

# 控制与决策

Control and Decision

基于改进GNG算法的燃煤锅炉数据动态特征分析与控制

吴永明, 陈琳升, 李少波

引用本文:

吴永明, 陈琳升, 李少波. 基于改进GNG算法的燃煤锅炉数据动态特征分析与控制[J]. *控制与决策*, 2021, 36(8): 1855–1861.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2019.1343>

---

## 您可能感兴趣的其他文章

Articles you may be interested in

[基于局部信息增量与MPLS的质量相关故障检测方法](#)

Quality-related fault detection method based on local information increment and MPLS

*控制与决策*. 2021, 36(7): 1647–1654 <https://doi.org/10.13195/j.kzyjc.2019.1402>

[CART决策树方法在煤电厂节能降耗中的应用](#)

Application of CART decision tree model in reducing coal consumption in coal power plant

*控制与决策*. 2021, 36(5): 1232–1238 <https://doi.org/10.13195/j.kzyjc.2019.1272>

[基于条件对抗生成孪生网络的目标跟踪](#)

Conditional generative adversarial siamese networks for object tracking

*控制与决策*. 2021, 36(5): 1110–1118 <https://doi.org/10.13195/j.kzyjc.2019.1215>

[基于自适应混合核典型变量分析的工业过程质量相关故障检测](#)

Quality-related fault detection for industrial processes based on adaptive mixed kernel canonical variable analysis

*控制与决策*. 2021, 36(4): 801–807 <https://doi.org/10.13195/j.kzyjc.2020.0690>

[基于矩阵的双论域模糊概率粗糙集增量更新算法](#)

Incremental updating of fuzzy probability rough sets over two universes based on matrix method

*控制与决策*. 2021, 36(3): 553–564 <https://doi.org/10.13195/j.kzyjc.2019.0692>

# 基于改进GNG算法的燃煤锅炉数据动态特征分析与控制

吴永明<sup>1,2,3</sup>, 陈琳升<sup>1,2†</sup>, 李少波<sup>1,2,3</sup>

(1. 贵州大学 现代制造技术教育部重点实验室, 贵阳 550025; 2. 贵州大学 公共大数据国家重点实验室, 贵阳 550025; 3. 贵州大学 机械工程学院, 贵阳 550025)

**摘要:** 数据动态特征分析与控制技术是一种重要的数据挖掘手段, 燃煤锅炉数据具有明显时序性和漂移性等特点, 针对目前数据跟踪与监督算法大多缺乏动态性、实时性和稳定性等问题, 设计一种基于改进生长神经气模型(GNG)的自适应聚类模型, 建立基于概率、范围搜寻、节点平均距离的节点生成、删除机制, 实现对漂移数据实时监控. 最后以燃煤锅炉动态数据为分析对象进行实验, 实验结果表明该模型和算法对动态漂移数据的实时跟踪能力更强, 能对燃煤锅炉动态数据进行准确、有效的监督和控制.

**关键词:** 燃煤锅炉; 动态特征; 数据漂移; GNG; 监控

中图分类号: TP273

文献标志码: A

DOI: 10.13195/j.kzyjc.2019.1343

开放科学(资源服务)标识码(OSID):



**引用格式:** 吴永明, 陈琳升, 李少波. 基于改进 GNG 算法的燃煤锅炉数据动态特征分析与控制[J]. 控制与决策, 2021, 36(8): 1855-1861.

## Dynamic characteristics analysis and control of coal-fired boiler based on improved GNG algorithm

WU Yong-ming<sup>1,2,3</sup>, CHEN Lin-sheng<sup>1†</sup>, LI Shao-bo<sup>1,2,3</sup>

(1. Key Laboratory of Advanced Manufacturing Technology of Ministry of Education, Guizhou University, Guiyang 550025, China; 2. State Key Laboratory of Public Big Data, Guizhou University, Guiyang 550025, China; 3. College of Mechanical Engineering, Guizhou University, Guiyang 550025, China)

**Abstract:** Data dynamic feature analysis and control technology are considered as important data mining methods. The coal-fired boiler data have obvious characteristics such as timing and drift. In view of the current lack of dynamic, real-time problems of data tracking monitoring algorithms, we propose an adaptive clustering model based on improved growing neural gas (GNG). The improved GNG is used to realize real time monitoring for drift data. The node generation and deletion mechanism are established. based on probability, range search and node average distance. Finally, the dynamic data for coal-fired boilers are taken as the analysis object. The experimental results show that the model and algorithm have stronger real-time tracking ability for dynamic drift data, and can effectively supervise and control the dynamic data of coal-fired boilers.

