

DOI: 10.7667/PSPC171898

基于奇异谱分析的短期电价预测

殷豪, 曾云, 孟安波, 刘哲

(广东工业大学, 广东 广州 510006)

摘要: 针对电价序列具有非线性和非平稳性的特点, 提出了一种基于奇异谱分析(SSA)和改进布谷鸟算法(ICS)优化极限学习机(ELM)的短期电价预测模型。采用奇异谱分析提取电价序列中的趋势成分和振荡成分, 进行准周期信号分量重建, 并对重建序列进行 ELM 建模预测。针对 ELM 预测模型中的参数易陷入局部最优的问题, 为了提高预测精度, 提出改进布谷鸟算法优化预测模型的参数。最后将所有预测序列进行叠加, 得到最终的电价预测值。以澳大利亚某电力市场电价数据为例进行分析, 通过与其他几种预测模型相比, 表明 SSA-ICS-ELM 模型能有效提高电价预测的精度和稳定性。

关键词: 奇异谱分析; 改进布谷鸟算法; 极限学习机; SSA-ICS-ELM 模型; 电价预测

Short-term electricity price forecasting based on singular spectrum analysis

YIN Hao, ZENG Yun, MENG Anbo, LIU Zhe

(Guangdong University of Technology, Guangzhou 510006, China)

Abstract: In view of the nonlinear and non-stationary characteristics of electricity price time series, the novel model for electricity price forecasting in this paper is proposed by the combination of Singular Spectrum Analysis (SSA) and Extreme Learning Machine (ELM) optimized by the Improved Cuckoo Search algorithm (ICS). SSA is used to extract the trend components and oscillation components of the original data and reconstruct all the components, and the ELM model is used to predict the reconstruction sequences. Against the parameters that in the ELM prediction model tend to fall into the local optimum, the ICS algorithm is introduced to optimize the model parameters to further improve the predictive value. Finally, all the predicted sequences are summed up to get the final forecast of electricity price. The empirical results demonstrate that the SSA-ICS-ELM model can improve the prediction accuracy and stability of electricity price forecasting considerably in comparison with other methods by analyzing the price data in Australia electricity market.

This work is supported by Science and Technology Project of Guangdong Province (No. 2016A010104016) and Science and Technology Project of Guangdong Power Grid Company (No. GDKJQQ20152066).

Key words: SSA; ICS algorithm; ELM; SSA-ICS-ELM model; electricity price forecasting

0 引言

与传统能源相比, 电力作为绿色能源, 更符合环境友好型社会的要求。现如今在放松管制和竞争激烈的市场环境下, 所有电力市场参与者的决策高度依赖于电价, 使得电价预测模型成为能源市场研究的基石之一^[1-2]。同时, 由于电力需求和天气、商业强度、日常活动等因素紧密相连^[3], 使得电价有着非线性和非稳定性的特点。

在过去几十年里, 时间序列法常用于电价预测^[4], 其大致分为: 统计模型^[5]、混合模型^[6]、人工智能模型。随着人工智能法在预测领域越来越受欢迎, 现已有大量人工智能法用于预测领域, 如人工神经网络^[7]、极限学习机 (Extreme Learning Machine, ELM)^[8]、支持向量机^[9]等。本文选取 ELM 作为预测模型, 然而, 单一的预测模型由于参数选择问题, 往往不能进行准确的预测, 而优化后的预测模型对参数的全局搜索能力克服了人为选择的局限性, 能很大程度提高预测精度。因此, 大量的优化算法被广泛应用, 如粒子群算法(Particle Swarm Optimization, PSO)^[10]、遗传算法^[11]、布谷鸟算法(Cuckoo Search,

基金项目: 广东省科技计划项目资助 (2016A010104016); 广东电网公司科技项目资助 (GDKJQQ20152066)

CS)^[12]等。

另外, 由于原始数据的固有特性, 如上所述, 电价数据受到很多干扰因素的影响, 导致滤波处理技术也成为数据预处理的一个重要阶段。奇异谱分析(Singular Spectrum Analysis, SSA)^[13]是一种强大的降噪技术, 现已应用到负荷预测、水文预测等领域。文献[14]实验结果显示 SSA 对去除噪声信号效果优于经验模态分解和小波分解。

基于上述问题的考虑, 本文提出一种基于 SSA 和改进布谷鸟算法(Improved Cuckoo Search, ICS)优化 ELM 的电价预测模型。针对电价序列波动大的特点, 首先采用 SSA 信号处理技术对原始电价数据进行分解和重构, 并分离出原始电价的趋势、振荡和噪声成分。为了减少噪声信号对预测结果产生负面影响, 最后采用 ICS-ELM 模型对降噪的电价数据进行预测, 本文对 CS 算法进行改进, 以提高预测精度。针对电价具有季节性的特点, 本文采用同一电力市场不同季节的电价数据进行仿真, 结果表明 SSA-ICS-ELM 模型都能得到较高的预测精度。

1 奇异谱分析

SSA 是一种结合多变量统计和概率理论的非参数方法, 经常用于时间序列分析, 从原始数据中识别和提取趋势、周期振荡成分和噪声。SSA 包含很多因素, 如典型时间序列、多元统计、多元几何和奇异值分解(Singular Value Decomposition, SVD)^[15]。其具体步骤如下。

