

基于VMD与改进麻雀算法优化LSSVM的多晶硅生产能耗预测*

赵铁成¹, 谢丽蓉^{1†}, 范协诚², 王智勇³, 邓佑刚², 李朋², 叶金鑫¹

(1. 新疆大学 电气工程学院, 新疆 乌鲁木齐 830017; 2. 新特能源股份有限公司, 新疆 乌鲁木齐 830011;
3. 新疆焱加华工业科技有限公司, 新疆 乌鲁木齐 830018)

摘要: 针对多晶硅还原生产能耗预测精度较低问题, 提出了基于VMD-ASSA-LSSVM模型的多晶硅生产能耗预测方法. 首先, 采用主成分分析方法对能耗影响因素的数据降维处理, 提高模型执行效率. 利用变分模态分解(Variational Mode Decomposition, VMD)将能耗序列分解为不同特征尺度能耗分量, 降低能耗序列的非平稳性、复杂度. 其次, 为解决麻雀搜索算法(Sparrow Search Algorithm, SSA)的收敛慢与收敛精度低问题, 引入适应性学习因子进行改进. 结合改进的自适应麻雀搜索算法寻优最小二乘支持向量机的可调参数, 建立了VMD-ASSA-LSSVM的能耗预测组合模型; 然后对分解的能耗分量单独预测, 叠加子序列预测结果即为最终能耗预测. 最后, 以某多晶硅企业实际生产数据验证该方法的有效性, 证实提高了预测精度.

关键词: 多晶硅; 麻雀搜索算法(SSA); LSSVM; VMD; 能耗预测

DOI: 10.13568/j.cnki.651094.651316.2021.08.05.0001

中图分类号: TP391.9 **文献标识码:** A **文章编号:** 2096-7675(2022)04-0498-010

引文格式: 赵铁成, 谢丽蓉, 范协诚, 王智勇, 邓佑刚, 李朋, 叶金鑫. 基于VMD与改进麻雀算法优化LSSVM的多晶硅生产能耗预测[J]. 新疆大学学报(自然科学版)(中英文), 2022, 39(4): 498-507.

英文引文格式: ZHAO Tiecheng, XIE Lirong, FAN Xiecheng, WANG Zhiyong, DENG Yougang, LI Peng, YE Jinxin. Energy consumption prediction of polysilicon production based on VMD and improved sparrow algorithm optimized LSSVM[J]. Journal of Xinjiang University(Natural Science Edition in Chinese and English), 2022, 39(4): 498-507.

Energy Consumption Prediction of Polysilicon Production Based on VMD and Improved Sparrow Algorithm Optimized LSSVM

ZHAO Tiecheng¹, XIE Lirong¹, FAN Xiecheng², WANG Zhiyong³,
DENG Yougang², LI Peng², YE Jinxin¹

(1. School of Electrical Engineering, Xinjiang University, Urumqi Xinjiang 830017, China; 2. Xinte Energy Co. Ltd., Urumqi Xinjiang 830011, China; 3. Xinjiang Yijiahua Industrial Technology Co. Ltd., Urumqi Xinjiang 830018, China)

Abstract: Aiming at the low prediction accuracy of polysilicon reduction production energy consumption, a polysilicon production energy consumption prediction method based on VMD-ASSA-LSSVM model is proposed. Firstly, principal component analysis is used to reduce the dimension of the data of energy consumption influencing factors to improve the execution efficiency of the model. The energy consumption series is decomposed into energy consumption components with different characteristic scales by using variational mode decomposition(VMD), which reduces the complexity of energy consumption series. Secondly, to solve the problems of slow convergence and low convergence accuracy of sparrow search algorithm(SSA), adaptive learning factor is introduced to improve it. Combined with the improved adaptive sparrow search algorithm to optimize the adjustable parameters of least squares support vector machine, a combined energy consumption prediction model of VMD-ASSA-LSSVM is established; Then, each energy consumption component is predicted separately, and the final energy consumption

* 收稿日期: 2021-08-05

基金项目: 国家自然科学基金(62163034).

作者简介: 赵铁成(1992-), 男, 硕士生, 从事多晶硅生产能耗预测的研究, E-mail: 649265305@qq.com.

† 通讯作者: 谢丽蓉(1969-), 女, 教授, 博士生导师, 主要从事控制系统优化、新能源发电、负荷预测等方面的研究, E-mail: xielifirong@xju.edu.cn.

prediction is obtained by superimposing the prediction results of subsequence. Finally, the actual production data of a polysilicon enterprise are used to verify the effectiveness of the method and improve the prediction accuracy.