**Keywords:** coal-fired boiler; dynamic characteristics; data drift; GNG; monitor

## 0 引言

节能减排对电厂燃煤锅炉的 $\text{NO}_x$ 排放量有了更严苛的要求, 然而电厂的锅炉燃烧过程是一个复杂的多输入多输出系统, 具有高度的非线性、强耦合特性<sup>[1]</sup>. 相关学者对该问题进行了大量研究, 针对传统机械的改进, 基于人工智能等算法对相关数据进行建模分析已成为热点<sup>[2]</sup>. 此外, 通过智能算法研究燃煤锅炉的整体或者部分性能指标, 能够对锅炉的 $\text{NO}_x$

排放以及效率进行可靠性预测评估或聚类分析.

在燃煤锅炉输出数据预测研究方面, 文献[3]基于最小二乘法改进支持向量机(LSSVM)算法, 进行燃煤锅炉的排放预测, 但需要对原始数据进行严格筛选和分割, 破坏了数据间的隐藏关联性; 文献[4]基于LSSVM算法提出了实时更新误差的LSSVM-Scheme算法, 提升了LSSVM算法精度; 文献[5]通过改进的深度置信网络(DBN)成功预测了氮氧化物排量; 文献

收稿日期: 2019-09-24; 修回日期: 2019-12-20.

基金项目: 国家自然科学基金项目(51505094, 61962009); 贵州省科学技术基金项目[(2016)1037]; 贵州省科技支撑计划项目[(2017)2029]; 贵州大学引进人才科研项目[贵大人基合字(2014)60号].

责任编辑: 阳春华.

†通讯作者. E-mail: clsnnqns@163.com.

[6]的分布式粒子群优化(MR-PSO)算法对燃煤锅炉模型进行了多目标优化,该模型要求磨粉机制粉量固定不变,并且处理了大规模数据集。

在燃煤锅炉数据聚类研究方面,虽然关于燃煤锅炉性能、效率分析及控制方面的优化方案已经很多,但大部分方案适应性不强,提出的算法也局限于数据本身必须较平稳、噪声少,于是在预测分析前的聚类分析就显得尤为关键。对于燃煤锅炉数据动态特征分析,常采用聚类算法。文献[7]对燃煤的灰污染进行了在线监督,为后续控制和优化吹灰效果奠定了基础;文献[8]基于模糊 $C$ 均值聚类解决了燃煤锅炉氧含量非线性变化的特点,然而采用锅炉指标数据太少;文献[9]针对上述问题解决均值聚类不适应多目标等缺点,提出了改进 $K$ 原型聚类算法,但是对于聚类数目确定并没有合理方案。

针对上述问题,亟需能够处理数据量大、指标多、具有时间序列<sup>[10]</sup>的模型和方法,同时应对在线与动态数据流是目前重要研究方向<sup>[11]</sup>。因此,本文根据燃烧锅炉数据特征,提出一种基于改进GNG算法的自适应检测与跟踪模型,以适应动态漂移和奇异数据检测和分析,通过数据差异将数据有效区分成多个集群。在改进GNG算法中,有效避免传统GNG无法及时删除不再更新的节点,同时在数据动态漂移方向及时生成新的神经节点,能实时反映数据特征动态变化,实现数据动态跟随与监督。该算法不需要预设聚类数目,且能够适用于多指标数据集实时、准确的动态特征分析、跟踪和有效控制。