1) 嵌入。假设时间序列 $\mathbf{Y} = (y_1, y_2, \dots, y_N)$ 有 N 个样本点, SSA 分析中嵌入的维度由 L (窗口长度)表示: $\mathbf{X}_i = (y_i, y_{i+1}, \dots, y_{i+L-1})$ 。SSA 由 2 个互补阶段组成, 分别是分组和重构。由 K 个向量 $\mathbf{X}_i (i=1, 2, \dots, K=N-L+1)$ 组成的轨迹矩阵可以表示为

$$\mathbf{X} = \begin{bmatrix} y_1 & y_2 & \cdots & y_K \\ y_2 & y_3 & \cdots & y_{K+1} \\ \vdots & \vdots & & \vdots \\ y_L & y_{L+1} & \cdots & y_N \end{bmatrix} \quad (1)$$

2) 奇异值分解。考虑到协方差 $\mathbf{S} = \mathbf{X}\mathbf{X}^T$, 对 \mathbf{S} 的奇异值分解就是产生一组 L 个特征值 $\lambda (\lambda_1, \lambda_2, \dots, \lambda_L)$ 以及对应特征值的特征向量 $\mathbf{U}_1, \mathbf{U}_2, \dots, \mathbf{U}_L$ 。令 $d = \max\{i\}(\lambda_i > 0)$, $\mathbf{V}_i = \mathbf{X}^T \mathbf{U}_i \sqrt{\lambda_i}$ ($i=1, 2, \dots, d$), 则对 \mathbf{X} 进行奇异值分解可表示为

$$\mathbf{X} = \mathbf{E}_1 + \mathbf{E}_2 + \cdots + \mathbf{E}_d \quad (2)$$

式中, $\mathbf{E}_i = \sqrt{\lambda_i} \mathbf{U}_i \mathbf{V}_i^T$ 为基本矩阵, 矢量 $\mathbf{V}_1, \mathbf{V}_2, \dots, \mathbf{V}_d$ 为

主成分(Principle Components, PC), 集合 $(\sqrt{\lambda_i}, \mathbf{U}_i, \mathbf{V}_i)$ 为 \mathbf{X} 进行 SVD 后的第 i 个特征三元组。

3) 分组。进行步骤 2) 后, 考虑将集合 $J=(1, \dots, d)$ 分成 m 个不相交的组 I_1, I_2, \dots, I_m 。将 $I=(i_1, i_2, \dots, i_p)$ 表示为一组指数。然后, 对应于组成 I 的合成矩阵可以定义为 $\mathbf{X}_I = \mathbf{X}_{i_1} + \mathbf{X}_{i_2} + \cdots + \mathbf{X}_{i_p}$, 这个过程完成了矩阵 \mathbf{X} 接下来的分解。

$$\mathbf{X} = \mathbf{X}_{I_1} + \mathbf{X}_{I_2} + \cdots + \mathbf{X}_{I_m} \quad (3)$$

对于给定的 I_i , \mathbf{X}_i 的贡献率可以通过分解后特征值所占的比例来计算。在本文中, 从 d 个奇异值中选择奇异值个数用 r 表示, 最后 r 成为重组的个数。

4) 对角平均。通过对角平均, 每个矩阵可以依照下面步骤转换到时间序列中。假设 \mathbf{Z} 是一个 $L \times K$ 大小的矩阵, 矩阵里的数为 z_{ij} , 其中 $1 \leq i \leq L$, $1 \leq j \leq K$ 。设 $L^* = \min(L, K)$, $K^* = \max(L, K)$, $N = K + L - 1$, 若 $L < K$, 令 $z_{ij}^* = z_{ij}$, 否则 $z_{ij}^* = z_{ji}$, 则重构时间序列 $\mathbf{Z} = \{z_1, z_2, \dots, z_N\}$, 如式(4)所示。

$$y_k = \begin{cases} \frac{1}{k} \sum_{q=1}^{k+1} z_{q, k-q+1}^* & 1 \leq k \leq L^* \\ \frac{1}{L^*} \sum_{q=1}^{L^*} z_{q, k-q+1}^* & L^* < k \leq K^* \\ \frac{1}{N-K+1} \sum_{q=k-K^*+1}^{N-K^*+1} z_{q, k-q+1}^* & K^* < k \leq N \end{cases} \quad (4)$$

2 布谷鸟搜索算法

布谷鸟算法的核心思想是由布谷鸟繁殖方式和莱维飞行(Lévy Flight)原理结合产生。CS 算法一般通过本地搜索所设的发现概率 P_a 来进行更新, 从而具有较强的全局搜索能力^[16]。对于 CS 算法的核心思想, 可以做出以下三个假设:

1) 布谷鸟每次只产一个蛋代表一个解, 并在随机选择的鸟巢中产蛋。

2) 在所有随机选择的鸟巢中, 最好巢的蛋(最优解)将会保留给下一代。

3) 宿主发现布谷鸟蛋的概率是 $P_a (0 < P_a < 1)$ 。在这种情况下, 宿主会直接放弃这个蛋或鸟巢。

布谷鸟根据莱维飞行原理寻找新的鸟巢, 鸟巢数设为 n , 令 \mathbf{X}_i^t 是第 i 个布谷鸟目前的位置, 然后新的解 \mathbf{x}_i^{t+1} 如下式产生。

$$\mathbf{x}_i^{t+1} = \mathbf{x}_i^t + a \oplus L(\lambda) \quad i=1, 2, 3, \dots, n \quad (5)$$

$$\text{Lévy} \sim u = t^{-\lambda} \quad (6)$$

将所得新解与上一代的解进行比较, 若新解的位置优于上一代解的位置, 则 $x_i^{t+1} = x_i^t + a \oplus L(\lambda)$, 否则, $x_i^{t+1} = x_i^t$ 。其中 $a > 0$, a 表示优化问题的步长, 函数 $L(\lambda)$ 表示无限均值和方差的莱维飞行, Lévy 飞行基本上是随机产生一个步长, 且步长服从 $L(\lambda) \sim u^{-\lambda} (1 < \lambda \leq 3)$ 搜索路径。

3 改进的布谷鸟算法

通过 CS 算法获得的最优解, 在最优解周围, Lévy 步行能加快本地搜索的速度, 从而获得新的解。但是在后期, CS 算法难免会存在局部搜索能力不强, 陷入局部最优的问题, 局部最优一般是由于某维或某几维具有局部最优解形成的, 后期引入维竞争交叉机制, 使得本文提出改进布谷鸟算法在具有全局搜索能力基础上, 又摆脱了存在的小部分局部最优问题。

布谷鸟的蛋被发现的概率 P_a 是随机产生的, 先产生一个随机数 $r \in [0, 1]$ 。当 $r > P_a$ 时, 布谷鸟蛋被发现, 此时根据式(5)产生一个新解 x_{new} , 若优于上一代解 x_i^t , 则 $x_i^{t+1} = x_{new}$; 当 $r < P_a$, 则根据式(7)产生新个体保存在 MS_{vc} 中。

$$MS_{vc}(i, d_1) = r \cdot X(i, d_1) + (1-r) \cdot X(i, d_2) \quad (7)$$

$$i \in N(1, M), d_1, d_2 \in N(1, D), r \in [0, 1]$$

式中: MS_{vc} 为保存纵向交叉新个体的矩阵; D 表示所有的维数, 先将两维随机组合在一起, 共有 $D/2$ 个组合; $MS_{vc}(i, d_1)$ 为粒子 $X(i)$ 的第 d_1 维和第 d_2 维进行交叉得到的子代; 且 d_1, d_2 为随机产生的维。

4 极限学习机

极限学习机是一种新型的单隐层前馈神经网络算法, 随机生成所有输入权值和隐层节点偏置, 然后通过简单的广义逆运算计算出隐含层到输出层的输出权重^[17]。假设一组以 N 为样本的数, 如 (x_p, y_i) , 其中, $i=1, 2, \dots, n$, $[x_{i1}, x_{i2}, \dots, x_{im}] \in \mathbf{R}^m$ 和 $y_i = [y_{i1}, y_{i2}, \dots, y_{im}] \in \mathbf{R}^m$ 。具有 L 个隐层神经元的 ELM 输出可以表示为式(8), ELM 结构图如图 1 所示。

$$f_L = \sum_{i=1}^L \beta_i g(a_i \cdot x_i + b_i) = o_i \quad t=1, \dots, N \quad (8)$$

式中: $\mathbf{a}_i = [a_{i1}, a_{i2}, \dots, a_{im}]^T$ 为连接第 i 个隐层神经元和输入节点的权重向量; $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$ 为连接第 i 个隐层神经元和输出节点的权重向量; b_i 为

第 i 个隐含层神经元的偏置; g 为激活函数。式(8)可以简化为式(9)。

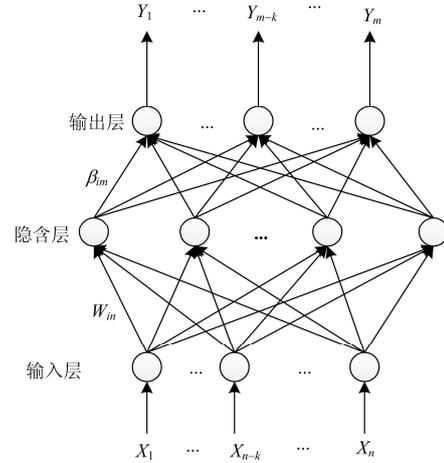


图 1 ELM 结构图

Fig. 1 Structure of the ELM

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{T} \quad (9)$$

$$\mathbf{H} = \begin{bmatrix} h(x_1) \\ \vdots \\ h(x_N) \end{bmatrix} = \begin{bmatrix} g(a_1 \cdot x_1 + b_1) & \cdots & g(a_l \cdot x_1 + b_l) \\ \vdots & \cdots & \vdots \\ g(a_1 \cdot x_N + b_1) & \cdots & g(a_l \cdot x_N + b_l) \end{bmatrix}_{N \times L} \quad (10)$$

$$\boldsymbol{\beta} = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_L^T \end{bmatrix}_{L \times m}, \quad \mathbf{T} = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix}_{N \times m} \quad (11)$$

