

基于数据的改进回声状态网络在高炉煤气发生量预测中的应用

刘颖¹ 赵玉君¹ 王伟¹ 吴毅平² 陈伟昌³

摘要 以钢铁企业高炉煤气系统这一复杂生产过程为背景, 针对高炉煤气发生量的预测问题, 提出一种基于数据的网络模型预测方法. 鉴于生产数据含噪高的特点, 采用经验模态分解将历史数据分解为若干独立的固有模式函数, 将小尺度函数经低通滤波器自适应去噪后, 再对数据重构以建立预测模型. 在建模过程中提出一种改进的回声状态网络, 通过奇异值分解求取网络输出权值, 克服了线性回归算法出现的病态问题, 提高了模型的预测精度. 现场实际数据预测结果表明所提出方法的有效性, 为制定煤气管网平衡调度方案提供科学的决策支持.

关键词 预测模型, 回声状态网络, 奇异值分解, 经验模态分解
中图分类号 TP18

Improved Echo State Network Based on Data-driven and Its Application to Prediction of Blast Furnace Gas Output

LIU Ying¹ ZHAO Jun¹ WANG Wei¹ WU Yi-Ping² CHEN Wei-Chang³

Abstract Based on the complex process of blast furnace gas (BFG) system in steel industry, a network forecasting method based on data-driven is established in this paper for the prediction problem on BFG output. Since the practical data include a diversity of noises, an empirical mode decomposition approach is employed to decompose the time series signal into a group of independent intrinsic mode functions, and the formed small-scale intrinsic mode functions are denoised by low-pass filter with an adaptive threshold. Then, the re-constructed signals are used to build the forecasting model, in which an improved echo state network is proposed and the network output weights are obtained by singular value decomposition. Therefore, the ill-conditioned problem of previous linear regression is overcome and the forecasting precision is increased. The prediction results using practical production data show the validity of the proposed method and also provide the scientific decision support for the gas resources scheduling.

Key words Prediction model, echo state network (ESN), singular value decomposition (SVD), empirical mode decomposition (EMD)

钢铁企业生产工艺过程复杂, 所涉及的能源介质种类繁多, 且能源介质的传输与转换过程普遍存在着多品种、多用途、高耦合等特点. 其中高炉煤气 (Blast furnace gas, BFG) 是钢铁冶炼过程中产生的副产品, 也是钢铁生产中如炼焦、加热炉、电厂等环节所需的重要二次能源, 其有效合理的利用直接影响到钢铁企业的能耗标准和产出成本. 由于 BFG 生产过程复杂同时伴有大幅波动, 其发生量很难通过机理模型来获得, 目前实际生产中对其定量的估计往往是依靠现场人员的生产经验来完成, 而

这样的经验估计也因其存在的主观性而常常无法实现对 BFG 的合理调度和有效利用, 从而导致能源浪费. 对 BFG 发生量进行科学预测, 可为煤气管网平衡调整提供决策支持, 从而制定合理的煤气使用计划, 减少煤气放散损失, 提高钢铁企业节能降耗水平.

借助实际生产过程的大量历史数据, 针对 BFG 的发生量采用基于数据的时间序列预测方法为此类难于建立机理模型的问题求解提供了新的途径. 回声状态网络 (Echo state network, ESN) 是一种新型递归神经网络^[1-2], 其独特的动态储备池结构 (Dynamical reservoir, DR) 使网络具备良好的短期记忆能力, 在时间序列预测方面表现出较好的性能^[3-4]. 然而 ESN 在求解输出权值时采用线性回归算法, 在处理实际问题时易导致病态解, 且伴随着较大幅值的输出权值. Jaeger 提出在状态变量上引入噪声以改善解的性能^[5], 然而噪声幅值的确定主要依靠经验, 目前尚缺乏可靠的方法. 此外该文献证明, 当样本个数小于输出权值维数时, 无论噪声幅值

收稿日期 2008-12-15 收修改稿日期 2009-02-15
Received December 15, 2008; in revised form February 15, 2009
国家高技术研究发展计划 (863 计划) (2007AA04Z1A9) 资助
Supported by National High Technology Research and Development Program of China (863 Program) (2007AA04Z1A9)
1. 大连理工大学信息与控制研究中心 大连 116024 2. 上海宝信软件股份有限公司自动化部 上海 201203 3. 上海宝钢股份有限公司能源中心 上海 210900
1. Research Center of Information and Control, Dalian University of Technology, Dalian 116024 2. Automation Department, Shanghai Baosight Software Co., Ltd., Shanghai 201203 3. Energy Center, Shanghai Baosteel Co., Ltd., Shanghai 210900
DOI: 10.3724/SP.J.1004.2009.00731

取多少, ESN 的解必为奇异. 史志伟等采用岭回归方法求解输出权值^[6], 但该方法仅当方程病态时, 其结果优于最小二乘估计, 且岭参数在多数情况下与观测数据有关, 较难选择, 从而限制了其推广.

