = 1 \end{cases} \quad (11)$$

$$\begin{cases} \hat{\alpha} = \arg \min_{\alpha} \left\{ \lambda_1 \|\alpha\|_1 + \frac{\lambda_2}{2} \|\alpha\|_2^2 \right\} \\ \text{s.t.} \quad \|\Psi \alpha - \mathbf{x}\|_2^2 \leq \varepsilon \quad \text{and} \quad \sum_{i=1}^N \alpha_i = 1 \end{cases} \quad (12)$$

$$\begin{cases} \hat{\alpha} = \arg \min_{\alpha} \left\{ \|\Psi \alpha - \mathbf{x}\|_2^2 \right\} \\ \text{s.t.} \quad \lambda_1 \|\alpha\|_1 + \frac{\lambda_2}{2} \|\alpha\|_2^2 \leq \xi \quad \text{and} \quad \sum_{i=1}^N \alpha_i = 1 \end{cases} \quad (13)$$

式中, λ_1 和 λ_2 为非负参数, 参数 ξ 限制 α 中的不同范数加权之和的大小。

弹性网络正则项的引入在保持解的稀疏性的同时, 还增强了“组效应”(grouping effect)^[12], 达到好的求解效果。上述式(8)一式(13)优化问题的求解过程可看作凸线性规划问题(Disciplined Convex Programming, DCP)的求解, 算法的具体实现则通过调用CVX工具箱软件^[19]完成, 该软件针对对称的锥约束, 使用SeDuMi优化求解器, 该求解器包含了线性规划、二次规划、半定规划等优化问题的算法求解, 适用于本文稀疏编码方法的所有BPDN优化问题。

CVX软件的具体求解步骤简要概括如下:

- Step 1 检验优化问题符合凸优化;
- Step 2 产生等价的具有兼容性的内点问题;
- Step 3 基于SeDuMi求解器求解;
- Step 4 转换为原优化问题的解。

2 稀疏编码应用于时间序列预测

针对长度为 N 的单变量时间序列数据 $\{y(t)\}$, 首先由时间序列构建数据集, 待建立的预测模型如式(14)所示。

$$\hat{y}(t+h) = f(\mathbf{x}(t)) = f[y(t), y(t-1), \dots, y(t-m+1)] \quad (14)$$

式中: $\hat{y}(t+h)$ 为预测输出; h 为步长; m 为嵌入维数; $f(\cdot)$ 为待建立的映射关系; 即 $f: \mathbf{R}^m \rightarrow \mathbf{R}$ 。

其次, 为构建基于式(14)的由不同稀疏编码方法建立的预测模型, 需要选择字典, 如DCT字典、小波字典等, 本文则直接选择由单变量时间序列构建的历史时延输入—输出数据对, 分别作为字典, 无需模型的训练阶段。由全部的历史输入数据向量构建字典 $\Psi \in \mathbf{R}^{m \times N_1}$, 其中, N_1 为训练数据集的数目, Ψ 的原子为: $\mathbf{x}(t) = [y(t), y(t-1), \dots, y(t-m+1)]^T$, Ψ 一经确定则不再变化。另一个字典 $\Phi \in \mathbf{R}^{1 \times N_1}$ 由相应的目标输出 $y(t+h)$ 作为原子构成。显然, 稀疏逼近是一种基于内存的学习方法。

对于测试数据集 $\{\mathbf{x}(t); y(t+h)\}_{t=N_1}^N$ 中的任一数据, 首先选择式(8)一式(13)中的任一种稀疏编码优化算法, 借助字典 Ψ , 计算出相应的稀疏向量 $\alpha \in \mathbf{R}^{N_1 \times 1}$ 表示, 在此基础上, 相应的预测目标输出 $\hat{y}(t+h)$ 应为

$$\hat{y}(t+h) = \langle \Phi, \alpha \rangle \quad (15)$$

式中, $\langle \cdot \rangle$ 为内积符号。

对于非平稳时间序列而言, 由于模型的参数一旦固定, 将很难跟踪信号的剧烈变化, 并产生很大的预测误差。因此, 实际应用中往往需要考虑在线自适应的预测策略。基于此, 随着测试数据的不断依次进入, 可对已有字典进行在线自适应更新, 进行在线预测。因此, 进一步可给出如下所述的字典自适应更新策略。