## 1 GNG算法原理

文献[12]提出的生长神经气模型(GNG)属于竞争型、无监督的自组织神经网络,它具有在动态增量输入空间中不断学习和生成拓扑网络节点的能力<sup>[13]</sup>,能够很好表现数据的拓扑特征。文献[14]用GNG调整云点网格密度,文献[15]基于GNG拓扑性能进行机器人路径规划研究。但GNG算法也有部分缺点:新节点生成必须依靠预设周期,未能及时删除不再更新的节点;不能及时删除不再获胜的节点导致传统GNG无法完成动态变化数据及时跟踪和监督,如图1所示。

如图1所示:当 $t = 100$ 时,由于数据分布特征稳定,传统GNG网络拓扑结构良好;在 $t = 500$ 时,可以看出数据开始出现动态漂移,但未能在数据特征漂移方向及时生成新神经节点;随着数据流不断输入,如 $t = 1000$ 时的数据移动特征明显,此时出现了不再获

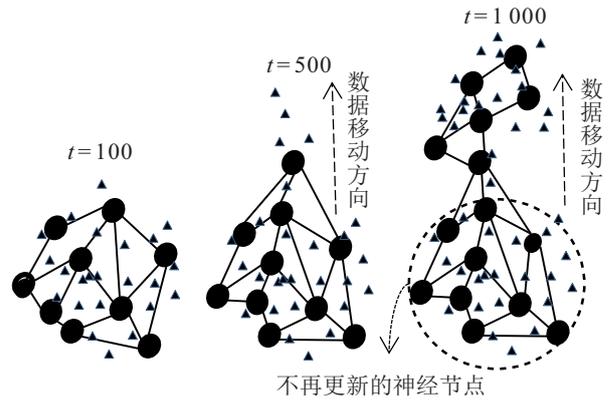


图1 传统GNG算法原理

胜的神经节点,但它们却不能被及时淘汰,导致无法准确及时跟踪数据流的动态特征,影响决策者做出可靠控制决策。文献[16]提出的GNG-A算法虽然改善了此缺点,但GNG-A丢失部分网络拓扑性能<sup>[17]</sup>。鉴于此,本文提出改进GNG的自适应算法,可克服上述缺点,并保存传统GNG算法本身良好的拓扑性。

## 2 改进GNG算法

### 2.1 改进GNG算法的适应性机制

改进GNG算法的神经节点权重学习机制:每次数据输入到竞争网络,仅有一个获胜神经元,对获胜神经元即其邻域的神经元进行权重计算,定义如下:

$$J_{n^*} = J_{n^*} + \alpha_1 \times (x - J_{n^*}), \quad (1)$$

$$J_{n^{**}} = J_{n^{**}} + \alpha_2 \times (x - J_{n^{**}}), \quad (2)$$

其中 $J_{n^*}$ 、 $\alpha_1$ 、 $x$ 、 $J_{n^{**}}$ 、 $\alpha_2$ 表示获胜神经节点权重、获胜节点的权重学习系数、输入向量、获胜节点的邻域节点、邻域节点的权重学习系数。两个学习系数需手动设置,通常 $\alpha_1$ 远远大于 $\alpha_2$ 。

### 2.2 改进GNG算法节点生成机制

传统GNG算法创建新神经元是周期性的。如果分布突然发生变化,则数据点开始进入特征空间的新区域,该算法无法立即适应这些区域的表示。在很多实际应用中,在不影响现有神经元的情况下,需要立即创建新的神经元。为了实时处理数据漂移特性,本文提出一种动态策略,允许在必要时生成新的神经元,该策略保证在分布稳定的情况下生成的神经元较少,当数据特征出现新颖性或突变时,能够生成更多神经元,生成新节点的条件为

$$V < f_k - 1/(t - t^*), \quad V \in (0, 1), \quad (3)$$

其中 $W$ 、 $f_k$ 、 $k$ 、 $t$ 、 $t^*$ 、 $V$ 分别为迭代次数(取值与目前网络节点总数相近)、最近 $W$ 次迭代中频率最高的前 $k$ 个神经元的平均获胜频率、预设系数、此次迭代步