另外, ESN 通常对不含噪声的时间序列预测效果较好^[7], 而实际工业生产过程中, 大量的历史数据往往含有噪声, 若直接采用观测数据进行预测, 往往导致预测效果较差. Soltani 采用基于小波分解与重构的预测方法^[8], 但是小波分析需要预先确定基函数和分解尺度, 且缺乏自适应性, 一旦基波被选定就需用其对所有待分析的历史数据进行处理, 缺乏灵活性.

本文针对钢铁企业 BFG 发生量的预测问题, 结合上述对基于历史数据的时间序列预测方法的分析, 提出一种基于数据的 BFG 发生量预测方法: 改进回声状态网络预测方法. 首先通过经验模态分解 (Empirical mode decomposition, EMD) 将被分析的历史序列数据分解为多个固有模态函数 (Intrinsic mode function, IMF), 该过程基于历史数据本身的自适应分解, 无需选择基函数, 再将分解后的小尺度固有模态函数经低通滤波器自适应阈值去噪, 完成对序列数据的重构. 在预测过程中, 提出奇异值分解方法 (Singular value decomposition, SVD) 求取网络的输出权值, 通过选择适当参数舍弃较小的奇异值, 克服了线性回归算法的病态问题. 采用本文提出的方法对宝钢 4 座高炉煤气发生量进行了预测, 长期的现场数据实验表明除噪后的预测精度高于目前应用的其他方法.

1 问题描述

钢铁企业的生产过程会产生大量的副产煤气, 而此类副产品又是钢铁生产重要的二次能源, 其合理有效的再利用直接关系到企业的经济效益和能耗标准. 通常副产煤气包括高炉煤气、焦炉煤气和转炉煤气三种, 其中高炉煤气热值最低, 生产过程复杂, 且产出波动大, 一般情况下企业在对煤气调度和平衡调整不善时首先选择将高炉煤气作放散处理, 势必产生大量有害气体对环境造成污染.

以我国自动化程度较高的宝钢为例, 高炉煤气发生源为 4 座高炉, 其输配系统由管网、煤气柜、混合站、加压站组成; 用户主要包括焦炉、热轧加热炉、冷轧热处理、化产、合成、低压锅炉、发电厂等等. 图 1 为宝钢 BFG 系统管网图.

由于生产工艺的影响, BFG 的发生量经常发生波动, 四座高炉在产生 BFG 的同时, 自身热风炉也要消耗部分 BFG 用于鼓风机吹氧, 而热风炉换炉时自身使用量约为送风时的一半, 则单座高炉的 BFG 发生量约增加 $1.3 \times 10^5 \text{ m}^3/\text{h}$, 若四座高炉的波峰波谷大致重叠, BFG 发生量的落差可达 $5 \times 10^5 \text{ m}^3/\text{h}$, 将对煤气系统造成强烈的冲击. 因此现场需通过改变调节用户的煤气用量维持管网平衡, 若调节用户调节能力不能满足则需要采取放散进行调整. 目前企业对于 BFG 的合理再利用往往依靠生产人员的经验, 通过估计其发生量来实现对高炉煤气的平衡调度. 但由于其产出量波动大等特点, 仅仅凭借人工经验很难对其进行准确的定量估计. 因此对 BFG 发