Key words: polysilicon; sparrow search algorithm(SSA); LSSVM; VMD; energy consumption prediction

0 引言

多晶硅是光伏产业设备生产的主要原材料,其需求增长迅速,年增长率约为31.2%。多晶硅还原生产是生产多晶硅的关键过程,生产工艺总电耗的60%用于多晶硅还原生产,约占综合生产成本的30%^[1]。采取一定的措施来减少还原生产的能耗已经成为各多晶硅企业关注的热点问题。生产过程主要能耗是还原炉内硅棒表面高温所需的电耗,多晶硅的还原生产是一个随机、动态、复杂的过程。所需能耗时刻变化,在生产过程中很难确定下一时刻的能耗情况,这种复杂的生产过程给工艺人员的可控管理带来了极大的困难^[2]。因此,对还原炉沉积生产过程的能耗展开了研究并对其生产过程中的下一时段的能耗进行预测,明确下一时段的能耗情况,以降低还原沉积过程能耗把控的不确定性,提高工艺人员对还原炉操作的可靠性、合理性。

关于多晶硅生产过程中还原炉能耗的研究目前大多从技术上提高工艺水平,改进设备,并进行模拟仿真。Nie等^[3]采用数值模拟方法研究反应堆焦耳加热过程的热能消耗分析,对降低多晶硅生产还原过程中的能耗具有重要的参考意义。沈琛^[4]通过利用Aspen Plus过程仿真软件对现有的再生气体回收工艺和节能优化过程进行了模拟和能耗对比分析,从而降低了能耗。刘继三等^[5]提出“Aspen Plus模拟方案”,在传统技术中优化蒸汽消费、水循环和能源消费,大大降低了能源消耗的成本。韩金豆等^[6]利用三氯硅烷蒸馏和热泵整流技术中的差分热整合技术减少加热和冷却能耗约50%。杨金祥^[7]、方文宝^[8]、夏小霞^[9]等探究了多晶硅还原炉中温度对凝固速率、硅棒直流加热模型和三氯氢硅氢还原过程的影响,对降低多晶硅生产还原过程中的能耗有一定指导意义。郭久俊^[10]针对还原过程中能耗的复杂影响因素的问题,提出了一种基于LSTM-Adaboost递归神经网络多晶硅生产制造工艺的能耗预测模型,以实现能耗预测。尽管在多晶硅生产制造过程中关于节能优化的研究获得了一些成果,但多晶硅生产过程的能耗预测研究仍相对较少、且预测精度低。

针对以上问题,本文提出了基于VMD与改进麻雀算法优化LSSVM的多晶硅生产能耗预测方法。从主成分分析算法(Principal Component Analysis, PCA)对多晶硅还原生产能耗影响因素降维入手,依次介绍了能耗序列的VMD序列分解方法、麻雀搜索算法原理及改进后自适应麻雀搜索算法(Adaptive Sparrow Search Algorithm, ASSA);自适应麻雀搜索算法优化LSSVM,寻找最优惩罚系数与核函数,提高其泛化能力。通过实验仿真分析得出所提组合预测模型可大大提高能耗预测的准确性。

1 基于PCA的多晶硅还原生产能耗影响因素降维

1.1 PCA算法原理

多晶硅还原生产能耗受多种因素影响,机理复杂、耦合性强。若把所有参数直接输入到预测模型中,会导致模型执行效率低。因此,有必要消除多晶硅生产过程所有参数数据间多重共线性。本文采用主成分分析算法^[11](PCA)对多晶硅还原生产能耗影响因素降维处理,PCA算法原理如下:

(1) 构成变量采样的原始数据矩阵 $\mathbf{x}_{n \times p}$:

$$\mathbf{x}_{n \times p} = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1p} \\ x_{21} & x_{22} & \cdots & x_{2p} \\ \cdots & \cdots & \cdots & \cdots \\ x_{n1} & x_{n2} & \cdots & x_{np} \end{bmatrix} \quad (1)$$

式中: n 为样本数; p 为样本中指标的数量。

(2) 对矩阵 $\mathbf{x}_{n \times p}$ 标准正态分布化处理得到标准化矩阵 \mathbf{R} ,且对其求解相关系数矩阵 \mathbf{R} 。相关系数的计算公式如下:

$$r_{ij} = \frac{\sum_{m=1}^n (x_{mi} - \bar{x}_i)(x_{mj} - \bar{x}_j)}{\sqrt{\sum_{m=1}^n (x_{mi} - \bar{x}_i)^2 \sum_{m=1}^n (x_{mj} - \bar{x}_j)^2}} \quad (2)$$

式中: r_{ij} 为 x_{mi} 与 x_{mj} 之间的相关系数,且 $r_{ij} = r_{ji}$ 。

(3) 建立关系矩阵 \mathbf{R} , 计算 \mathbf{R} 的特征值及特征向量, 由其特征值确定最小变量数量 m .

$$\mathbf{R} = (x_{n \times p}^*)^T x_{n \times p}^* / (n-1) \quad (3)$$

$$\left(\sum_{i=1}^m \lambda_i \right) / \left(\sum_{i=1}^n \lambda_j \right) \geq \eta \quad (4)$$

式中: 取 $\eta=0.85$; 既用 m 维的特征向量代表原始训练数据基本特征.