骤、上一次生成神经元的迭代步骤、属于0~1的随机数。此节点生成机制应用概率知识,并且增加了减缓生成速度的延迟项 $-1/(t-t^*)$ ,注意系数 $k$ 需手动设置,算法实现如下。

改进算法节点生成机制。

- 1) 输入  $W, k$ .
- 2)  $t^* \leftarrow 0$ .
- 3) 获取数据维度.
- 4) for 输入数据变量  $X$ .
- 5)  $t \leftarrow t + 1$ .
- 6) 计算各节点最近  $W$  次迭代的获胜次数,按此参数降序排列所有神经节点.
- 7) 计算排列前  $k$  位节点平均获胜频率  $f_q$ .
- 8) if  $\text{rand} < f_q - 1/(t - t^*)$ ,  $\text{rand} \in (0, 1)$ .
- 9) 误差最大节点  $J_{\text{errmax}}$  与误差次大节点  $J_{\text{errmax2}}$  之间生成新的神经节点为  $J_{\text{newnode}}$ ,更新  $J_{\text{newnode}}$  的权重和局部误差.

$$J_{\text{newnode}} = 0.5 \times (J_{\text{errmax}} + J_{\text{errmax2}}),$$

$$E_{\text{new}} \leftarrow 0.5 \times E_{\text{max}}.$$

- 10) end if
- 11) end for

### 2.3 改进GNG算法节点淘汰机制

本文提出的新淘汰机制原理:寻找不再获胜时间最长神经节点  $N_{\text{errmin}}$ (表现为拥有最小局部误差  $E_{\text{errmin}}$ ),以点  $N_{\text{errmin}}$  为圆心,以网络中有关联神经节点间的平均欧氏距离  $d_{\text{aver}}$  为半径做范围搜索,假设数据仅有两类指标,即在圆形区域内范围搜索,  $N$  为当前网络节点总数,当区域外神经节点数  $N_{\text{out}} > N \times b$ ,  $b \in (0, 1)$  时,删除  $N_{\text{errmin}}$ ,如图2所示( $b$ 通常取0.5)。

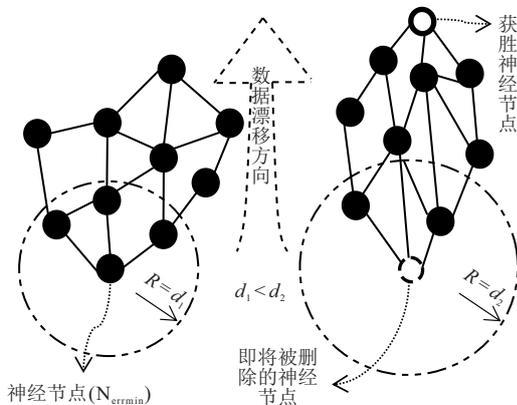


图2 改进GNG的节点删除机制

如图2所示,当输入数据趋于平稳时,神经节点分布均匀密集(即节点间平均距离较小),此时删除机

制的搜索半径  $R = d_1$ ,不满足  $N_{\text{out}} > N \times b$ ,  $N_{\text{errmin}}$  不被删除,有效避免了过度删除节点,保证了网络稳定性。相反,当数据的特征发生漂移时,随着输入向量的移动,神经节点也会朝着数据漂移方向移动,此时距离输入向量较远的极少数神经节点移动缓慢,整个神经网络的平均节点距离增大为  $d_2$ ,不再获胜的  $N_{\text{errmin}}$  节点被滞留(即“将被删除的神经节点”),搜索半径  $R = d_2 > d_1$ ,并且此时已满足删除条件  $N_{\text{out}} > N \times b$ ,应及时删除节点  $N_{\text{errmin}}$ ,保证神经网络节点跟踪数据的及时性。