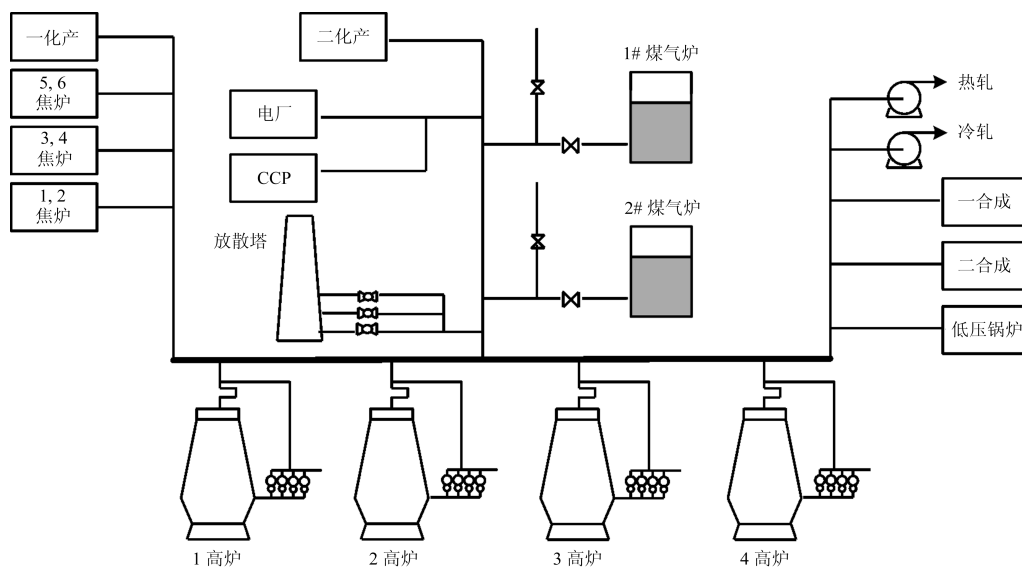


图 1 宝钢 BFG 系统管网图

Fig. 1 BFG network of Baosteel

生量定量预报的准确度直接关系到副产煤气能源的合理利用和有效调度, 否则调度不利造成的煤气放散将导致企业能耗成本的大大增加. 由于煤气的发生量与生产工况有关, 而国内钢铁企业很少有较详尽的各环能源计划来对其进行预估计, 因此依据生产计划对 BFG 发生量进行准确测算通常难以实现, 故采用时间序列的思想进行预测.

2 改进的回声状态网络

2.1 回声状态网络

回声状态网络 (ESN) 是一种新型递归神经网络, 在时间序列预测方面已表现出较好的性能^[1], 其内部的动态储备池 (DR) 包含了大量稀疏连接的神经元, 蕴含系统的运行状态, 并具有短期记忆功能, 而非线性系统的动态特性即由 DR 产生. ESN 示意图如图 2 所示.

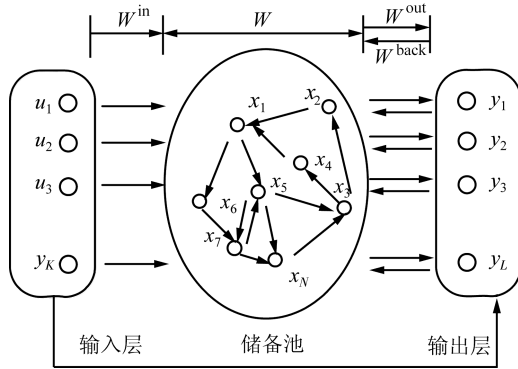


图 2 ESN 结构示意图

Fig. 2 Diagram of an echo state network

其基本方程可以写为

$$\mathbf{x}(k+1) = f(W^{\text{in}}\mathbf{u}(k+1) + W\mathbf{x}(k) + W^{\text{back}}\mathbf{y}(k)) \quad (1)$$

$$\mathbf{y}(k+1) = f^{\text{out}}(W^{\text{out}}(\mathbf{u}(k+1), \mathbf{x}(k+1), \mathbf{y}(k))) \quad (2)$$

其中, f 为 DR 内部激活函数, 通常采用 Sigmoid 型函数 $\tanh()$, 使 ESN 具有良好的非线性特性; $\mathbf{x}(k)$ 为 k 时刻 DR 的状态变量; $\mathbf{u}(k)$ 为 k 时刻系统输入向量; $\mathbf{y}(k)$ 为网络输出; $W^{\text{in}}(N \times K)$ 为输入权值矩阵; $W(N \times N)$ 为 DR 内部神经元的连接矩阵 (为使 DR 具有动态记忆能力, W 通常保持 1% ~ 5% 的稀疏连接, 且谱半径小于 1); $W^{\text{back}}(N \times L)$ 为输出神经元与 DR 的反馈矩阵; f^{out} 为输入与输出单元激活函数, 一般使用线性函数; $W^{\text{out}}(L \times (K + N + L))$ 为输出权值矩阵. W^{in} 、 W 、 W^{back} 三者在网络学习前构建, 而 W^{out} 是在学习结束后计算得出.

2.2 基于奇异值分解的改进 ESN

作者通过大量的仿真实验发现, 应用基本

ESN 对 BFG 发生量进行预测时, 网络输出权值 \hat{W}^{out} 的幅值有时较大, 导致预测结果恶化. 分析其原因是: DR 中的状态变量与期望输出之间为线性关系, 传统 ESN 采用线性回归算法确定输出权值 W^{out} , 即 $(\hat{W}^{\text{out}})^{\text{T}} = (M^{\text{T}}M)^{-1}M^{\text{T}}T$, 其中, $M = [\mathbf{x}^{\text{T}}(T_0), \mathbf{x}^{\text{T}}(T_0 + 1), \dots, \mathbf{x}^{\text{T}}(T)]^{\text{T}}$, $T = [\mathbf{y}(T_0), \mathbf{y}(T_0 + 1), \dots, \mathbf{y}(T)]^{\text{T}}$, 则 \hat{W}^{out} 的最小二乘估计的均方误差为

$$MSE(\hat{W}^{\text{out}}) = \sigma^2 \sum_{i=1}^t \frac{1}{\lambda_i} \quad (3)$$

式中, λ_i 为 $M^{\text{T}}M$ 的特征值. 当 M 呈病态时, $M^{\text{T}}M$ 接近奇异, 即至少有一个特征根接近于零, 于是导致了 $MSE(\hat{W}^{\text{out}})$ 误差较大. 史志伟等提出了岭估计来解决方程病态问题的方法^[6], 但该方法仅当方程病态时优于最小二乘估计, 且大多情况下岭参数与观测数据有关, 选择过程较困难, 限制了其应用.

