

GA-ELM 在硫铁矿制酸尾气 SO₂ 浓度预测的应用^①

黄远红, 黄清宝

(广西大学 电气工程学院, 南宁 530004)

摘要: 基于对整个生产流程的管控, 使硫铁矿生产硫酸尾气的 SO₂ 浓度达标排放, 提出运用 GA-ELM 对制酸尾气 SO₂ 浓度进行建模预测. 在硫铁矿制酸的生产过程中采集对尾气 SO₂ 浓度影响较大的关键点参数, 运用 GA-ELM 神经网络对烟气制酸尾气 SO₂ 浓度进行预测. 该方法在某厂实际检验, 其预测结果与实际数据吻合度较高, 对于调整和优化工艺指标和尾气达标排放起到很好的指导作用.

关键词: 尾气排放; SO₂ 浓度; 极限学习机; 预测

引用格式: 黄远红, 黄清宝. GA-ELM 在硫铁矿制酸尾气 SO₂ 浓度预测的应用. 计算机系统应用, 2017, 26(10): 251-254. <http://www.c-s-a.org.cn/1003-3254/5744.html>

Application of ELM in Prediction of SO₂ Concentration of the Tail Gas in Producing Acid with Pyrite

HUANG Yuan-Hong, HUANG Qing-Bao

(School of Electrical Engineering, Guangxi University, Nanning 530004, China)

Abstract: Based on the control of the whole production process, to make emissions of SO₂ concentration conform to the standards in the production of sulfuric acid with pyrite, we propose prediction for SO₂ concentration of tail gas with GA-ELM modeling. In the production of sulfuric acid by pyrite, we collect the key parameters with greater influence on the SO₂ concentration of exhaust gas, and use GA-ELM neural network to predict the SO₂ concentration while producing acid with exhaust gas. The method is tested in a factory, and the predicted results are highly identical with actual data. It plays an important guiding role for the adjustment and optimization of process index and exhaust emissions conforming to the standards.

Key words: exhaust emission; concentration of SO₂; GA-ELM; prediction

硫酸是化学工业的重要产品, 号称“工业之母”, 其广泛应用于冶金、化肥、石化、纺织和国防等许多工业部门; 但硫铁矿制酸尾气^[1]的 SO₂ 达标排放却是我国 SO₂ 污染控制和减排的重点^[2], 但由于生产线流程长, 参数众多且时效性、准确性、可靠性较差, 在发现尾气 SO₂ 浓度超标时再经操作人员综合、分析、判断后采取措施, 往往已造成长时间超标排放的恶果, 环境损失难以估量.

极限学习机 (Extreme learning machine, ELM,

2004 年由黄广斌提出)^[3]虽有学习速度快, 泛化能力强的特点, 但由于连接权值、阈值是随机选择, 网络训练效果不是很好^[4]; 提出利用遗传算法 (Genetic algorithms, GA) 优化^[5]得到 ELM 网络最优的初始权值、阈值, 二者结合的新型算法 (简称 GA_ELM 算法); 并采集实际生产过程对尾气 SO₂ 浓度有重大影响的关键点参数作为样本, 用 GA-ELM 神经网络对尾气 SO₂ 浓度进行快速建模, 根据预测结果对工艺流程参数提前干预, 优化、调整, 能够大大地减少或避免尾气 SO₂ 浓度超标

① 收稿时间: 2016-06-29; 采用时间: 2016-08-08

事故发生,在实际生产中有很好的效果。

1 理论基础

1.1 极限学习机理论基础

极限学习机基本思路^[3]: 极限学习机是一种简单易用、有效的单隐层前馈神经网络 (Single-hidden layer feedforward networks), 隐含层只有一层结点, 网络结构模型如图 1。