### 2.4 改进GNG算法实现

改进的GNG算法主要拥有权重计算、新节点生成机制、节点淘汰机制,具体实现步骤如下。

step 1: 初始化神经节点数,预设必要参数,归一化处理原始数据,获取数据维度。

step 2: 输入样本向量  $x$ ,遍历所有节点,得到获胜神经节点  $J_{n^*}$ ,并更新该节点局部误差

$$E_{J_{n^*}} = E_{J_{n^*}} + \|x - J_{n^*}\|^2. \quad (4)$$

step 3: 获胜节点  $J_{n^*}$  和有关联邻域节点  $J_{n^{**}}$  的权值调整为

$$J_{n^*} = \alpha_1 \times (x - J_{n^*}), \quad (5)$$

$$J_{n^{**}} = \alpha_2 \times (x - J_{n^{**}}). \quad (6)$$

step 4: 在获胜节点  $J_{n^*}$  与次获胜节点  $J_s$  间建立连接,并将  $J_{n^*}$  与  $J_s$  的连接年龄清零。

step 5: 移除连接年龄达到上限  $t_{\text{max}}$  的神经节点,并移除被独立节点。

step 6: 计算拓扑网络关关节点间平均距离  $d_{\text{newnode}}$ 。

step 7: 节点生成机制满足式(3)则生成新神经节点

$$J_{\text{newnode}} = 0.5 \times (J_{\text{errmax}} + J_{\text{errmax2}}), \quad (7)$$

$$E_{\text{newnode}} = 0.5 \times E_{\text{max}}. \quad (8)$$

step 8: 节点淘汰(删除)机制。以  $N_{\text{errmin}}$  为圆心进行搜索,若满足  $N_{\text{out}} > N \times b$  则删除  $N_{\text{errmin}}$ ,并且清空与  $N_{\text{errmin}}$  相关所有参数。

step 9: 减少神经网络的全局误差,  $\beta$  为全局误差系数,  $\beta \in (0, 1)$ , 即

$$E_N \leftarrow \beta \times E_N. \quad (9)$$

step 10: 结束一次循环,重复 step 2.

### 2.5 改进GNG算法可行性分析

为验证该改进GNG算法可行性,选取多组漂移数据进行神经节点数量适应性验证(如图3所示)、拓扑结构稳定分析(如图4所示),数据集见网站: <https://>

sites.google.com/site/.

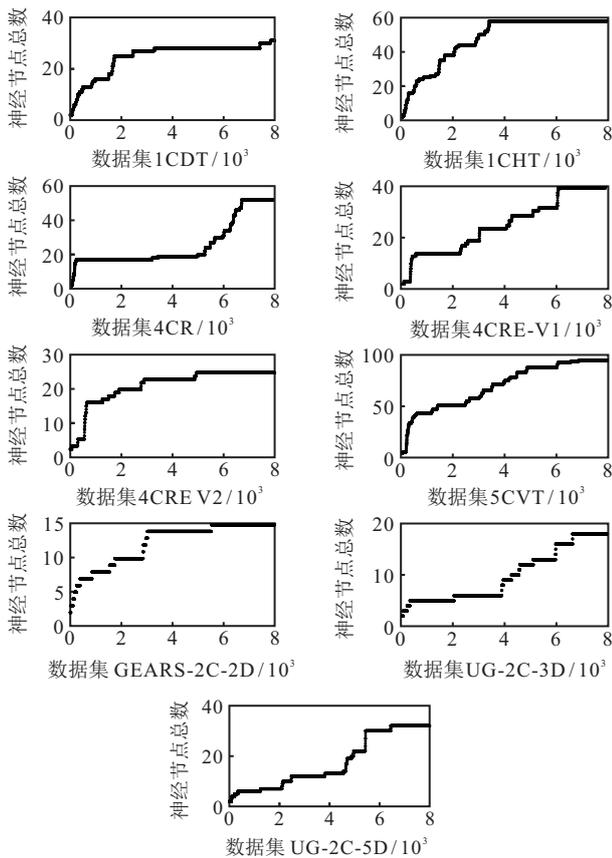


图3 神经节点总数适应性验证

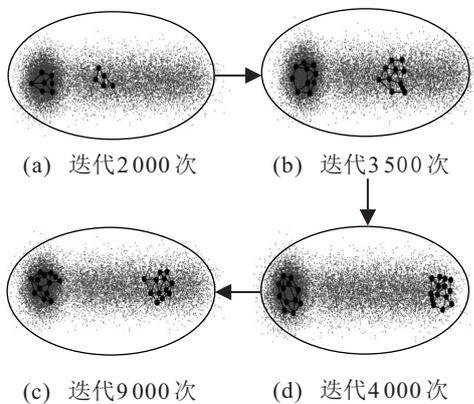


图4 拓扑结构稳定分析(数据集1CDT)