针对上述分析, 本文提出一种改进的 ESN 预测方法, 采用奇异值分解求取网络输出权值, 选取合适的参数对小奇异值舍弃处理, 可消除方程病态解的干扰, 提高预测性能. 状态矩阵 M , 输出信号状态矩阵 T 和输出权值矩阵 W^{out} 存在如下关系:

$$T = M(W^{\text{out}})^{\text{T}} \quad (4)$$

由奇异值分解定理^[9], 矩阵 M 存在正交阵 $U_M \in \mathbf{R}^{(T-T_0+1) \times (T-T_0+1)}$, $V_M \in \mathbf{R}^{(K+N) \times (K+N)}$, 使得

$$U_M^{\text{T}} M V_M = \text{diag}\{\sigma_1, \dots, \sigma_p\} \quad (5)$$

其中, $p = \min\{T - T_0 + 1, K + N\}$, $\sigma_1 \geq \dots \geq \sigma_p \geq 0$, σ_i 是 M 的奇异值. 则 M 的奇异值分解为 $M = U_M \Sigma^{-1} V_M^{\text{T}}$, $\Sigma = \text{diag}\{\sigma_1 \dots \sigma_r \ 0 \dots 0\}$. 有 M 的广义逆为

$$M^+ = V_M \Sigma^{-} U_M^{\text{T}} \quad (6)$$

其中,

$$\Sigma^{-} = \begin{bmatrix} \Sigma^{-1} & 0 \\ 0 & 0 \end{bmatrix}_{(K+N) \times (T-T_0+1)}$$

$$\Sigma^{-1} = \text{diag}\{\sigma_1^{-1}, \dots, \sigma_r^{-1}\}$$

对于式 (4) 按广义 LS 原理有 $(\hat{W}^{\text{out}})^{\text{T}} = M^+T$, 将式 (6) 代入则

$$(\hat{W}^{\text{out}})^{\text{T}} = M^+T = V_M \Sigma_M^{-} U_M^{\text{T}} T \quad (7)$$

即采用 SVD 方法对 ESN 的输出权值估计为

$$\hat{W}^{\text{out}} = \left(\sum_{j=1}^r \left(\frac{u_j^T T}{\sigma_j} \right) v_j \right)^T \quad (8)$$

$$w_k = \sum_{j=1}^r \frac{v_{kj}}{\sigma_j} \sum_{i=1}^{T-T_0+1} u_{ij} T_i, \quad k = 1, \dots, K + N \quad (9)$$

由式 (9) 可知, 较小的奇异值会使 LS 求解失真. 为此, 本文针对奇异值分解的结果提出选取适当参数 δ ($\sigma_1 \geq \dots \geq \sigma_r > \delta > \sigma_{r+1} \geq \dots \geq \sigma_{T-T_0+1}$), 将奇异值小于 δ 的部分舍弃处理的方法. 其优点在于通过舍弃小奇异值, 将近似相关的问题转化为近似不相关, 避免了输出权值矩阵近似相关性的影响. 本文选择 $\delta = \mu \|M\|_{\infty}$, μ 为计算机精度.

所提出的改进 ESN 预测方法在稳定性方面, 可以通过预先设定 DR 权值矩阵的谱半径来保证; 在网络训练方面, 其输出权值的确定是唯一且全局最优的, 避免了传统神经网络普遍存在的局部最小问题; 另外采用 SVD 方法求取网络输出权值, 无论方程良态或病态甚至秩亏都可使解的结果达到最优; 同时该方法避免了传统递归神经网络求时序偏微分的过程, 简化了网络训练.

3 基于经验模态分解的消噪方法

BFG 发生量的历史数据常常含有噪声, 经作者仿真实验发现, 直接采用提出的改进 ESN 进行预测, 其结果仍受噪声影响较大. 为了解决这一实际问题, 本文采用经验模态分解法 (EMD)^[10], 在预测前先对数据作消噪处理. 传统 EMD 消噪算法, 将小尺度本征模函数 (Intrinsic mode function, IMF) 作为噪声消除^[11-12], 易导致将有用信号同时消除的情况. 为此, 本文提出仅对小尺度 IMF 进行自适应除噪的方式. 在此过程中, 考虑到噪声水平较高时, 相邻信号的标准差较大, 故将此标准差作为判别噪声水平的标准, 对含噪高的数据采用低通滤波器除噪, 从而保留小幅值有用信号.