1.2 PCA多晶硅还原生产能耗影响因素降维

选取多晶硅公司实际生产数据, 包括 H_2 (氢气) 流量、TCS (三氯氢硅) 流量、尾气温度、尾气压力、混合气温度、相电流和相电压等共24组数据. 通过主成分分析算法确定所需的最小变量数量, 实现多晶硅还原生产能耗影响因素降维. 利用公式(1)~(3), 求出协方差矩阵的特征根及贡献率, 根据累计贡献率提取主成分, 计算结果如表1所示, 各主成分分量的贡献率如图1所示.

表 1 特征值及贡献率

成分变量名	特征值	方差贡献率/%	累计贡献率/%
W_1	6.664 2	41.65	41.65
W_2	3.779 3	23.62	65.27
W_3	2.091 0	13.07	78.34
W_4	1.088 2	6.80	85.14
W_5	0.923 4	5.77	90.91
W_6	0.848 2	5.30	96.21
W_7	0.302 8	1.89	98.11
W_8	0.183 4	1.15	99.25
W_9	0.090 7	0.57	99.82
W_{10}	0.015 7	0.10	99.92
W_{11}	0.006 9	0.04	99.96
W_{12}	0.002 8	0.02	99.98

由表1可知, 通过主成分分析计算结果得出结论: 当 $m=4$ 时, 主成分累计贡献率为85.14%, 由公式(4)主成分累计贡献率 $\eta \geq 85\%$, 即 $W_1 \sim W_4$ 主成分可抓住数据主要信息. 由图1可知, 各主成分分量的方差贡献率快速下降, 从 W_5 开始方差贡献率较低, 对整个数据信息的影响很小, 即 $W_1 \sim W_4$ 可有效包含原有生产数据的绝大部分信息, 极大提升预测模型的执行效率.




图 1 各主成分分量的贡献率

2 构建VMD-ASSA-LSSVM多晶硅还原生产能耗预测模型

2.1 变分模态分解原理

变分模态分解 (Variational Mode Decomposition, VMD) 是采用原始信号的非递归处理^[12-13]. 利用交替方向乘子法更新模块功能及其中心频率, 调整相应的基频带^[14], 最大限度地减少带宽估计. 具体构造步骤如下:

(1) 通过希尔伯特 (Hilbert) 变换计算每个模态函数 $u_k(t)$ 解析信号, 将中心频率 ω_k 的相应指数项混叠, 以获得每个模态的频谱.

$$[(\delta(t) + \frac{j}{\pi t}) * u_k(t)] e^{-j\omega_k t} \quad (5)$$

式中: $\delta(t)$ 是狄拉克函数; $*$ 表示卷积运算; $e^{-j\omega_k t}$ 表示中心频率复平面向量描述.

(2) 通过高斯平滑原理, 对 $u_k(t)$ 信号带宽解调.

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \|\partial_t [(\delta(t) + \frac{j}{\pi t}) * u_k(t)] e^{-j\omega_k t}\|^2 \right\}, \quad s.t. \sum_k u_k = f(t) \quad (6)$$

式中: $\{u_k\} = \{u_1, u_2, \dots, u_k\}$ 为 K 个模态分量 IMF ; $\{\omega_k\} = \{\omega_1, \omega_2, \dots, \omega_k\}$ 为各 IMF 的中心频率.

(3) 引入二次惩罚系数 α 和拉格朗日乘数 λ , 将约束性变分问题转换为无约束变分问题.

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_k \|\partial_t [(\delta(t) + \frac{j}{\pi t}) * u_k(t)] e^{-j\omega_k t}\|_2^2 + \|f(t) - \sum_k u_k(t)\|_2^2 + \left\langle \lambda(t), f(t) - \sum_k u_k(t) \right\rangle \quad (7)$$

(4) 利用交替方向乘子法更新 u_k, ω_k, λ 并求取上述拉格朗日函数的鞍点.

$$\hat{u}_k^{n+1}(\omega) = (\hat{f}(\omega) - \sum_{i=k} \hat{u}_i^n(\omega) + \hat{\lambda}^n(\omega)/2) / (1 + 2\alpha(\omega - \omega_k^n)^2) \quad (8)$$

$$\omega_k^{n+1} = \int_0^\infty \omega |\hat{u}_k^{n+1}(\omega)|^2 d\omega / \int_0^\infty |\hat{u}_k^{n+1}(\omega)|^2 d\omega \quad (9)$$

$$\lambda^{n+1}(\omega) \leftarrow \lambda^n(\omega) + \tau \left(f(\omega) - \sum_k \hat{u}_k^{n+1}(\omega) \right) \quad (10)$$

式中: τ 为噪声容限参数; $\hat{u}_k^{n+1}, \hat{f}(\omega), \hat{u}(\omega)$ 和 $\hat{\lambda}(\omega)$ 分别为 $u_k^{n+1}, f(t), u_t(t)$ 和 $\lambda(t)$ 的傅里叶变换.