如图 1 是一个典型的 SLFN 网络: 输入层有 n 个输入变量, 中间隐含层有 l 个神经元, 输出层有 m 个神经元; 设输入层与隐含层间的连接权值为 ω , 隐含层与输出层的连接权值为 β , 隐含层神经元阈值为 b ; 网络有 Q 个样本, 输入矩阵 X 和输出矩阵 Y , 隐含层神经元激励函数为 $g(x)$, 由图 1 网络输出 T 为:

$$T = [t_1, t_2, \dots, t_Q]_{m \times Q} \quad (1)$$

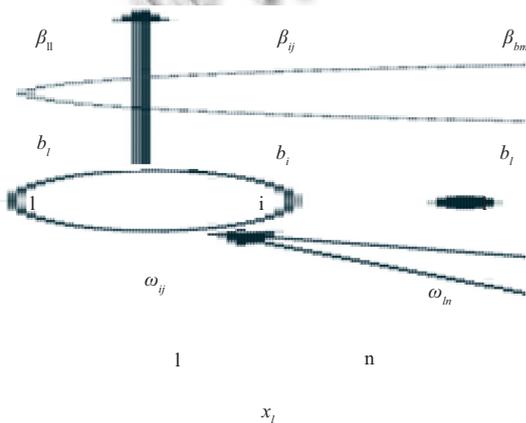


图 1 单隐层前馈神经网络 (SLFNs) 结构模型图

式 (1) 可表示为:

$$H\beta = T' \quad (T' \text{ 为矩阵 } T \text{ 的转置}) \quad (2)$$

当激活函数 $g(x)$ 无限可微时, ELM 的参数无需全部调整, 只需 ω 和 b 随机选择, 且在过程中保持不变) 通过求解以下方程组的最小二乘解获得:

$$\min_{\beta} \|H\beta - T'\|, \quad (3)$$

解为:

$$\beta = H^+ T' \quad (4)$$

式中 H^+ 为隐含层输出矩阵 H 的 Moore-Penrose 广义逆。

1.2 遗传算法理论

遗传算法^[5](Genetic algorithms, GA) 是 1962 年由美

国 Michigan 大学 Holland 教授提出的模拟自然界遗传机制和生物进化论而成的一种并行随机搜索最优化方法, 用“优胜劣汰, 适者生存”的生物进化原理进行神经网络参数的优化, 通过遗传的选择、交叉、变异等对个体进行筛选, 保留适应度优秀的个体, 同时新的群体又继承上一代群体的优秀基因, 从而得到最优的个体。

1.3 遗传算法优化极限学习机 (GA-ELM) 模型

遗传算法-极限学习机神经网络 (GA-ELM) 原理是通过 GA 对 ELM 的权值、阈值进行优化, 组建最优的 ELM 网络结构进行建模; 主要分为 ELM 网络确定、遗传算法优化和 ELM 神经网络的训练和预测等三大部分; 具体流程如图 2。

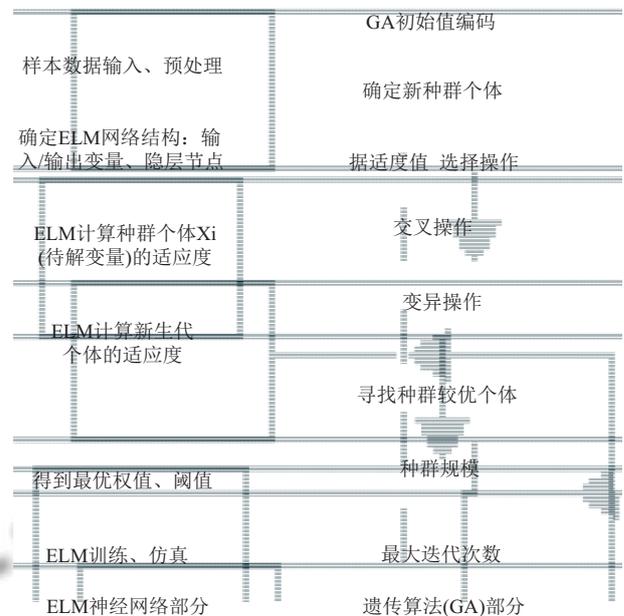


图 2 GA-ELM 算法流程

1.4 模型评价指标

(1) 均方根误差 (Rmse)

衡量仿真值与样本值之间 (点对点) 的偏差, 公式为:

$$Rmse = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (5)$$

式中, i 为样本个体; n 为样本总数; y_i 为仿真输出值; \hat{y}_i 样本输出量。

(2) 相关系数 (R^2)