式中: \mathbf{H} 为隐含层的输出矩阵; \mathbf{T} 为目标输出矩阵。ELM 随机选择输入权值和隐层的偏置, 一旦这些参数被随机确定, 隐含层的输出矩阵 \mathbf{H} 就保持不变, ELM 的训练过程就相当于寻找一个最小二乘解, 其解可表示为

$$\|\mathbf{H}\hat{\boldsymbol{\beta}} - \mathbf{T}\| = \|\mathbf{H}\mathbf{H}^+ \mathbf{T} - \mathbf{T}\| = \min \|\mathbf{H}\boldsymbol{\beta} - \mathbf{T}\| \quad (12)$$

其特解可以表示为

$$\hat{\boldsymbol{\beta}} = \mathbf{H}^+ \mathbf{T} \quad (13)$$

式中, \mathbf{H}^+ 为隐层输出矩阵的 \mathbf{H} 的摩尔-彭罗斯 (Moore-Penrose) 广义逆。

5 SSA-ICS-ELM 混合模型

5.1 SSA-ICS-ELM 混合模型

本文提出了 SSA 信号处理技术和 ELM 组成的混合预测模型。由于电价受很多非定性因素的影响, 导致了原始电价序列里不可避免地包含很多干扰信息。因此, SSA 技术最初运用于去除原始电价的噪

声, 并提取原始电价序列变化的主要特性。为了降低参数选择的随机性, 提高预测精度, 使用 ICS 优化 ELM 模型的输入层和隐含层之间的权值和隐层偏置, 本文所提混合模型的详细步骤如下。

步骤 1, SSA。采用 SSA 将原始电价序列分解为 r 个低频部分和 $L-r-1$ 个高频部分, 分别代表需要重构电价序列和过滤的噪声分量。

步骤 2, 数据分割。噪声消除后的电价序列分为训练序列和测试序列, 本文采用原始数据的前 85% 作为训练集, 15% 的数据作为测试集。

步骤 3, 初始化。初始化 ELM 的 2 个参数, 根据所规定的范围, 随机产生 n 个鸟巢 $\mathbf{X}_0 = (x_1^0, x_2^0, \dots, x_n^0)^T$, 每个鸟巢是一组 ELM 的参数。在 ICS 算法中, 本文设最大迭代次数 $T_{\max\text{gen}}$ 为 200、鸟巢数 n 为 30、鸟蛋被发现概率 P_a 为 0.25, 经过多次实验和参考文献[18], 当 P_a 设置为 0.25 时, 即为最优参数。

步骤 4, 优化。ICS 算法的目标函数为

$$\text{fit} = \frac{1}{N} \sum_{k=1}^N \sum_{t=1}^m (p_t - \hat{p}_t)^2 \quad (14)$$

式中: p_t 表示 ELM 的实际输出; \hat{p}_t 表示目标输出; N 表示训练样本数。a. 计算每个鸟巢的适应值, 获取并保留最优鸟巢的位置 X_{best} 。b. 按照 Lévy 飞行模式更新种群 $\mathbf{X}_t = (x_1^{(t)}, x_2^{(t)}, \dots, x_n^{(t)})^T$, 同时计算更新后鸟巢的适应值, 并与上一代的值进行比较, 保留更优解。c. 然后随机产生一个数 $r \in [0, 1]$, 若 $r > P_a$, 则按照 Lévy 飞行模式即式(5)更新种群, 否则按照式(7)更新种群, 并根据式(14)获得每个粒子的适应值, 若优于上一代, 则保留最优鸟巢位置, 当过程 b、c 达到所设定的迭代数 $T_{\max\text{gen}}$, 则算法终止, 否则重复步骤 b、c。

步骤 5, ELM 构建。ICS 算法获得的最佳解(最优鸟巢的位置)设为 ELM 的参数。以春季电价数据为例, 不同算法的最优收敛曲线如图 2 所示, 观察到 ICS 算法优化能力最强。

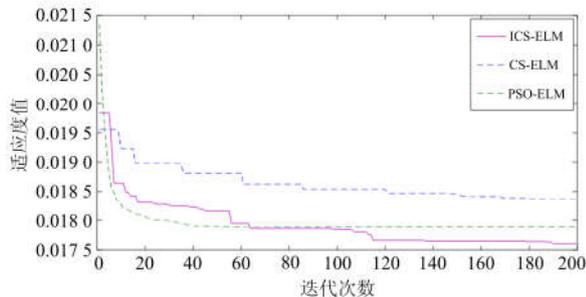


图 2 不同算法预测最优收敛曲线

Fig. 2 Prediction optimal convergence curves of different algorithms

步骤 6, 测试。采用 ICS-ELM 对所有序列进行预测, 最后叠加所有序列值, 即最终的预测值。

步骤 7, 评估。为了鉴定本文模型有效性, 采用了两种方法来评估预测效果, 如式(15)、式(16)分别是平均绝对误差(Mean Absolute Error, MAE)、平均绝对百分比误差(Mean Absolute Percentage Error, MAPE)的表达式。

$$\text{MAE} = \frac{1}{N} \sum_{t=1}^N |X(t) - \hat{X}(t)| \quad (15)$$

$$\text{MAPE} = \frac{1}{N} \sum_{t=1}^N \left| \frac{X(t) - \hat{X}(t)}{X(t)} \right| \times 100\% \quad (16)$$