1) 替换最旧原子(Replace Old, RO)策略

在RO策略中, 对初始字典 $\Psi \in \mathbf{R}^{m \times N_0}$ 中的原子, N_0 为初始字典中的数据数目, 以新观测的数据替代最旧的原子即可, 新字典的容量不变。相应的 $\Phi \in \mathbf{R}^{1 \times N_1}$ 也进行更新。

2) 替换最近原子(Replace Neighborhood, RNr)策略

在RNr策略中, 计算最新观测到的数据与初始字典 Ψ 中所有原子的欧氏距离, 找到与其最邻近的原子, 并进行替换, 新字典的容量不变。相应的 $\Phi \in \mathbf{R}^{1 \times N_1}$ 也进行更新。

3) 保持邻近原子(Keep Recent, KR)策略

在KR策略中, 初始字典 $\Psi \in \mathbf{R}^{m \times N_0}$ 。将最新观测到的数据加入初始字典中, 计算该数据与初始字典中的每个原子的欧氏距离, 只保留初始字典中与其最邻近的 K 个原子。

3 预测应用实例

本节的应用实例中, 为实现式(15)的预测模型,

稀疏权值向量 α 的计算将分别使用式(8)~式(13)所对应的不同目标函数, 调用CVX优化软件进行求解。基于式(8)~式(10)的不同稀疏编码求解方法分别简记为Basic sparse-1/2/3, 如式(10)所对应的稀疏编码求解记为Basic sparse-3方法。同理, 基于式(11)~式(13)的稀疏编码求解方法简记为EN-sparse-1/2/3。相应的稀疏编码在线预测方法则以不同的字典更新策略加以区分, 如应用RO策略, 且基于式(13)优化求解的稀疏编码方法简记为EN-sparse-3(RO)。

实验数据均进行如下归一化处理, 即

$$\mathbf{x}_n(t) = \frac{\mathbf{x}(t)}{\text{var}(\mathbf{x}(t))}$$

式中, $\text{var}(\cdot)$ 为方差函数。评价指标采用平均稀疏度 (Mean Sparsity)^[8]、均方根误差(RMSE)、平均绝对百分比误差(MAPE)或平均绝对值误差(MAE)^[20]。平均稀疏度主要度量稀疏编码求解的稀疏化程度大小。

实验对比的SVM方法, 其高斯核函数形式为

$$k(\mathbf{x}_i, \mathbf{x}_j) = \exp\left\{-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{2\sigma^2}\right\}$$

式中, σ 表示核函数宽度, 可通过交叉验证方法选出合适的惩罚参数 C 和 σ 。

由预测的风速, 经风电机组的“风速-风功”特性曲线可获得相应的风电功率, 转换关系如式(16)所示^[7]。

$$\hat{p}(\hat{v}) = \begin{cases} 0, & \hat{v} < v_{\text{cut-in}} \\ C(\hat{v}), & v_{\text{cut-in}} \leq \hat{v} \leq v_{\text{norm}} \\ p_{\text{norm}}, & v_{\text{norm}} \leq \hat{v} \leq v_{\text{cut-out}} \\ 0, & \hat{v} > v_{\text{cut-out}} \end{cases} \quad (16)$$

式中: \hat{v} 为预测风速; $v_{\text{cut-in}}$ 为“切入”风速; v_{norm} 为“额定”风速; $v_{\text{cut-out}}$ 为“切出”风速; $C(\cdot)$ 是由“风速-风功”特性曲线获得的函数; p_{norm} 为额定功率。

结合历史风速与风电功率数据, 可获得与式(16)等价的“风速-风功”特性曲线, 步骤如下:

Step 1: 将风速区间 $[v_{\text{cut-in}}, v_{\text{norm}}]$ 等间隔分割, 每个间隔为 0.2 m/s, 计算第 i 个区间中相应的风电功率均值 μ_p 及标准差 σ_p , 舍弃 $[\mu_p - \sigma_p, \mu_p + \sigma_p]$ 之外的数据点。