2.2 改进麻雀搜索算法

2.2.1 麻雀搜索算法

麻雀搜索算法^[15] (Sparrow Search Algorithm, SSA) 是一种新型智能优化算法, 主要模拟麻雀群的觅食和防止被捕食过程, 由发现者、跟随者、预警者组成麻雀群觅食模型. 在觅食过程中, 发现最佳食物的个体为发现者, 其余为追随者, 并选取一定比例的个体进行预警. 具体的搜索过程如下:

(1) 发现者位置迭代更新数学表达式如下:

$$x_{i,d}^{t+1} = \begin{cases} x_{i,d}^t \cdot \exp(\frac{-i}{\alpha \cdot W}), & r < \beta \\ x_{i,d}^t + q \cdot l, & r \geq \beta \end{cases} \quad (11)$$

式中: t 为迭代的数量, W 为迭代次数最大阈值, $x_{i,d}^t$ 为第 t 代的第 i 个麻雀的位置在第 d 维, $\alpha \in (0, 1]$. 预警值 $r \in [0, 1]$, 安全值 $\beta \in [0.5, 1]$, q 是服从正态分布的随机数, l 是元素全部为 1 的矩阵. 当 $r < \beta$ 时, 表明附近没有捕食者, 发现者进行范围性搜索. 当 $r \geq \beta$ 时, 表明发现捕食者并向种群发出警告, 麻雀种群要立即飞往安全的地方觅食.

(2) 追随者位置迭代更新数学表达式如下:

$$x_{i,d}^{t+1} = \begin{cases} q \cdot \exp(\frac{x_{\text{worst}}^t - x_{i,d}^t}{i^2}), & i > \frac{n}{2} \\ x_p^{t+1} + |x_{i,d}^t - x_p^{t+1}| \cdot a^+ \cdot l, & i \leq \frac{n}{2} \end{cases} \quad (12)$$

式中: x_p^{t+1} 为占据食物最多的位置, x_{worst}^t 为占据食物最少的位置, a^+ 为每个元素是 ± 1 的矩阵, 并且 $a^+ = a^T (aa^T)^{-1}$. 当 $i > n/2$ 时, 表明适应度值低的第 i 个追随者没有获得食物, 需要追随新的发现者获得食物.

(3) 预警者意识到危险时, 进行反捕食行为, 其数学表达式如下:

$$x_{i,d}^{t+1} = \begin{cases} x_{\text{best}}^t + \rho \cdot |x_{i,d}^t - x_{\text{best}}^t|, & f_i > f_g \\ x_{i,d}^t + k \cdot \left(\frac{|x_{i,d}^t - x_{\text{worst}}^t|}{(f_i - f_w) + \varepsilon} \right), & f_i = f_g \end{cases} \quad (13)$$

式中: x_{best}^t 为最安全位置, ρ 为学习率控制参数, $k \in [-1, 1]$ 为麻雀转移方向参数, f_i 为个体麻雀的适应值, f_g 、 f_w 为最优和最差适应值, $\varepsilon \in (0.01, 0.5)$. 当 $f_i > f_g$ 时, 表明麻雀捕食系数较大. 当 $f_i = f_g$ 时, 表明预警麻雀意识到危险, 需要靠近其它麻雀以最大程度地减少被捕食的风险系数.

2.2.2 改进麻雀搜索算法

麻雀搜索算法可用于不同领域解决优化问题. 麻雀在解空间中的位置是随机分布的, 当前个体周围没有相邻的麻雀时, 执行随机行走策略. 这种模式在有限的迭代次数下减缓了收敛趋势, 降低了收敛精度. 本文提出适应性学习解决该问题, 改进过程如下:

(1) 麻雀的安全系数变化率:

$$v = \frac{|f(x_{i,d}^t) - f(x_{\text{best}}^t)|}{f(x_{\text{best}}^t) + \mu} \quad (14)$$

式中: μ 为极小常数; $f(x_{i,d}^t)$ 为目标函数值; $f(x_{\text{best}}^t)$ 为最佳适应值.

(2) 麻雀在训练中的适应性学习因子: $\alpha_i^t = \frac{1}{1+e^{-v}}$, $v \in (0, 2]$.

(3) 麻雀种群中发现者、追随者、预警者的自适应位置迭代更新:

发现者自适应位置迭代更新:

$$x_{i,d}^{t+1} = \begin{cases} \alpha_i^t \cdot x_{i,d}^t \cdot \exp\left(\frac{-i}{\alpha \cdot W}\right), & r < \beta \\ \alpha_i^t \cdot x_{i,d}^t + q \cdot l, & r \geq \beta \end{cases} \quad (15)$$

追随者自适应位置迭代更新:

$$x_{i,d}^{t+1} = \begin{cases} q \cdot \exp\left(\frac{x_{\text{worst}}^t - x_{i,d}^t}{i^2}\right), & i > \frac{n}{2} \\ x_p^{t+1} + |\alpha_i^t \cdot x_{i,d}^t - x_p^{t+1}| \cdot a^+ \cdot l, & i \leq \frac{n}{2} \end{cases} \quad (16)$$