5.2 数据预处理和分类

季节的不同会影响用户的用电量, 使得电价具有季节性。为了验证本文模型的有效性, 本文仿真数据来源于澳大利亚新南威尔士州的春、夏、秋、冬四季的实测电价数据, 分别选取 2016 年 4 月、7 月、9 月和 12 月的数据作为仿真数据, 进行提前半小时短期电价预测, 将前 600 个数据作为训练集, 第 601~700 个数据作为测试集。

由于电价序列里包含很多噪声序列, 故本文采用 SSA 对原始数据进行预处理。在 SSA 中有 2 个重要参数需要确定: 一个是窗口长度 L , 一般 L 不能大于 $2/N$, 如果原始序列中存在整数周期的周期性分量, 建议 L 取与该周期成正比的数^[19], 本文的采样周期即一天的采样点(48 个点), 经过多次实验, 本文将所有实验的 L 都设为 12; 另一个是参数 r , r 则是需要重构的部分, 一般是分解后计算每个序列的贡献率, 贡献率的总和至少为预定阈值, 例如 $> 80\%$ 。另外, 检测奇异谱中的断点也是区分趋势、谐波和噪声的重要信息, 纯噪声分量的特征值一般呈缓慢下降趋势^[20]。

以春季的数据为例进行分析, 图 3 是前 12 个特征值对应的奇异谱图。从奇异值变化趋势可以看出, 从第 9 个奇异值开始, 下降速度变慢, 且序列 1~9 的贡献率之和占原始序列 91.46%, 所以将 r 设为 9。同理, 通过分析奇异谱图, 将夏季、秋季、冬季的实验中的 r 分别设为 9、8、8。图 4 是 r 个序列重构部分, 序列 1 对应着趋势部分, 其中序列 (2, 3)、(4, 5)、(6, 7), (8, 9) 都是成对存在, 其贡献率大小和振荡频率相似, 则 2~9 序列对应着振荡部分, 并产生时间序列的主要谐波。图 5 是序列 10~12 叠加的部分, 仅占原始序列的 8.54% 比重, 对应着噪声序列。