Step 2: 抛弃每个区间的散点, 所对应的风电功率在整个范围内被均分为10个区间, 计算功率出现的频数 $F(i, j)$ (第 j 个功率区间的样本数), 并将其归一化, 即 $\rho(i, j) = F(i, j) / \sum_{j=1}^{10} F(i, j)$, 并按降序排列。

Step 3: 设定阈值 ρ_T , 选择符合条件的前 k 个区间, 满足条件 $\sum_{j=1}^k \rho(i, j) \geq \rho_T$, 则第 i 个风速区间内的风电功率为

$$p(i) = \sum_{j=1}^k \rho(i, j) \rho(i, j) \quad (17)$$

式中, $\rho(i, j)$ 为第 i 个风速区间中第 j 个功率子区间内的平均功率值。

因此, 通过“滑窗”法依次获得整个风速区间上的等效的“风速-风功”曲线。

3.1 Santa Fe 混沌时间序列预测

Santa Fe混沌时间序列^[21]是一个远红外NH3激光器产生的混沌震荡的强度波形, 如图1所示。与文献[8]一致, 模型的嵌入维 m 取4, 以该时间序列的前900个训练输入数据向量作为字典 Ψ , 后续的100个数据作为测试进行单步预测。参数设置 $\lambda_1=0.8$, $\lambda_2=0.01$, $\varepsilon=1e-4$, $\delta=1$, $\xi=0.8$ 。SVM的参数为 $C=16$, $\sigma=4$ 。

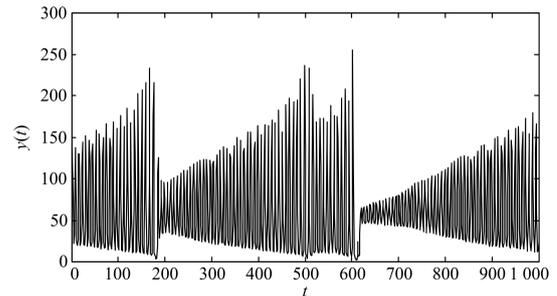


图1 远红外 NH3 激光器产生的 Santa Fe 混沌时间序列
Fig. 1 Santa Fe chaotic time series generated by NH3 (FIR) laser

表1给出了不同稀疏编码方法及SVM方法进行单步预测的数值结果。由表1可知, 不同稀疏编码方法, 其预测精度均优于SVM方法, 其中EN-sparse方法在平均稀疏度基本不变, 即保持了解的稀疏性的同时, 取得了最好的预测精度。表1还给出了不同稀疏方法求解的运行耗时比较, 可以看出EN-sparse-1/2方法的计算效率最高。图2进一步给出了应用EN-sparse-2方法的预测效果图, 从图2看出, EN-sparse方法的预测效果很好。实验分析还表明, EN-sparse-1/2方法具有很好的参数鲁棒性, 且求解的平均稀疏度和精度均较高。

表1 不同方法的预测结果对比

Table 1 Comparison of prediction results of different methods

预测方法	MAPE	RMSE	Mean Sparsity	t/s
SVM	27.067	15.448	0%	-
Basic sparse-1	7.224 8	8.995 4	99.56%	0.62
Basic sparse-2	7.273 8	9.565 4	98.33%	0.65
Basic sparse-3	7.355 5	9.004 6	99.48%	0.76
EN-sparse-1	6.143 0	8.111 0	97.11%	0.38
EN-sparse-2	6.117 7	8.124 8	97.11%	0.37
EN-sparse-3	6.358 3	8.115 2	79.11%	0.42

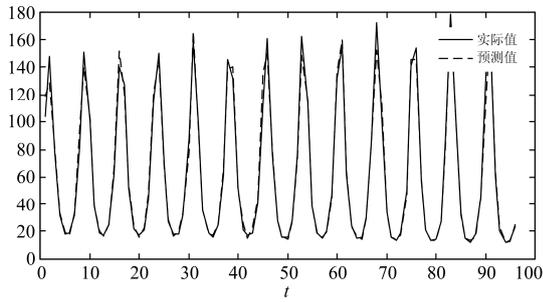


图2 Santa Fe 混沌时间序列的实际输出(实线)与 EN-sparse-1 方法的单步预测输出(虚线)比较

Fig. 2 Actual output (solid line) and the prediction value (dotted line) for the Santa Fe chaotic time series using EN-sparse-1 method