表示两个变量之间的紧密程度, 计算公式如下:

$$R^2 = \frac{n \sum_{i=1}^n y_d y - \sum_{i=1}^n y_d \cdot \sum_{i=1}^n y}{\sqrt{n \sum_{i=1}^n y_i^2 - \left(\sum_{i=1}^n y_i\right)^2} \cdot \sqrt{n \sum_{i=1}^n y^2 - \left(\sum_{i=1}^n y\right)^2}} \quad (6)$$

2 ELM 应用模型的建立

2.1 工艺过程简介

某厂硫酸生产工艺流程^[6](无脱硫装置)如图3。

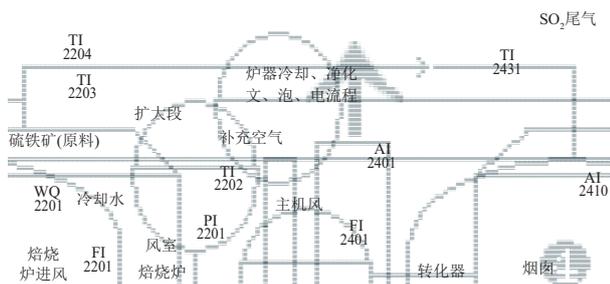


图3 硫铁矿为原料生产硫酸的原则流程图

流程简介: 原料硫铁矿经计量皮带秤(位号 WQ2201)进入焙烧炉, 由鼓风机鼓风(风量 FI2201)进入风室(压力 PI2201)的空气与硫铁矿沸腾燃烧; 在炉内(主要扩大层)产生带 SO₂ 的炉气, 经冷却、净化、干燥, 由主风机提压, 炉气(流量 FI2401, SO₂ 浓度分析 AI2401), 经过转化器 1, 2, 3, 4 段把 SO₂ 转化成 SO₃ 并用浓硫酸进行循环吸收(两转两吸), 产出合格硫酸; 尾气(含 SO₂) 经 4 段, 由烟囱排大气中。

2.2 影响尾气 SO₂ 浓度的参数

关键参数: 原料硫铁矿的投入量(WQ2201), 焙烧炉进风量(FI2201)

重要参数: 风室静压(PI2201), 过渡段温度(TI2202), 扩大段温度(TI2203), 燃烧炉出口温度(TI2204), 主风机出口风量(FI2401), 炉气 SO₂ 浓度分析以及转化器四段出口温度(TI2431)。

3 仿真实验

3.1 仿真数据的选取

由于生产流程较长, 影响尾气 SO₂ 浓度的因素相关性很强, 在本次实验中选取以上全部 9 个参数样本的输入变量, 力求能够真实地反映尾气 SO₂ 浓度变化。

3.2 样本数据的预处理

数据是直接采集生产中仪表测量的真实数据

(2148 组), 数据离散性、突变和误差相对较大, 本实验采用小波包降噪^[7,8]和一维中值滤波对数据进行预处理。

(1) 主成分(PCA)分析^[9]

由于有 9 个输入变量, 维数较大, 对后面的网络运算速度有很大的影响; 首先做 PCA 分析以降低维度, 但在程序运行结果中 9 个变量的贡献率在 (6.8%—21.2%) 间, 无法降维。

(2) 小波包降噪

为了减少失真, 采用全局阈值默认(正交小波函数为 shannon 小波)的小波包降噪。

(3) 一维中值滤波^[10]处理

用窗宽 30, 分列做一维中值滤波处理。

(4) 样本数据的划分

样本数据等间隔抽取 3/4 数据(1611 组)作为训练样本进行拟合, 另外的 1/4 数据(537 组)为测试样本进行泛化实验。

(5) 训练样本、测试样本的标准归一化处理。

3.3 ELM 神经网络的相关参数确定

(1) 隐含层神经元个数

在本次实验中, 虽然样本训练个数达 1611 个, 但加入遗传算法后, 在取较小的神经元个数的情况下就能达到较好的效果, 时间大大地缩短。

(2) 设定输入层与隐含层间的初始连接权值 ω 和隐含层神经元的阈值 b 。

利用遗传算法和 ELM 网络进行训练, 根据最小适应度值来寻找最佳的连接权值 ω 和阈值 b , 作为最终的 ELM 网络最佳参数进行仿真。

(3) 隐含层神经元的激活函数: 选择无限可微函数。

3.4 遗传算法的相关参数确定

主要元素: 种群规模, 个体长度、进化次数以及交叉概率、变异概率等。

交叉概率: 交叉操作时, 选择种群中的二个个体, 按拟定的概率交叉而得到新个体; 据一般文章认为, 交叉概率的大小对于相对简单的优化问题影响不大, 本文选取交叉概率=0.5 是经多次运行, 在 MSE 基本相近的情况下, 以运行时间相对短的标准来确定。