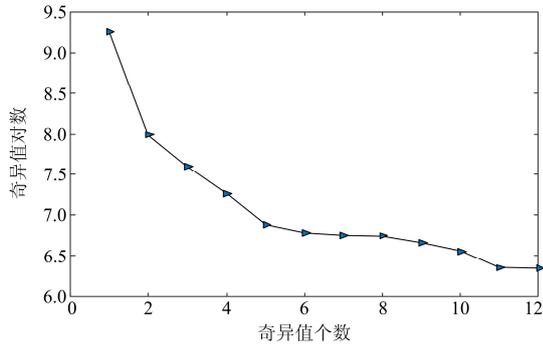


图 3 电价序列的奇异谱图

Fig. 3 Singular spectrum of electricity price time series

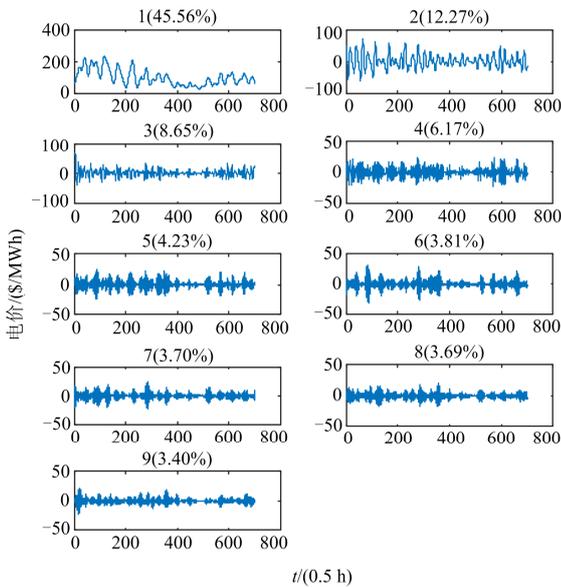


图 4 前 9 个序列的重构序列

Fig. 4 Reconstructed components corresponding to the first nine triples

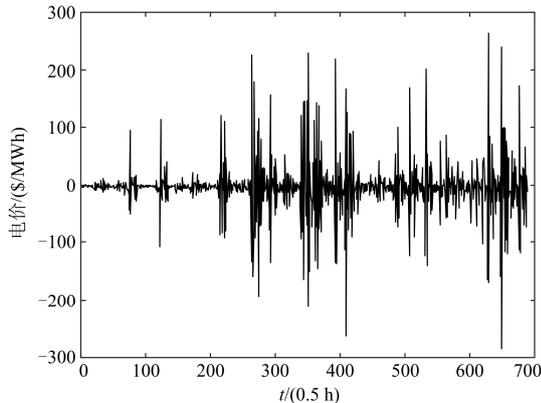


图 5 重构噪声序列

Fig. 5 Reconstructed components corresponding to the noisy time series

5.3 SSA-ICS-ELM 模型流程图

图 6 是本文模型的流程图, 其中 RC_1, \dots, RC_L 分别是子序列 1, \dots , 子序列 L 通过 SSA 重构的序列。

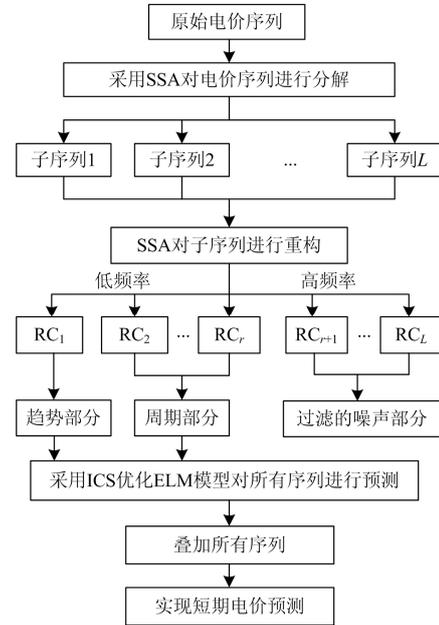


图 6 基于 SSA-ICS-ELM 的短期电价预测框图

Fig. 6 Short-term electricity price forecast flowchart of the SSA-ICS-ELM model

6 算例分析

本文所有训练仿真均在 Matlab R2016b 版本环境下进行, 所有模型中 ELM 隐含层节点个数设为 6 个, 隐含层函数为 Sigmoid, 且所有模型的迭代次数都设置相同。

本文实验由两部分组成, 实验 1: 为了验证 SSA-ICS-ELM 模型的有效性, 引入 ICS-ELM 模型、CS-ELM 模型和 ELM 模型进行对比。实验 2: 为了更全面评估本文模型的性能及适用性, 建立 EEMD-ICS-ELM(即对原始电价序列进行集合经验模式分解, 对分解后的各子序列建立 ICS 优化 ELM 模型)、VMD-ICS-ELM(即对原始电价进行变分模式分解, 再对分解后的各子序列建立 ICS 优化 ELM 模型)两种模型与本文模型进行比较, 其中, 经过对以上两种模型进行多次实验, 将 EEMD 的集合数为 300, 分解层数为 8, VMD 的分解层数设为 9。

实验 1 和实验 2 的各模型的评价指标分别如表 1 和表 2 所示, 图 7 是实验 1 中各模型的预测曲线图。如表 1 所示, 在四个季节中, SSA-ICS-ELM 模型的性能指标都处于最佳状态, 以春季不同模型的仿真结果为例: (1) SSA-ICS-ELM 模型较 ICS-ELM 模型的 MAPE 和 MAE 分别降低 85%和 87%, 原因

是 SSA 具有强大的去噪能力,降低了原始序列的复杂特性;(2) ICS-ELM 较 ELM 模型的 MAPE 和 MAE 减少了 6%和 8%, CS-ELM 较 ELM 模型的 MAPE 和 MAE 减少了 3%和 2%,显然 ICS-ELM 模型减少误差程度多于 CS-ELM 模型,原因是 ICS 算法优化能力强于 CS 算法;(3) 通过观察图 7 和表 1 可得,本文模型的波动范围最小,拟合效果最好,在四个季节中,秋季预测效果最好,春季稍微有所降低,可能是春季数据系列波动较大。

表 1 实验 1 中不同模型的预测误差

Table 1 Prediction error of different models in experiment one

季节	SSA-ICS-ELM		ICS-ELM	
	MAPE/%	MAE/%	MAPE/%	MAE/%
春	3.74	3.39	25.67	26.83
夏	3.56	2.98	24.59	24.04
秋	1.73	0.80	12.08	6.00
冬	2.37	1.67	17.27	11.64

季节	CS-ELM		ELM	
	MAPE/%	MAE/%	MAPE/%	MAE/%
春	26.92	28.94	27.38	29.41
夏	24.65	24.24	24.89	24.47
秋	12.62	6.27	12.80	6.37
冬	19.25	12.39	18.27	12.07

表 2 实验 2 中不同模型的预测误差

Table 2 Prediction error of different models in experiment two

季节	春	夏	秋	冬
	VMD-ICS-ELM			
MAPE%	8.95	9.07	6.37	5.24
MAE/%	8.75	7.12	2.84	3.07
EEMD-ICS-ELM				
MAPE%	9.31	10.11	6.78	5.89
MAE/%	9.09	8.62	3.06	3.32
SSA-ICS-ELM				
MAPE%	3.74	3.56	1.73	2.37
MAE/%	3.39	2.98	0.80	1.67

为了显示本文模型的优越性,从表 2 可以看出:在 3 种模型中,本文所提模型在四季中都表现出最高预测精度。以春季为例,SSA-ICS-ELM 模型较 VMD-ICS-ELM 模型的 MAPE 和 MAE 分别降低了 58%和 61%,较 EEMD-ICS-ELM 模型的 MAPE 和 MAE 分别降低 60%和 62%,原因是 SSA 的分解效果相对于 VMD 和 EEMD 更加优良,其次是 VMD。由各模型对比可知,本文所提 SSA-ICS-ELM 模型在所有实验中预测精度最高,且都优于本文涉及的其他模型,具有一定的适用价值。