3.2 短期风电功率间接预测实例

应用实例采用美国国家可再生能源实验室(NREL)所提供的Western数据集^[22], 该数据通过10 min的时间间隔, 2 km的空间间隔进行采样, 应用SCORE统计相关技术, 可获取每个网格点的距地面约100 m高度的10个风机的风电功率输出。

实验选取丹佛市以西10英里位置的680台Vestas v90 3-M型号的风机, 数据为同一时间的68个网格点所提供的风速与风电功率各自的平均值。将连续2个数据进行平均作为新数据, 即预处理后的数据采样间隔为20 min。测试数据集包含从2004年12月1日到12月7日的风速值, 取12月1日之前的14天所包含的历史风速数据为训练数据集。

与文献[6]一致, 由历史的风速、风电功率数据进行计算, 置 $v_{cut-in} = 2.6 \text{ m/s}$, $v_{cut-out} = 33.1 \text{ m/s}$, $v_{norm} = 20.4 \text{ m/s}$, 按照等价的“风速-风功”特性曲线转换过程, 将整个风速区间上的风电功率通过“滑窗”法依次处理, 获得最终的“风速-风功”特性等效曲线, 如图3所示, 其中黑色实线部分表示由实测数据拟合出的风速-风电功率特性。

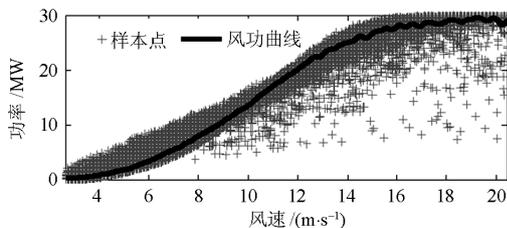


图3 风电机组的风功特性曲线及风功散点图

Fig. 3 Wind power curve and wind speed scatterplot for wind turbine generator

给定嵌入维 $m=6$, 应用不同稀疏编码方法分别构建提前1/2/3小时的风速预测模型, 并结合风速-

风电功率的拟合曲线, 如图3的粗实线所示, 以实现风电功率的间接预测。具体预测过程中, 可实现在线自适应预测, 在每预测72个采样点, 即一天的风速变化基础上, 结合已获取的实际风速值, 再次计算及更新风速-风功特性的等效转换曲线, 进行不间断持续在线自适应更新的预测。

实验中, 通过交叉验证法, 不同稀疏编码方法的参数设置为 $\varepsilon=1e-4$, $\delta=1$, $\xi=0.5$, $K=900$, 不同预测步长下 λ_1 和 λ_2 及SVM的参数设置由表2给出, 此时可取得较优的实验结果。

表2 不同预测步长下的参数选择

Table 2 Parameter selection of different prediction steps

参数	$h=3$	$h=6$	$h=9$
λ_1	0.3	0.8	0.8
λ_2	0.8	0.01	0.01
C	64	32	32
σ	1.5	1.5	1.3

表3—表5分别列出了三种不同预测步长下, 10种具有代表性的稀疏编码方法与SVM、wavelet-SVM方法^[6]的数值对比结果。由表3—表5可看出, 在保持一定平均稀疏度的情况下, 针对不同预测步长的短期风电功率预测, 未加入字典在线更新策略时, EN-sparse方法的MAE和RMSE值均最低, 当加入不同字典在线更新策略后, 所有稀疏编码方法的在线预测精度在原有程度上均有所提升, 且平均稀疏度不变。在平均稀疏度维持在约70%以上时, EN-sparse-1(RO)、EN-sparse-1(RNr)方法进行提前1 h($h=3$)预测的在线预测精度最高, EN-sparse-1(RNr)方法提前2 h($h=6$)预测的在线预测精度最高, EN-sparse-1(RNr)、EN-sparse-1(KR)方法提前3 h($h=9$)预测时的在线预测精度最高。

表3 提前1 h 预测时不同方法的结果对比

Table 3 Comparison of prediction results of different sparse code methods and other methods for 1-hour ahead prediction