变异概率: 种群中随机选择一个个体, 按拟定概率变异达到一个新个体; 变异概率=0.3 是运用本文数据多次运行, 试凑法确定。

3.5 仿真实验

(1) 迭代次数对网络的影响: 其中, 交叉概率 0.5, 变异概率 0.3, 隐层神经元个数 25.

表1 迭代(进化)次数对网络仿真性能对比结果

迭代次数	训练时间(s)	拟合误差(mse)	拟合的相关系数(R ²)	泛化误差(mse)	泛化的相关系数(R ²)
10	1.0315	0.6546	0.7485	1.1434	0.7422
50	3.7500	0.6474	0.5740	1.1400	0.7439
100	6.8440	0.6723	0.7347	1.2069	0.7134

(2) 种群规模数对网络的影响: 其中, 迭代次数 50, 交叉 0.5, 变异 0.3, 神经元个数 25.

表2 种群规模数对网络仿真性能对比结果

种群规模数	训练时间(s)	拟合误差(mse)	拟合相关系数(R ²)	泛化误差(mse)	泛化相关系数(R ²)
10	3.4380	0.6711	0.7357	1.2160	0.7097
15	5.140	0.6563	0.7472	1.1399	0.7438
200	17.1250	0.6854	0.7242	1.2019	0.7152

(3) 隐层神经元个数对网络的影响: 其中, 迭代次数 50, 种群规模 10, 交叉概率 0.5, 变异概率 0.3.

表3 隐层神经元数对网络仿真性能对比结果

隐层神经元个数	训练时间(s)	拟合误差(mse)	拟合相关系数(R ²)	泛化误差(mse)	泛化相关系数(R ²)
50	13.765	0.5686	0.8102	1.0290	0.7913
120	58.485	0.4112	0.9008	0.8107	0.8712
200	148.438	0.3191	0.9402	0.8089	0.8753

(4) 普通 ELM 网络与 GA-ELM 的仿真对比.

表4 普通 ELM 与 GA-ELM 网络性能对比结果

神经网络类型	神经元个数	训练时间(s)	拟合误差(mse)	拟合相关系数(R ²)	泛化误差(mse)	泛化相关系数(R ²)
ELM	120	0.032	3.2692	0.1007	5.6624	0.0681
ELM	500	4.063	2.1641	0.2306	4.2494	0.1033
GA-ELM	50	13.7650	0.5686	0.8102	1.0290	0.7913
GA-ELM	120	58.4850	0.4112	0.9008	0.8107	0.8712

从上述的比对数据来看, 如果用单纯的 ELM 作为仿真该案, 效果非常差, 基本处于弱相关的状态, 从一定意义上说, 根本就不能用普通 ELM 进行该案的仿真, 即使它的运算时间短(因为 GA-ELM 运行时间受迭代次数、种群规模的大小影响很大).

(5) 最佳参数(隐含层神经元个数 120, 权值、阈值由 GA+ELM 选择)的 ELM 对尾气 SO₂ 浓度拟合、泛化对比结果图如图 4、图 5.