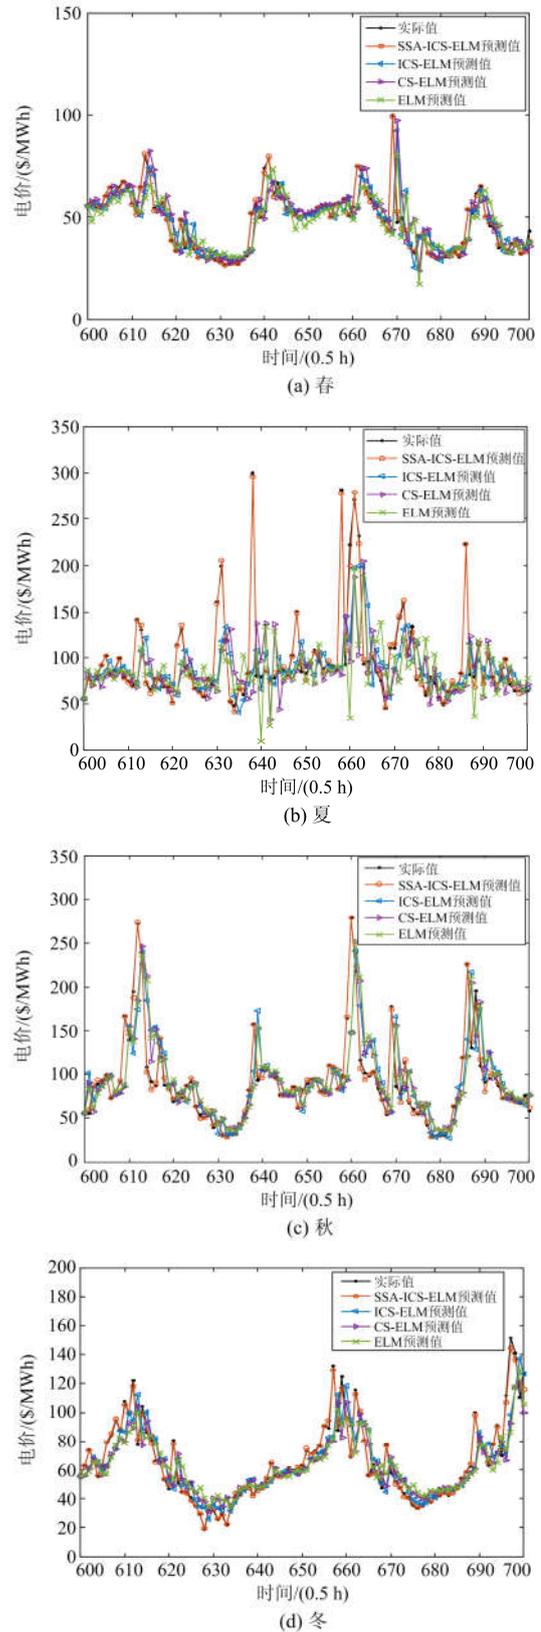


图 7 实验 1 中不同季节的预测曲线图
Fig. 7 Prediction curves of different seasons in experiment one

7 结论

由于单一的模型具有局限性, 本文采用奇异谱分析对电价序列进行分解, 为了解决布谷鸟算法优化参数时存在小部分局部最优问题, 提出了改进布谷鸟算法优化极限学习机的参数, 并建立 SSA-ICS-ELM 混合模型, 为电价预测提供一种有效且适用性强的方法。通过实验可得出以下结论:

- 1) 相比 EEMD 和 VMD, SSA 降噪效果更好, 可以较大程度提高电价预测精度。
- 2) ICS 算法比 CS 算法全局搜索能力更强, 收敛速度更快, 为 ELM 算法提供了一种新的优化方法。
- 3) 所提 SSA-ICS-ELM 混合模型与其他混合模型相比, 具有较强的预测能力, 且适用范围广, 预测值有利于电力系统和电力市场的正常运行。