预警者自适应位置迭代更新:

$$x_{i,d}^{t+1} = \begin{cases} x_{\text{best}}^t + \rho \cdot |\alpha_i^t \cdot x_{i,d}^t - x_{\text{best}}^t|, & f_i > f_g \\ \alpha_i^t \cdot x_{i,d}^t + k \cdot \left(\frac{|\alpha_i^t \cdot x_{i,d}^t - x_{\text{worst}}^t|}{(f_i - f_w) + \varepsilon}\right), & f_i = f_g \end{cases} \quad (17)$$

2.3 最小二乘支持向量机

LSSVM是对SVM的改进和扩展, 将低维空间中的线性不可分问题转化到高维空间中去解决, 避免了二次规划问题^[16-18], 将最优化问题的求解转化为求解线性方程, 降低算法的复杂度, 同时提升收敛的精度^[19-20]. LSSVM的回归过程如下:

(1) LSSVM的回归模型:

$$f(x) = \omega^T \varphi(x) + b \quad (18)$$

式中: ω 为特征空间中的权系数向量; $\varphi(x)$ 为把 x 映射到高维特征空间的非线性映射函数; $b \in \mathbf{R}$ 为偏差.

(2) 利用结构风险最小化准则^[21], 式(18)对应的LSSVM优化问题可以转变成式(19), 为解决带约束问题, 引入 α_i 构建Lagrange函数:

$$\min_{\omega, b, e} J(\omega, e) = \frac{1}{2} \omega^T \omega + \frac{\xi}{2} \sum_{i=1}^n e_i^2, \quad s.t. \quad y_i = \omega^T \varphi(x_i) \quad (19)$$

$$L(\omega, b, e_i, \alpha_i) = J(\omega, e) - \sum_{i=1}^n \alpha_i [\omega^T \varphi(x_i) + b + e_i - y_i] \quad (20)$$

式中: e_i 为误差变量; ξ 为惩罚系数; α_i 为Lagrange乘法算子.

(3) 通过KKT条件求解, 并最终得到回归函数^[22]为:

$$f(x) = \sum_{i=1}^n \alpha_i K(x_i, x_j) + b \quad (21)$$

$$K(x_i, x_j) = x_i \cdot x_j^T = \exp\{-\|x_i - x_j\|^2 / 2\sigma^2\} \quad (22)$$

式中: $K(x_i, x_j)$ 为核函数; σ 为核函数宽度. 自适应麻雀算法对LSSVM中的可调参数 ξ 和 σ 寻优.

2.4 预测模型的建立

自适应麻雀算法优化最小二乘支持向量机的流程如图2所示,其具体运行步骤如下所示:

步骤1: 设置ASSA算法参数: 麻雀的种群规模为20、最大迭代次数为50、学习率控制参数为 ρ .

步骤2: 初始化麻雀位置 $x_{i,d}^t$. 将均方误差 (Mean Squared Error, MSE) 作为适应度函数, 然后利用公式(23)计算出每只麻雀个体适应度值 P_{best} , 选取适应度值最小个体作为全局最优值 G_{best} .

$$f(x) = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (23)$$

式中: $f(x)$ 为目标函数; n 为样本数; y_i 为真实观测值; \hat{y}_i 为预测值.

步骤3: 根据公式(15)、(16)、(17)更新麻雀种群中发现者、追随者、预警者的位置, 根据公式(17)判断麻雀是否进行反捕食行为.

步骤4: 更新个体最优解 P_{best} 和全局最优解 G_{best} , 检查是否满足寻优停止条件的预设最大迭代次数. 若满足则结束寻优, 输出ASSA寻找的全局最优值. 否则转至步骤2继续寻优.

步骤5: 将ASSA寻找的最优惩罚系数 ξ 和核函数宽度 σ 值赋值给LSSVM, 建立最优的LSSVM预测模型.

本文最大迭代次数设置为50次, 为了提高实验结果的可靠性, 算法独立运行30次, 取30次的平均值作为最终展示结果, 适应度函数平均收敛曲线如图3所示.

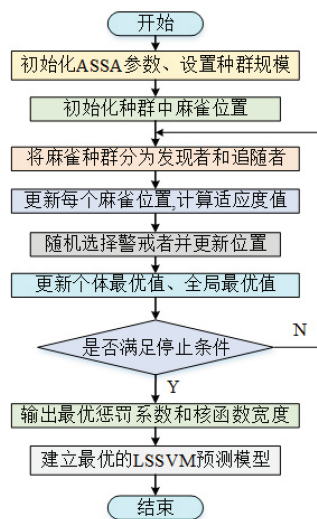


图 2 ASSA优化LSSVM流程图




图 3 ASSA优化LSSVM平均适应度收敛曲线

由图3可知, ASSA算法平均在第20次迭代之后就找到了全局最优值, 并将最优参数赋予LSSVM, 构成最优的ASSA-LSSVM多晶硅还原生产能耗预测模型.