预测方法	MAE	RMSE	Mean Sparsity	t/s
SVM	1.505 4	2.527 0	0%	—
Basic sparse-1	1.738 9	2.961 8	99.54%	2.16
Basic sparse-2	1.961 3	3.105 2	99.49%	2.11
EN-sparse-1	1.124 4	2.207 5	72.12%	0.91
EN-sparse-2	1.180 3	2.323 9	82.42%	0.86
Basic sparse-1(RO)	1.732	2.932 3	99.54%	2.17
Basic sparse-2(KR)	1.734 5	3.037 3	99.48%	2.13
EN-sparse-1(RO)	1.047 5	1.736 3	68.15%	0.95
EN-sparse-1(RNr)	1.046 0	1.754 4	68.84%	0.96
EN-sparse-2(RO)	1.084 5	1.824 0	76.29%	0.88
EN-sparse-2(RNr)	1.085 5	1.834 9	76.60%	0.87
Wavelet-SVM ^[6]	1.122 1	—	—	—

表4 提前2 h 预测时不同方法的结果对比

Table 4 Comparison of prediction results of different sparse code methods and other methods for 2-hour ahead prediction

预测方法	MAE	RMSE	Mean Sparsity	t/s
SVM	2.252 9	3.784 8	0%	—
Basic sparse-1	2.429 6	4.051 2	99.40%	2.25
Basic sparse-2	2.506 2	4.070 9	98.88%	2.12
EN-sparse-1	2.166 7	3.505 7	91.27%	0.97
EN-sparse-2	2.137 8	3.501 2	93.12%	0.96
Basic sparse-1(RNr)	2.282 2	3.854 7	99.37%	2.27
Basic sparse-2(RNr)	2.359 3	3.864 3	98.80%	2.15
EN-sparse-1(RNr)	1.963 4	3.247 3	91.20%	0.98
EN-sparse-1(KR)	2.050 3	3.573 9	91.27%	0.97
EN-sparse-2(RNr)	2.072 3	3.404 2	97.06%	0.97
EN-sparse-2(KR)	2.069 4	3.761 0	92.97%	0.93
Wavelet-SVM ^[6]	2.313 9	—	—	—

表5 提前3 小时预测时不同方法的结果对比

Table 5 Comparison of prediction results of different sparse code methods and other methods for 3-hour ahead prediction

预测方法	MAE	RMSE	Mean Sparsity	t/s
SVM	3.647 5	6.250 2	0%	—
Basic sparse-1	3.571 1	5.779 0	98.84%	2.38
Basic sparse-2	3.302 8	5.544 6	75.29%	2.29
EN-sparse-1	3.180 7	5.070 2	91.27%	0.96
EN-sparse-2	3.217 1	5.198 7	84.40%	0.95
Basic sparse-1(RNr)	3.496 6	5.786 3	99.07%	2.39
Basic sparse-2(KR)	3.191 4	5.533 9	70.81%	2.27
EN-sparse-1(RNr)	3.104 1	5.069 5	91.19%	0.99
EN-sparse-1(KR)	3.070 8	5.086 3	91.27%	0.95
EN-sparse-2(RNr)	3.273 0	5.305 3	84.32%	0.96
EN-sparse-2(KR)	3.133 5	5.160 2	84.32%	0.94
Wavelet-SVM ^[6]	3.228 3	—	—	—

表3—表5还分别给出了在不同预测步长下, 不同稀疏方法求解的运行耗时比较, 可以看出EN-sparse-1/2方法以及结合不同在线更新策略的在线预测方法均具有相近的耗时, 运算效率较高, 且明显优于Basic sparse-1/2方法, 满足在线预测的实际需求。图4—图6则给出了EN-sparse-1(RNr)方法分别进行提前1/2/3小时预测时的预测效果图, 具体包括预测值与真实值的对比、各点的绝对误差及误差分布直方图三个子图, 误差分布直方图的横轴为: $(\text{真实值} - \text{预测值}) / p_{\text{norm}} \times 100\%$ 。从图4—图6可清

晰地看出, EN-sparse-1(RNr)方法的预测效果非常好, 均优于文献[6]中的Wavelet-SVM方法。图7进一步给出了基于EN-sparse-1(KR)方法提前3 h预测时, 且取不同K值的NMSE值随测试数据更新的收敛曲线。图8给出了EN-sparse-1(RO/RNr/KR)三种方法提前3 h预测时的NMSE值随测试数据更新的收敛曲线。由图7—图8可看出, 基于EN-sparse-1方法进行在线预测时, 能取得较高的预测精度, 且方法的鲁棒性好, 不同字典更新策略的预测效果相当。