消噪算法步骤如下:

步骤 1. 找出信号 $X(t)$ 的所有局部极大、极小值点, 用三次样条插值函数拟合出信号的上包络线和下包络线, 求出两包络线的平均值 m_1 , 将 $X(t)$ 与 m_1 之差记为 h_1 ($h_1 = X(t) - m_1$). 判断 h_1 是否为 IMF, 若不是, 则重复上述分解过程对其进一步分解, 第 k 步的结果 h_{1k} 可写成 $h_{1(k-1)} - m_{1k} = h_{1k}$. 定义 $h_{1k} = c_1$, 则 c_1 即为从原始数据中得到的第一个 IMF.

步骤 2. 计算 $r_1 = X(t) - c_1$, 将 r_1 作为分解数据, 重复上述筛分过程, 当剩余分量小于预定值或为

单调函数时停止, 最终将信号分解成 n 个 IMF 和一个剩余分量 r_n , 即 $X(t) = \sum_{i=1}^n c_i + r_n$.

步骤 3. 选择前 k 个 IMF 分量进行消噪, 采用自适应阈值 T_i ($T_i = (i-1)^2 \sigma_i / n^2, 1 \leq i \leq k$), 其中 σ_i 表示第 i 尺度信号的标准差.

步骤 4. 计算第 i 个信号相邻信号的标准差 σ_i^j , 若 $\sigma_i^j > T_i$, 则采用低通滤波器去噪.

步骤 5. 将消噪后的 IMF 分量和其余的 $n-k$ 个分量重构, 得到消噪后的时间序列信号.

4 实验及运行效果

为了验证所提出的基于数据的高炉煤气发生量预测方法的有效性, 选取上海宝钢煤气系统中 4 座高炉 BFG 发生量的数据进行建模和验证. 以 1 号高炉为例, 随机选取某时间段的 500 个点进行分析 (采样频率 1 分钟), 如图 3 所示. 由图 3 可知, BFG 发生量的时间序列数据随机波动较大. 对数据进行 EMD 分解的时间与幅值的对应关系如图 4 (见下页) 所示, 共得到 15 个 IMF, 最后一个为剩余量. 采用低通滤波器对分解后的前 3 个 IMF 去噪, 经数据重构后的结果如图 5 (见下页) 所示. 由图 5 中可以看出, 本文方法在消噪的同时较好地保留了有用信号, 除噪效果较好.

采用提出的基于奇异值分解的 ESN 方法对去噪重构的 BFG 发生量数据进行预测. 选择 ESN 中储备池维数为 100, 保持 1% 的稀疏连接, 连接权值矩阵的谱半径为 0.75, DR 内部激活函数为 $\tanh()$, 输出单元采用线性激活函数, 训练样本为上述去噪后的 500 个点, 预测后 60 分钟内 1 号高炉 BFG 发生量, 结果如图 6 (a) (见第 736 页) 所示, 图中圆圈为实际生产数据, 星号为预测值. 采用同样方法预测同一时段 2~4 号高炉 BFG 发生量的结果如图 6 (b)~(d) 所示.




图 3 宝钢 1 号高炉 BFG 发生量

Fig. 3 BFG output of No. 1 blast furnace in a certain time period




图4 原始数据的 EMD 分解结果

Fig. 4 Empirical mode decomposition of original data




图5 EMD 去噪重构后的结果

Fig. 5 Re-constructed signals by empirical mode decomposition

为了说明所提方法的有效性, 将其与误差反向传播 (Back propagation, BP) 方法、径向基函数 (Radial basis function, RBF) 方法以及原始 ESN 方法的预测结果进行比较. 以宝钢 2008 年 5 月 13 日 12:00 ~ 12:59 时, 各高炉 BFG 发生量为实验数据, 4 种方法的预测结果如图 7(a) ~ (d) (见下页) 所示, 选取归一化均方根误差 (Normalized root mean square error, NRMSE)、均方误差 (Mean square error, MSE) 和平均绝对百分比误差 (Mean absolute percentage error, NRMSE) 作为判断预测效果的依据, 其计算公式为

$$NRMSE = \sqrt{\frac{1}{T \|y_d\|^2} \sum_{t=1}^T (y(t) - y_d(t))^2} \quad (10)$$