3 VMD-ASSA-LSSVM多晶硅还原生产能耗预测模型

多晶硅还原生产能耗具有非线性、非平稳性和随机性的特点, 使得多晶硅还原生产能耗预测精度低. 针对该问题, 本文提出VMD-ASSA-LSSVM多晶硅还原生产能耗预测模型, 如图4所示. 具体的多晶硅能耗预测过程如下:

步骤1: 利用主成分分析方法 (PCA) 提取多晶硅还原生产过程的主要影响因素, 实现降低影响因素数据维数, 提升预测模型的执行效率.

步骤2: 利用变分模态分解(VMD)将多晶硅还原生产能耗序列分解, 获得 K 个不同尺度的本特征模态分量, 为避免发生频率混叠现象, 采用观察中心频率方法确定模态分量的个数.

步骤3: 为解决麻雀搜索算法(SSA)当个体周围没有相邻的麻雀时, 在有限的迭代次数下减缓了收敛趋势、降低了收敛精度, 本文提出引入适应性学习因子解决该问题.

步骤4: 为提高模型在短尺度时序的预测能力, 对各模态分别建立LSSVM预测模型. 利用自适应麻雀搜索算法(ASSA)对LSSVM中可调参数进行寻优, 极大提升模型的预测精度.

步骤5: 将各模态预测模型的预测值相叠加作为最终预测结果, 得到多晶硅生产过程能耗最终预测值.

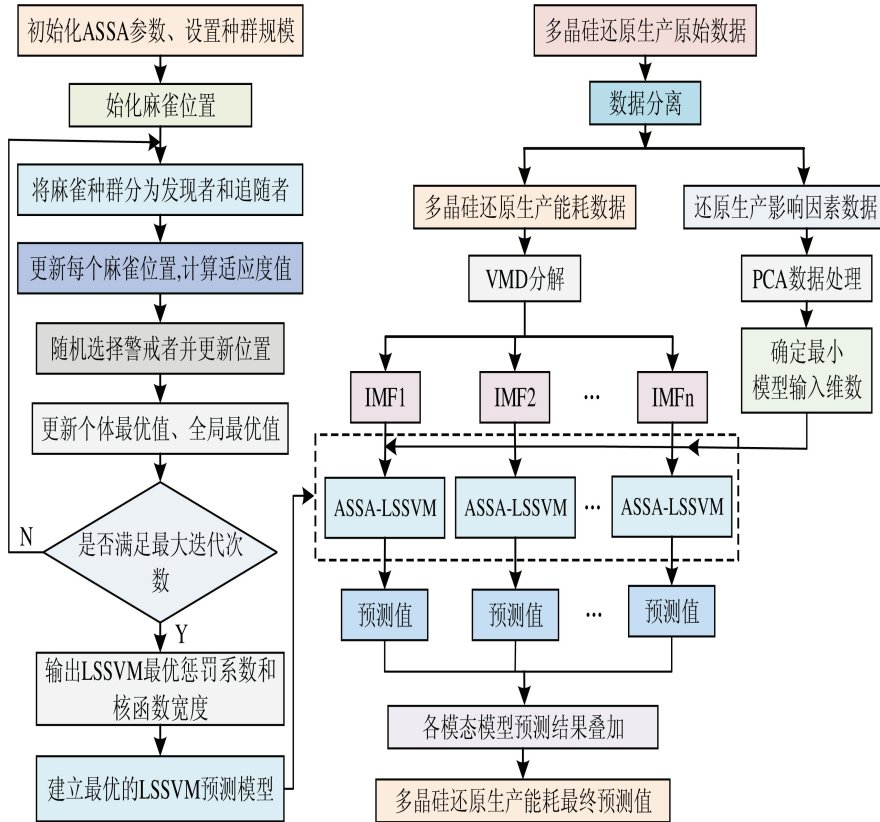


图 4 VMD-ASSA-LSSVM多晶硅还原生产能耗预测模型

4 算例分析

4.1 多晶硅还原生产能耗原始数据VMD分解

数据来自某多晶硅公司GBAI-ICS系统平台采集多晶硅还原生产的能耗数据, 实验选取多晶硅公司二分厂2018年9月1日到2018年10月20日的1 200组能耗数据, 其中前1 164组数据作为训练集, 后36组数据作为测试集, 样本采样间隔为1 h. 多晶硅还原生产能耗样本数据如图5所示. 由图5可知, 能耗数据具有非线性、非平稳性和随机性的特点, 为解决该问题, 利用VMD对能耗数据分解处理. VMD需先选定模态个数 K , 模态分解的次数过少时, 信号中的一些重要信息被排除或者丢失. 模态分解个数过多时, 相邻模态分量的中心频率彼此接近, 导致频率混叠. 因此, 采用观察中心频率方法^[23-24]确定 K 的大小.




图 5 能耗数据

多晶硅还原生产能耗数据通过VMD分解可得 K 个 IMF 分量,其中心频率呈低频到高频分布,选取分量的中心频率取到最大值时的 K 值作为分解次数.对 K 从小到大取值,检验不同 K 值各模态对应的中心频率是否相近,判断其是否过分解. K 取不同值时的中心频率如表2所示.