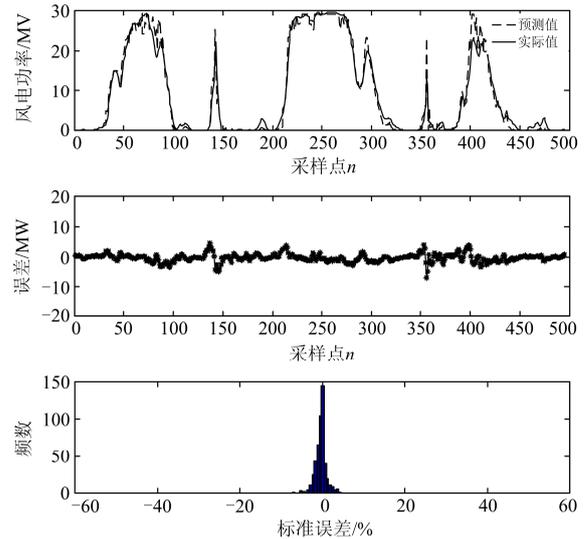


图4 EN-sparse-1(RNr)方法的预测结果(提前1 h 预测)

Fig. 4 Comparison of prediction results using EN-sparse-1(RNr) method for 1-hour ahead prediction

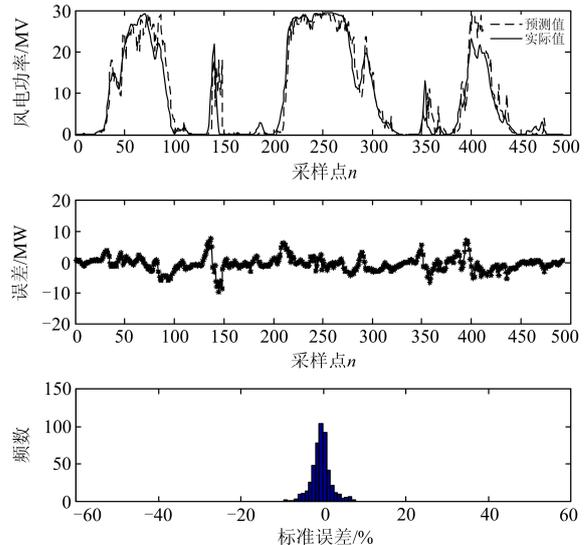


图5 EN-sparse-1(RNr)方法的预测结果(提前2 h 预测)

Fig. 5 Comparison of prediction results using EN-sparse-1(RNr) method for 2-hour ahead prediction

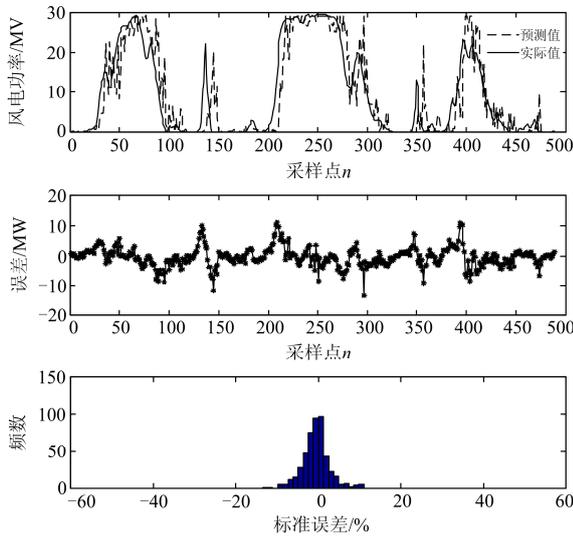


图 6 EN-sparse-1(RNr)方法的预测结果(提前 3 h 预测)

Fig. 6 Comparison of prediction results using EN-sparse-1(RNr) method for 3-hour ahead prediction