$$MSE = \frac{1}{T} \sum_{t=1}^T (y(t) - y_d(t))^2 \quad (11)$$

$$MAPE = \frac{100}{T} \sum_{t=1}^T \frac{|y(t) - y_d(t)|}{y_d(t)} \quad (12)$$

其中, T 为预测样本点的个数, $y(t)$ 为预测值, $y_d(t)$ 为样本实际值. 各方法预测精度如表 1 (见第 737 页). 由表中数据可知, 本文提出的方法在对宝钢 4 座高炉 BFG 发生量预测时, 以上 3 种测算精度均高于其他方法. 分析其原因: BP 和 RBF 属于静态神经网络模型, 节点连接形式固定, 网络性能受隐层节点影响很大, 此外其核心思想是通过梯度下降的方式来进行网络学习, 易存在局部极小问题, 从而造成预测误差偏大. ESN 利用固定权值的 DR 来存储从教师信号得到的信息, 通过计算从 DR 状态空间到输出节点线性回归所需要的输出权值来达到最小化训练误差, 避免了传统网络存在的局部最小问题. 但原始 ESN 方法适用于不含噪声的预测, 本文在对实际问题预测时首先采用 EMD 方法对数据进行自适应除噪, 减小了噪声对 ESN 预测精度的影响, 同时采用 SVD 方法求解网络输出权值, 克服方程的病态解问题, 进一步提高了预测精度.