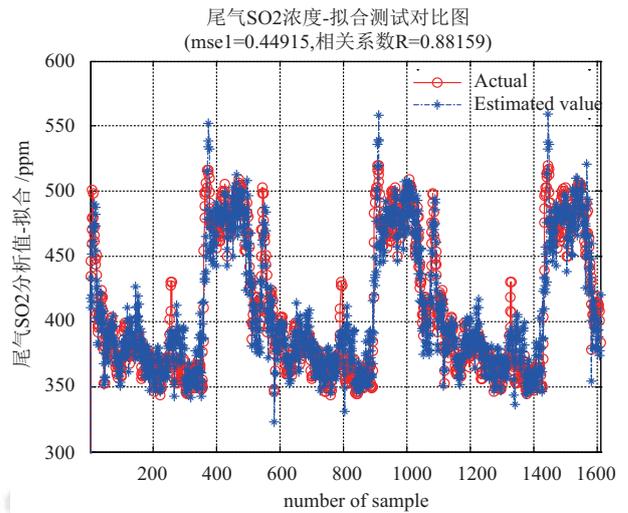


图4 GA-ELM 对制酸硫酸尾气 SO₂ 浓度拟合图

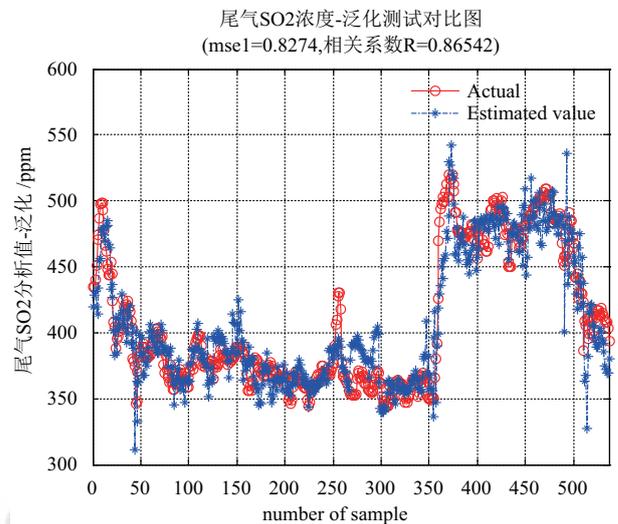


图5 GA-ELM 对制酸硫酸尾气 SO₂ 浓度泛化图

(6) 仿真结果分析

经过比对分析, GA-ELM 都能较好地对实际生产工况进行仿真; 遗传进化次数、种群规模因素对仿真结果影响不大, 但二者与运算时间成正比. 隐含层神经元个数对整个网络影响最大: 个数越多, 网络均方根误差越小, 相关系数越大, 但运行时间较长.

4 结束语

GA-ELM 神经网络具有较好的鲁棒性、泛化能力; 通过遗传算法寻找最优的网络连接权值和阈值, 克服了普通 ELM 连接权值和阈值的随意性所带来的网络仿真的不确定性, 同时由于 ELM 神经元个数(一般取样

本数) 的大大减少, 使得网络训练时间大大缩短; 在实际生产过程中面对高维、数据波动大以及数据量大、工况复杂多变的情况下准确预测, 对生产、环保监测等有特别重要的现实意义。

参考文献

- 1 刘少武, 齐焉, 赵树起, 等. 硫酸生产技术. 南京: 东南大学出版社, 1993, 12: 771-771.
- 2 程婷, 刘洁岭, 蒋文举. 我国硫酸工业尾气脱硫技术现状分析. 四川化工, 2013, 16(1): 45-48.
- 3 Huang GB, Zhu QY, Siew CK. Extreme learning machine: Theory and applications. *Neurocomputing*, 2006, 70(1-3): 489-501. [doi: [10.1016/j.neucom.2005.12.126](https://doi.org/10.1016/j.neucom.2005.12.126)]
- 4 孙鑫. 极限学习机结构优化及其应用研究[硕士学位论文]. 南宁: 广西大学, 2014: 5-8.
- 5 史峰, 王辉, 郁磊, 等. MATLAB 智能算法 30 个案例分析. 北京: 北京航空航天大学出版社, 2011: 290-295.
- 6 崔恩选. 化学工艺学. 北京: 高等教育出版社, 1990: 137-162.
- 7 孙延奎. 小波分析及其应用. 北京: 机械工业出版社, 2005: 253-256.
- 8 胡昌华, 张军波, 夏军, 等. 基于 MATLAB 的系统分析与设计-4-小波分析. 西安: 西安电子科技大学出版社, 1999: 258-261.
- 9 谢中华. MATLAB 统计分析与应用: 40 个案例分析. 北京: 北京航空航天大学出版社, 2010: 354-359.
- 10 徐明远, 刘增力. MATLAB 仿真在信号处理中的应用. 西安: 西安电子科技大学出版社, 2007: 226-235.