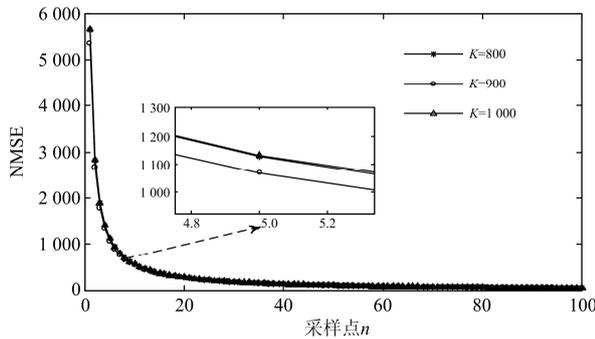


图 7 EN-sparse-1(KR)方法在取不同 K 值时的 NMSE 变化曲线(提前 3 h 预测)

Fig. 7 Comparison of NMSE convergence curves for EN-sparse-1(KR) methods under different K value when test data changes for 3-hour ahead prediction

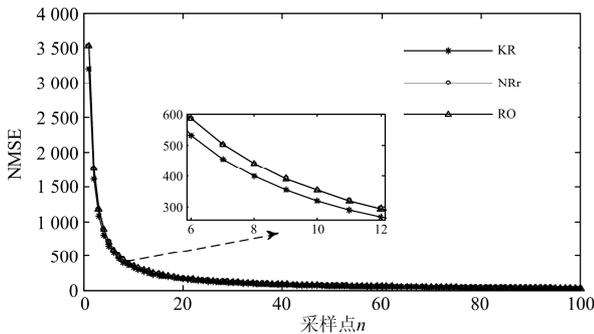


图 8 不同字典在线更新策略的 EN-sparse-1 方法的 NMSE 变化曲线(提前 3 h 预测)

Fig. 8 Comparison of NMSE convergence curves for EN-sparse-1 methods using different dictionary update strategies for 3-hour ahead prediction

4 结论

针对风电功率短期预测, 提出一种基于字典的稀疏编码预测方法, 通过实验实例检验了所提出方法的预测结果, 结论如下:

1) 不同Basic sparse方法均表现出与SVM相当的预测结果。在保持一定平均稀疏度的前提下, EN-sparse方法的预测效果均优于上述方法, 稀疏编码方法若增加在线字典更新策略后, 预测精度均在原有基础上有一定提升, 显示出更好的预测效果。

2) 本文算法无需模型的训练阶段, 针对测试数据的求解涉及稀疏编码的优化运算, 可调参数少, 避免了SVM方法选择核函数及最优“超参数”的困难。由于将稀疏权值的求解转换为凸优化问题, 预测模型输出的计算仅涉及内积运算, 计算效率高。

3) 本文的方法可用于短期风电功率在线自适应预测中, 具有一定的应用潜力, 进一步的研究包括考虑字典学习算法与稀疏编码结合的预测方法。

参考文献

- [1] 钱政, 裴岩, 曹利宵, 等. 风电功率预测方法综述[J]. 高电压技术, 2016, 42(4): 1047-1060.
QIAN Zheng, PEI Yan, CAO Liyou, et al. Review of wind power forecasting method[J]. High Voltage Engineering, 2016, 42(4): 1047-1060.
- [2] 薛禹胜, 郁琛, 赵俊华. 关于短期及超短期风电功率预测的评述[J]. 电力系统自动化, 2015, 39(6): 141-151.
XUE Yusheng, YU Chen, ZHAO Junhua. A review on short-term and ultra-short-term wind power prediction[J]. Automation of Electric Power Systems, 2015, 39(6): 141-151.
- [3] 李军, 李大超. 基于优化核极限学习机的风电功率时间序列预测[J]. 物理学报, 2016, 65(13): 130501-130501.
LI Jun, LI Dachao. Wind power time series prediction using optimized kernel extreme learning machine method[J]. Acta Physica Sinica, 2016, 65(13): 130501-130501.
- [4] 张颖超, 王雅晨, 邓华, 等. 基于IAFSA-BPNN的短期风电功率预测[J]. 电力系统保护与控制, 2017, 45(7): 58-63.
ZHANG Yingchao, WANG Yachen, DENG Hua, et al. IAFSA-BPNN for wind power probabilistic forecasting[J]. Power System Protection and Control, 2017, 45(7): 58-63.
- [5] 李燕青, 袁燕舞, 郭通. 基于AMD-ICSA-SVM的超短期风电功率组合预测[J]. 电力系统保护与控制, 2017, 45(14): 113-120.