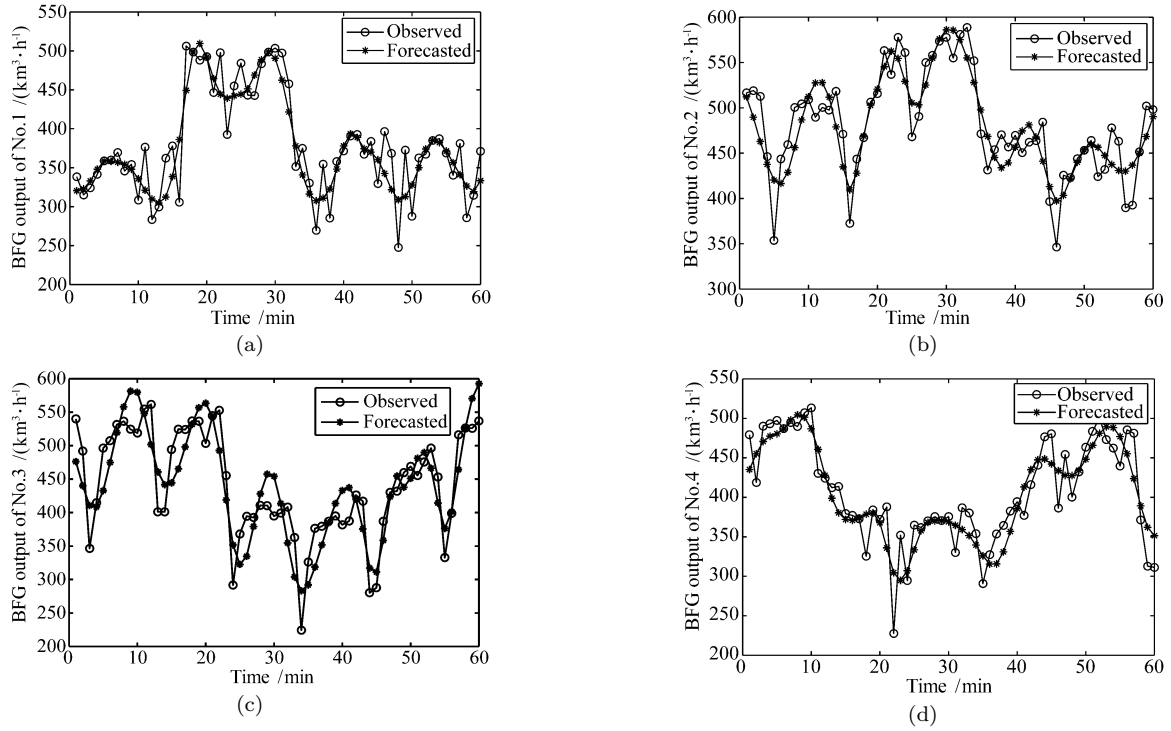


图6 宝钢4座高炉BFG发生量预测结果
Fig.6 Prediction results of BFG output in Baosteel

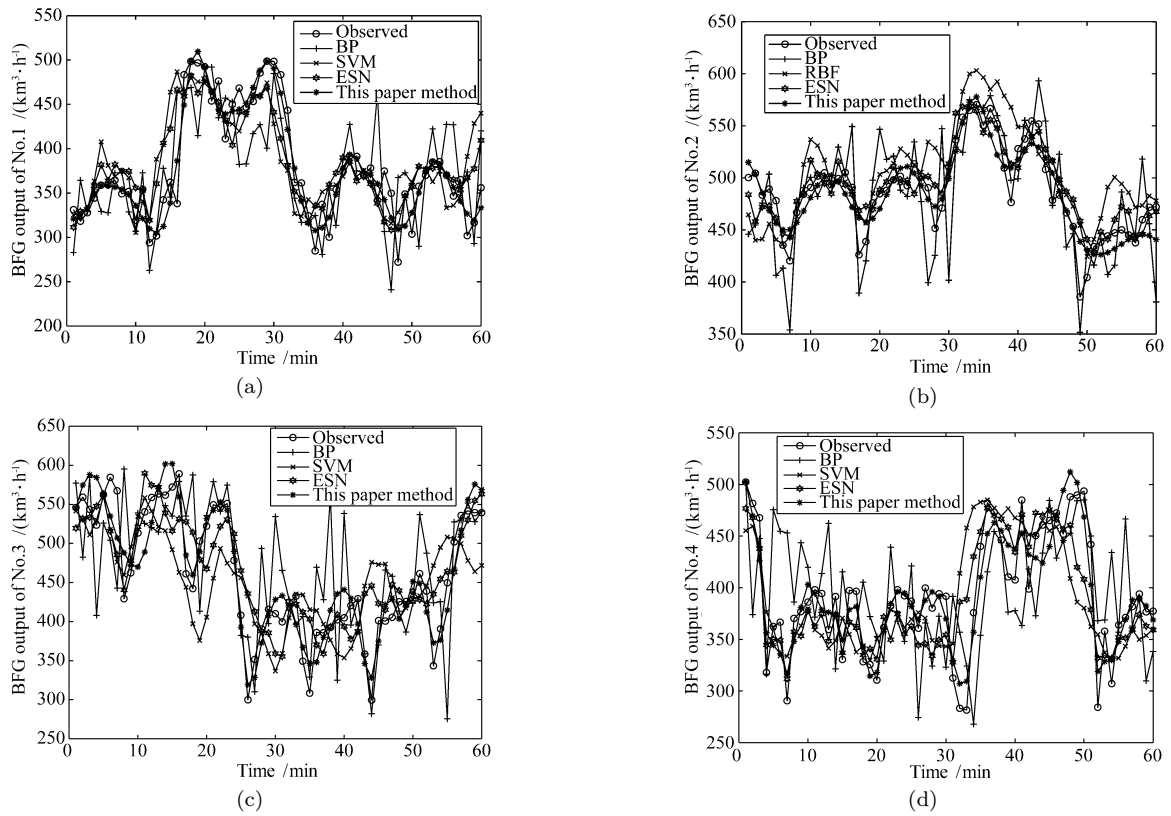


图7 四种方法对各高炉BFG发生量的预测结果
Fig.7 Prediction results of BFG output using four methods

表 1 宝钢各高炉 BFG 发生量预测误差比较
Table 1 Prediction errors comparison of BFG output using four methods

预测方法	预测对象	NRMSE	MSE	MAPE (%)
BP	1 号高炉	0.8953	1575.6205	11.0069
	2 号高炉	0.73196	1420.4001	6.0137
	3 号高炉	1.42595	2660.4778	14.7471
	4 号高炉	1.1239	1828.3902	13.43
RBF	1 号高炉	0.84915	1147.1764	6.4906
	2 号高炉	0.65034	981.1209	5.6527
	3 号高炉	1.1327	2221.1976	12.0461
	4 号高炉	0.98015	2571.2525	10.1721
ESN	1 号高炉	0.66796	628.4878	5.4726
	2 号高炉	0.48902	433.156	4.4059
	3 号高炉	0.65348	994.7694	7.8275
	4 号高炉	0.58587	1057.936	6.4139
本文方法	1 号高炉	0.3679	306.2257	3.6496
	2 号高炉	0.30329	268.3751	3.0289
	3 号高炉	0.35487	508.7191	4.6961
	4 号高炉	0.30375	456.4997	4.3717

采用上述预测方法, 开发了 BFG 发生量预测系统, 系统的试运行效果得到了宝钢能源部调度专家的肯定. 利用该系统, 调度人员可以实时准确地获得整个企业 BFG 系统的发生量, 从而为钢铁企业煤气系统的实时调度、能源平衡调整提供了可靠的决策支持, 进而提高钢铁企业节能降耗水平.

5 结论


以钢铁企业高炉煤气系统为背景, 提出基于数据的改进回声状态网络预测方法对高炉煤气发生量进行预测. 该方法避免了传统神经网络局部极小、收敛速度慢的缺点, 网络输出权值的确定采用奇异值分解的方法, 克服了方程的病态解问题. 此外, 针对高炉煤气历史数据含噪高的特点采用经验模态分解方法将预测序列分解为若干个独立的 IMF 及余项, 然后将分解后小尺度固有模态函数经自适应阈值去噪, 并重构后进行建模. 最后, 采用本文提出的方法对上海宝钢 4 座高炉的 BFG 发生量进行预测, 得到了较为满意的结果, 为实现煤气管网平衡调整提供了决策支持作用.