表 2 K 取不同值时的中心频率

模态分量数	模态1	模态2	模态3	模态4	模态5	模态6	模态7
$K=3$	0.227	278	932	-	-	-	-
$K=4$	0.238	187	581	917	-	-	-
$K=5$	0.214	180	432	742	935	-	-
$K=6$	0.173	178	253	487	743	915	-
$K=7$	0.123	164	212	435	589	712	908

由表2可知,当 $K=6$ 时,模态分量2的中心频率为178,模态分量3的中心频率为253,模态频率相近,为避免频率混叠,本文选取 K 值为5,采用VMD分解结果如图6所示.




图 6 VMD分解结果

4.2 预测结果对比分析

为验证本文提出预测模型的优越性,以相同原始数据样本为基础,分别选择LSSVM、VMD-LSSVM、SSA-LSSVM、ASSA-LSSVM和VMD-ASSA-LSSVM预测模型进行对比分析.五种模型预测结果对比如图7所示、相对误差如图8所示,性能评价指标如表3所示.




图 7 模型预测结果对比




图 8 模型相对误差对比

通过以上实验仿真结果可以得出:对比分析LSSVM模型与VMD-LSSVM模型,采用VMD将多晶硅能耗序列分解为不同特征的模态,分别建模预测能有效改善预测精度. ASSA-LSSVM模型在SSA-LSSVM模型的基础上,引入自适应学习因子,解决SSA算法收敛速度慢、收敛精度下降的问题,提高了对LSSVM的优化效果. VMD-ASSA-LSSVM模型比较好地解决了对于极端时刻的预测效果不佳的问题,预测效果更优,能够更好地拟合出能耗变化趋势.

表 3 误差指标对比

评价指标	LSSVM	VMD-LSSVM	SSA-LSSVM	ASSA-LSSVM	VMD-ASSA-LSSVM
<i>MAE</i>	0.240 19	0.191 54	0.142 92	0.125 86	0.103 44
<i>RMSE</i>	0.279 52	0.224 58	0.176 94	0.157 48	0.129 49
<i>MAPE</i>	0.021 31	0.015 88	0.011 63	0.010 05	0.008 27

为了增加仿真结果的可靠性,本文将10次仿真评价指标数值的平均值作为预测模型的误差评判结果,如表3所示. 通过对比观察,发现VMD-LSSVM模型相较LSSVM模型,误差评价指标*MAPE*降低了34.19%、*MAE*降低了25.40%、*RMSE*降低了24.46%; ASSA-LSSVM模型相较SSA-LSSVM模型,误差评价指标*MAPE*降低了15.72%、*MAE*降低了13.55%、*RMSE*降低了12.33%; VMD-ASSA-LSSVM模型相较ASSA-LSSVM模型,误差评价指标*MAPE*降低了21.52%、*MAE*降低了21.67%、*RMSE*降低了21.62%. 实验结果表明: ASSA-LSSVM模型提升了LSSVM的泛化能力; VMD-ASSA-LSSVM模型预测精度最高.

为进一步验证VMD-ASSA-LSSVM预测模型的预测精度,与VMD-PSO-LSSVM、VMD-BSO-LSSVM以及VMD-BAS-LSSVM等预测模型进行仿真对比试验. 模型预测结果对比如图9所示,预测误差评价指标对比如表4所示.

由图9可知,相比其它对比预测模型, VMD-ASSA-LSSVM预测模型的预测值与能耗真实值的拟合程度最高、预测效果最好. 即使在能耗的峰谷点附近,本文所提预测模型也能有较好的预测精度.

表 4 误差指标对比

评价指标	VMD-PSO-LSSVM	VMD-BSO-LSSVM	VMD-BAS-LSSVM	VMD-ASSA-LSSVM
<i>MAE</i>	0.135 55	0.132 32	0.133 16	0.103 44
<i>RMSE</i>	0.167 58	0.163 44	0.165 84	0.129 49
<i>MAPE</i>	0.011 22	0.010 54	0.010 77	0.008 27

由表4可知,相比VMD-PSO-LSSVM、VMD-BSO-LSSVM、VMD-BAS-LSSVM预测模型,本文所提方法的误差评价指标*MAPE*分别降低了35.67%、27.45%和30.23%; *MAE*分别降低了31.04%、27.92%和28.73%; *RMSE*分别降低了29.42%、26.22%和28.07%, VMD-ASSA-LSSVM预测模型的各项预测误差指标值均最小. 因此,本文所提预测模型预测性能优于上述其它模型.

5 结论

为了实现多晶硅生产过程能耗的管控,需要对多晶硅生产过程能耗进行精准、高效预测,提出了一种基于VMD与改进麻雀算法优化LSSVM的多晶硅生产能耗预测方法,主要结论如下:

(1) 考虑到多晶硅生产过程受复杂因素影响,通过主成分分析算法(PCA)对输入多变量降维,客观地反映多变量预测因子中所需的最小变量数量,在保证信息完整的前提下提高运算速度.