- LI Yanqing, YUAN Yanwu, GUO Tong. Combination ultra-short-term prediction of wind power based on AMD-ICSA-SVM[J]. Power System Protection and Control, 2017, 45(14): 113-120.
- [6] ZENG J W, QIAO W. Short-term wind power prediction using a wavelet support vector machine[J]. IEEE Transaction on Sustainable Energy, 2012, 2(3): 255-264.
- [7] ELAD M, FIGUEIREDO M A T, MA Y. On the role of sparse and redundant representations in image processing[J]. Proceedings of the IEEE, 2010, 98(6): 972-982.
- [8] FAKHR M W. Sparse locally linear and neighbor embedding for nonlinear time series prediction[C] // 2015 Tenth International Conference on Computer Engineering & Systems (ICCES), December 23-24, 2015, Cairo, Egypt: 371-377.
- [9] FAKHR M W. Online nonstationary time series prediction using sparse coding with dictionary update[C] // 2015 International Conference on Information and Communication Technology Research (ICTRC), May 17-19, 2015, Abu Dhabi, United Arab Emirates: 112-115.
- [10] YU C N, MIROWSKI P, HO T K. A sparse coding approach to household electricity demand forecasting in smart grids[J]. IEEE Transactions on Smart Grid, 2017, 8(2): 738-748.
- [11] FORERO P A, RAJAWAT K, GIANNAKIS G B. Prediction of partially observed dynamical processes over networks via dictionary learning[J]. IEEE Transactions on Signal Processing, 2014, 62(13): 3305-3320.
- [12] HUI Z, TREVOR H. Regularization and variable selection via the elastic net[J]. Journal of the Royal Statistical Society, 2005, 67(2): 301-320.
- [13] FIGUEIREDO M A T. Adaptive sparseness for supervised learning[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2003, 25(9): 1150-1159.
- [14] TIBSHIRANI R. Regression shrinkage and selection via the lasso[J]. Journal of the Royal Statistical Society. Series B (Methodological), 1996, 58(1): 267-288.
- [15] CHEN S S, DONOHO D L, SAUNDERS M A. Atomic decomposition by basis pursuit[J]. SIAM review, 2001, 43(1): 129-159.
- [16] BECKER S, BOBIN J, CANDÈS E J. NESTA: a fast and accurate first-order method for sparse recovery[J]. SIAM Journal on Imaging Sciences, 2011, 4(1): 1-39.
- [17] JOHNSON R A, WICHERN D W. Applied multivariate statistical analysis[M]. Upper Saddle River, NJ: Prentice Hall, 2002.
- [18] EFRON B, HASTIE T, JOHNSTONE I, et al. Least angle regression[J]. The Annals of statistics, 2004, 32(2): 407-499.
- [19] GRANT M, BOYD S. CVX: Matlab software for disciplined convex programming[EB/OL]. [2016-04-01]. <http://cvxr.com/cvx>.
- [20] 杨茂, 刘红柳, 季本明. 基于混沌理论的风电功率超短期多步预测的误差分析[J]. 电力系统保护与控制, 2017, 45(4): 50-55.
- YANG Mao, LIU Hongliu, JI Benming. Analysis of ultra-short-term prediction error of wind power based on chaos theory[J]. Power System Protection and Control, 2017, 45(4): 50-55.
- [21] WEIGEND A S, GERSHENFELD N A. Time series prediction: forecasting the future and understanding the past[M]. Harlow, UK: Addison Wesley, 1994.
- [22] POTTER C, LEW D, MCCA A J, et al. Creating the dataset for the western wind and solar integration study (USA)[J]. Wind Engineering, 2008, 32(4): 325-338.

收稿日期: 2017-05-22; 修回日期: 2017-07-15

作者简介:

李 军(1969—), 男, 通信作者, 博士, 教授, 研究方向为计算智能与复杂非线性系统预测、控制; E-mail: lijun691201@mail.lzjtu.cn

於 阳(1991—), 男, 硕士研究生, 研究方向为风电功率预测与控制工程。E-mail: yy_sunshine7@163.com

(编辑 张爱琴)