References

1 Jaeger H. Tutorial on Training Recurrent Neural Networks, Covering BPTT, RTRL, EKF and "Echo State Network"

Approach, Technical Report GMD Report 159, German National Research Center for Information Technology, German, 2002

- Jaeger H. Adaptive nonlinear system identification with echo state networks. *Advances in Neural Information Processing Systems 15*. Cambridge: The MIT Press, 2003. 593–600
- Jaeger H, Haas H. Harnessing nonlinearity: predicting chaotic systems and saving energy in wireless communication. *Science*, 2004, **304**(5667): 78–80
- Kountouriotis P A, Obradovic D, Su L G, Mandic D P. Multi-step forecasting using echo state networks. In: *Proceedings of the International Conference on Computer as a Tool*. Belgrade, Serbia: IEEE, 2005. 1574–1577
- Jaeger H. Reservoir riddles: suggestions for echo state network research. In: *Proceedings of the International Joint Conference on Neural Networks*. Washington D. C., USA: IEEE, 2005. 1460–1462
- Shi Zhi-Wei, Han Min. Ridge regression learning in ESN for chaotic time series prediction. *Control and Decision*, 2007, **22**(3): 258–267
(史志伟, 韩敏. ESN 岭回归学习算法及混沌时间序列预测. *控制与决策*, 2007, **22**(3): 258–267)
- Prokhorov D. Echo state networks: appeal and challenges. In: *Proceedings of the International Joint Conference on Neural Networks*. Washington D. C., USA: IEEE, 2005. 1463–1466
- Soltani S. On the use of the wavelet decomposition for time series prediction. *Neurocomputing*, 2002, **48**(1-4): 267–277
- Golub G H, van Loan C F. *Matrix Computations*. Baltimore: The Johns Hopkins University Press, 1983
- Huang N E, Shen Z, Long S R, Wu M C, Shih H H, Zheng Q A. The empirical mode decomposition method and the Hilbert spectrum for nonstationary time series analysis. *Proceedings of the Royal Society A*, 1998, **454**(1971): 903–995
- Flandrin P, Rilling G, Goncalves P. Empirical mode decomposition as a filter bank. *IEEE Signal Processing Letters*, 2004, **11**(2): 112–114
- Wu Z H, Huang N E. A study of the characteristics of white noise using the empirical mode decomposition method. *Proceedings of the Royal Society A*, 2004, **460**(2046): 1597–1611



刘颖 大连理工大学控制理论与控制工程博士研究生. 2004 年获得大连理工大学自动化系学士学位. 主要研究方向为一体化生产计划与调度、系统仿真建模、智能优化算法及应用、人工神经网络. E-mail: liuying8227@163.com
(LIU Ying Ph. D. candidate in control theory and control engineering at

Dalian University of Technology. She received her bachelor degree from the Department of Automation, Dalian

University of Technology in 2004. Her research interest covers integrated production planning and scheduling problem, system simulation modeling, intelligent optimization and application, and artificial neural network.)



赵 珺 大连理工大学信息与控制研究中心讲师。2008 年获得大连理工大学自动化系博士学位。主要研究方向为生产计划与调度、现代集成制造系统、工业生产一体化优化技术。本文通信作者。

E-mail: jun.z@163.com

(**ZHAO Jun** Lecturer at the Research Center of Information and Control,

Dalian University of Technology. He received his Ph. D. degree from Department of Automation, Dalian University of Technology in 2008. His research interest covers industrial production scheduling, computer integrated manufacturing system, and intelligent optimization and application. Corresponding author of this paper.)



王 伟 大连理工大学信息与控制研究中心教授。1988 年获得东北大学博士学位。1990~1992 年为挪威科技大学电气工程系博士后。主要研究方向为自适应控制、现代集成制造系统和流程工业过程控制。

E-mail: wangwei@dlut.edu.cn

(**WANG Wei** Professor at the Re-

search Center of Information and Control, Dalian University of Technology. He received his Ph. D. degree from Northeast University in 1988. He was a postdoctor at Division of Engineering Cybernetics, Norwegian Science and Technology University during 1990 to 1992. His research interest covers adaptive control, computer integrated manufacturing system, and computer control of industrial process.)



吴毅平 上海宝信软件股份有限公司资深技术总监。主要研究方向为钢铁自动化技术。

E-mail: wuyiping@baosight.com

(**WU Yi-Ping** Chief technology officer at Shanghai Baosight Software Co., Ltd. His research interest covers automation technology in iron and steel

enterprise.)



陈伟昌 上海宝钢股份宝钢分公司能源环保部工程师。主要研究方向为能源调度及管理。

E-mail: chenwc@baosteel.com

(**CHEN Wei-Chang** Engineer at the Energy Center, Shanghai Baosteel Co., Ltd. His research interest covers energy source scheduling and manage-

ment.)