图 9 模型预测结果对比

(2) 变分模态分解(VMD)可以更细致表征多晶硅生产过程能耗在不同频率尺度上的变化特性,分解结果具有更好的规律性。LSSVM与SVM相比预测精度更高,预测速度更快,并且待优化参数更少。同时,自适应麻雀搜索算法(ASSA)经过引入自适应学习因子,解决了原有算法收敛速度慢、收敛精度下降的问题。

(3) 考虑VMD、LSSVM、ASSA各自优点,综合设计了VMD-ASSA-LSSVM组合预测方法,通过选取的实验数据,对模型进行验证。实验结果表明,该模型可有效提高预测的精度。

参考文献:

- [1] 江华,金艳梅,叶幸.等.中国光伏产业2019年回顾与2020年展望[J].太阳能,2020,3:14-23.
- [2] 朱晨曦.基于NICA的多晶硅还原炉能耗与质量优化[D].广州:广东工业大学,2018.
- [3] NIE Z F, RAMACHANDRAN P A, HOU Y Q. Optimization of effective parameters on Siemens reactor to achieve potential maximum deposition radius: an energy consumption analysis and numerical simulation[J]. International Journal of Heat and Mass Transfer, 2018, 117: 1083-1098.
- [4] 沈琛.多晶硅尾气吸附塔再生气回收工艺的节能优化及流程模拟[J].现代化工,2019,39(S1):192-194.
- [5] 刘继三,姚又省.冷氢化工艺的节能优化及流程模拟[J].化学工程,2016,44(1):11-13.
- [6] 韩金豆,梁世民.三氯氢硅节能精馏工艺模拟研究[J].现代化工,2019,39(7):207-210.
- [7] 杨金祥,石爽,姜大川,等.多晶硅定向凝固过程中温度对凝固速率的影响[J].材料导报,2019,33(S1):28-32.
- [8] 方文宝,周扬民,聂陟枫,等.多晶硅还原炉中硅棒的直流电加热模型[J].太阳能学报,2018,39(8):2287-2292.
- [9] 夏小霞,周乃君.多晶硅还原炉内三氯氢硅还原过程的数值模拟[J].硅酸盐学报,2014,42(7):932-938.
- [10] 郭久俊.基于LSTM-Adaboost的多晶硅生产的能耗预测[J].计算机应用与软件,2018,35(12):71-75+117.
- [11] 王依宁,解大,王西田,等.基于PCA-LSTM模型的风电机网相互作用预测[J].中国电机工程学报,2019,39(14):4070-4081.
- [12] WU Q L, LIN H X. Short-term wind speed forecasting based on hybrid variational mode decomposition and least squares support vector machine optimized by bat algorithm model[J]. Sustainability, 2019, 11(3): 652-668.
- [13] 梁智,孙国强,李虎成,等.基于VMD与PSO优化深度信念网络的短期负荷预测[J].电网技术,2018,42(2):598-606.
- [14] 牛安敏,张宏立,王聪.基于VMD-Leaky-ESN的电力系统短期负荷多步预测方法[J].新疆大学学报(自然科学版)(中英文),2020,37(4):562-569.
- [15] XUE J, SHEN B. A novel swarm intelligence optimization approach: sparrow search algorithm[J]. Systems Science & Control Engineering, 2020, 8(1): 22-34.
- [16] LIU C, NIU P F, LI G Q, et al. A hybrid heat rate forecasting model using optimized LSSVM based on improved GSA[J]. Neural Processing Letters, 2017, 45(1): 299-318.
- [17] ZHANG J H, LIU Y. Application of complete ensemble intrinsic time-scale decomposition and least-square SVM optimized using hybrid DE and PSO to fault diagnosis of diesel engines[J]. Frontiers of Information Technology & Electronic Engineering, 2017, 18(2): 272-287.
- [18] GU X D, DENG F, GAO X, et al. An improved sensor fault diagnosis scheme based on TA-LSSVM and ECOC-SVM[J]. Journal of Systems Science & Complexity, 2018, 31(2): 372-384.
- [19] 梁甜,高丙朋.生物氧化预处理过程中氧化槽温度的预测控制[J].新疆大学学报(自然科学版),2018,35(1):108-114.
- [20] 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):194-202.
- [21] 肖怀硕,李清泉,施亚林,等.灰色理论-变分模态分解和NSGA-II优化的支持向量机在变压器油中气体预测中的应用[J].中国电机工程学报,2017,37(12):3643-3653.
- [22] 张英杰,许伟,汤龙波,等.基于滚动时间窗的PSO-LSSVM的通信基站能耗建模[J].湖南大学学报(自然科学版),2017,44(2):122-128.
- [23] 陶凯,吴定会.基于VMD-JAYA-LSSVM的短期风电功率预测[J].控制工程,2021,28(6):1143-1149.
- [24] 刘长良,武英杰,甄成刚.基于变分模态分解和模糊C均值聚类的滚动轴承故障诊断[J].中国电机工程学报,2015,35(13):3358-3365.