参考文献

- [1] 白杨, 李昂, 夏清. 新形势下电力市场营销模式与新型电价体系[J]. 电力系统保护与控制, 2016, 44(5): 10-16.
BAI Yang, LI Ang, XIA Qing. Electricity business marketing modes in the new environment and new electricity pricing systems[J]. Power System Protection and Control, 2016, 44(5): 10-16.
- [2] 熊尚飞, 邹小燕. 电力市场价格风险价值与波动预测研究综述[J]. 电力系统保护与控制, 2014, 42(2): 146-153.
XIONG Shangfei, ZOU Xiaoyan. Value at risk and price volatility forecasting in electricity market: a literature review[J]. Power System Protection and Control, 2014, 42(2): 146-153.
- [3] 张显, 王锡凡. 分时段短期电价预测[J]. 中国电机工程学报, 2005, 25(15): 1-6.
ZHANG Xian, WANG Yifan. Review of the short-term electricity price[J]. Proceedings of the CSEE, 2005, 25(15): 1-6.
- [4] HE K, YU L, TANG L. Electricity price forecasting with a BED (Bivariate EMD Denoising) methodology[J]. Energy, 2015, 91: 601-609.
- [5] 刘丽燕, 邹小燕. GARCH 族模型在电力市场电价预测中的比较研究[J]. 电力系统保护与控制, 2016, 44(4): 57-63.
LIU Liyan, ZOU Xiaoyan. Comparison of GARCH models in electricity price forecasting[J]. Power System Protection and Control, 2016, 44(4): 57-63.
- [6] 陈思杰, 周浩. 电力市场电价预测方法综述[J]. 电力系统保护与控制, 2006, 34(11): 54-60.
CHEN Sijie, ZHOU Hao. Electricity price forecast method of electricity market[J]. Power System Protection and Control, 2006, 34(11): 54-60.
- [7] 张肖波, 李婧娇, 罗欣. 基于灰色关联分析与人工神经网络算法的节假日负荷预测研究[J]. 广东电力, 2012, 25(7): 38-42.
ZHANG Xiaobo, LI Jingjiao, LUO Xin. Research on load forecast on holidays based on grey relational analysis and artificial neural network algorithm[J]. Guangdong Electric Power, 2012, 25(7): 38-42.
- [8] 陈金楷, 夏季, 谭鹏, 等. 结合相空间重构和 ELM 的磨煤机振动软测量[J]. 热力发电, 2015, 44(3): 42-47.
CHEN Jinkai, XIA Ji, TAN Peng, et al. Phase space reconstruction and ELM based soft measurement for vibration of a mill with multiple parameters and coal types[J]. Thermal Power Generation, 2015, 44(3): 42-47.
- [9] 熊军华, 牛珂, 张春歌, 等. 基于小波变异果蝇优化支持向量机短期负荷预测方法研究[J]. 电力系统保护与控制, 2017, 45(13): 71-77.
XIONG Junhua, NIU Ke, ZHANG Chungge, et al. LSSVM in short-term load forecasting based on wavelet transform and mutant fruit fly optimization algorithm[J]. Power System Protection and Control, 2017, 45(13): 71-77.
- [10] 周俊, 陈璟华, 刘国祥, 等. 粒子群优化算法中惯性权重综述[J]. 广东电力, 2013, 26(7): 6-12.
ZHOU Jun, CHEN Jinghua, LIU Guoxiang, et al. Summary on inertia weight in particle swarm optimization algorithm[J]. Guangdong Electric Power, 2013, 26(7): 6-12.
- [11] 董福贵, 张世英, 谭忠富, 等. 基于遗传算法的小波神经网络在电价预测中的应用[J]. 计算机工程, 2005, 31(4): 32-33.
DONG Fugui, ZHANG Shiyong, TAN Zhongfu, et al. Application for electricity price forecasting using wavelet neural networks based on GA[J]. Computer Engineering, 2005, 31(4): 32-33.
- [12] 薛浩然, 张珂珩, 李斌, 等. 基于布谷鸟算法和支持向量机的变压器故障诊断[J]. 电力系统保护与控制, 2015, 43(8): 8-13.
XUE Haoran, ZHANG Keheng, LI Bin, et al. Fault diagnosis of transformer based on the cuckoo search and support vector machine[J]. Power System Protection and Control, 2015, 43(8): 8-13.
- [13] ZHANG X, WANG J, ZHANG K. Short-term electric load forecasting based on singular spectrum analysis and support vector machine optimized by Cuckoo search algorithm[J]. Electric Power Systems Research, 2017, 146: 270-285.
- [14] 罗勇, 匡翠林, 卢辰龙, 等. 基于 SSA 的 GPS 坐标序

- 列去噪及季节信号提取[J]. 大地测量与地球动力学, 2015, 35(3): 391-395.
- LUO Yong, KUANG Cuilin, LU Chenlong, et al. GPS coordinate series denoising and seasonal signal extraction based on SSA[J]. Journal of Geodesy and Geodynamics, 2015, 35(3): 391-395.
- [15] ABDOLLAHZADE M, MIRANIAN A, HASSANI H, et al. A new hybrid enhanced local linear neuro-fuzzy model based on the optimized singular spectrum analysis and its application for nonlinear and chaotic time series forecasting[J]. Information Sciences, 2015, 295: 107-125.
- [16] XIAO L, WANG J, HOU R, et al. A combined model based on data pre-analysis and weight coefficients optimization for electrical load forecasting[J]. Energy, 2015, 82: 524-549.
- [17] LI Z, YE L, ZHAO Y, et al. Short-term wind power prediction based on extreme learning machine with error correction[J]. Protection and Control of Modern Power Systems, 2016, 1(1): 9-16. DOI: 10.1186/s41601-016-0016-y.
- [18] YANG X S, DEB S. Engineering optimization by cuckoo search[J]. International Journal of Mathematical Modeling & Numerical Optimization, 2010, 1(4): 330-343.
- [19] LIU H, CHEN C, TIAN H Q, et al. A hybrid model for wind speed prediction using empirical mode decomposition and artificial neural networks[J]. Renewable Energy, 2012, 48(6): 545-556.
- [20] HASSANI H. Singular spectrum analysis: methodology and comparison[J]. Journal of Data Science, 2007, 5(2): 239-257.
-
- 收稿日期: 2017-12-30; 修回日期: 2018-03-01
- 作者简介:
- 殷豪(1972—), 女, 硕士, 副教授, 研究方向为电力系统的稳定与控制; E-mail: 3403446@qq.com
- 曾云(1994—), 女, 通信作者, 硕士研究生, 研究方向为人工智能算法在电力市场中的应用; E-mail: 30892875@qq.com
- 孟安波(1971—), 男, 博士, 教授, 主要从事电力系统自动化、系统分析与集成等方面的研究工作。E-mail: mengambo@vip.sina.com
- (编辑 葛艳娜)