如图3所示,随着数据流输入,网络节点数通过逐渐增加以满足拓扑结构需要,伴随着数据的漂移特征出现(数据集1CDT的第1700次迭代时出现数据漂移特征),节点数目稳定在一定范围(如数据集1CDT对应的网络节点在第3300次迭代时趋于稳定),节点数目稳定不代表没有节点的删除与生成,而是删除与生成机制在该数据特征情况下达到平衡状态,验证了改进算法的节点数目拥有良好适应性、稳定性,其余数据集节点增长情况类似。

图4反映了数据集1CDT由两个集群构成,一个平稳分布,另一个具有明显漂移特征,随着数据的不

断输入,数据在图4(a)时出现漂移特征,图4(d)时漂移已十分明显,较小散点反映数据分布,较大圆点代表神经节点,线条连接了两个相互关联的神经节点,改进的GNG算法既能够表现平稳集群的数据特征分布(图4(a)~图4(d)中左边集群),也能反映漂移特征<sup>[18-20]</sup>(图4(a)~图4(d)中右边集群),并且在整个数据漂移过程中改进GNG的网络均表现稳定,较大圆点构成的三角形依照德罗拉三角法则,能够及时、准确、稳定地对动态变化数据进行实时跟踪与监控<sup>[21-22]</sup>。

### 3 实例验证

#### 3.1 燃煤锅炉数据

实验研究对象选择某电厂410T四角切圆粉煤锅炉,并且考虑多种指标对锅炉的氮氧化物 $NO_x$ 及效率的影响,基于改进GNG算法对具有动态漂移特性的燃煤锅炉数据进行实验分析,验证该算法对数据的及时跟随与监督能力,为决策者提供理论支持。数据如表1和表2所示。

表1 班组重构前后成本对比

指标序号	指标	指标序号	指标
1	主蒸汽量/(t/h)	12	排烟温度(左)/ $^{\circ}C$
2	主给水量/L	13	排烟温度(右)/ $^{\circ}C$
3	给煤量/kg	14	一次风机电流(左)/A
4	热值/(cal/g)	15	一次风机电流(右)/A
5	含硫量比例	16	二次风机电流(左)/A
6	灰分比例	17	二次风机电流(右)/A
7	*1 电流/A	18	引风机电流(左)/A
8	*2 电流/A	19	引风机电流(右)/A
9	*3 电流/A	20	炉膛氧量百分比
10	炉膛温度(左)/ $^{\circ}C$	21	$NO_x$ 排量/( $mg/m^2$ )
11	炉膛温度(右)/ $^{\circ}C$	22	效率(百分比)

表2 实验数据

工况序号	指标序号	1	2	...	18	...	21	22
1		354	346		90		42	96
2		336	357		89		43	92
3		339	342		84		42	93
4		348	334		88		42	91
5		335	321		88		43	94
6		347	350		85		45	92
7		332	341		87		44	96
8		364	341		90		43	90
...		...	...		...		...	...
90		371	380		97		51	87
91		389	361		92		53	84
92		370	366		91		54	70
93		374	372		96		55	85
94		364	371		93		51	85
95		358	373		95		62	83
96		151	350		91		54	79

表1中反映了本次实验数据的20个输入指标,以及氮氧化物排放量、锅炉燃烧效率两个评价指标. 根据国家统一标准,氮氧化物排放量需严格控制,在50 mg/m<sup>3</sup>以下. 表2中性能指标21、22被加粗代表了符合标准,否则不符合国标. 为说明表2数据存在漂移特性,对燃煤锅炉原始数据进行可视化处理,在指标1~20中随机选取3个指标,充分展示燃煤锅炉性能由不符合标准(正方形)迁移至符合标准(三角形)的过程,如图5所示.

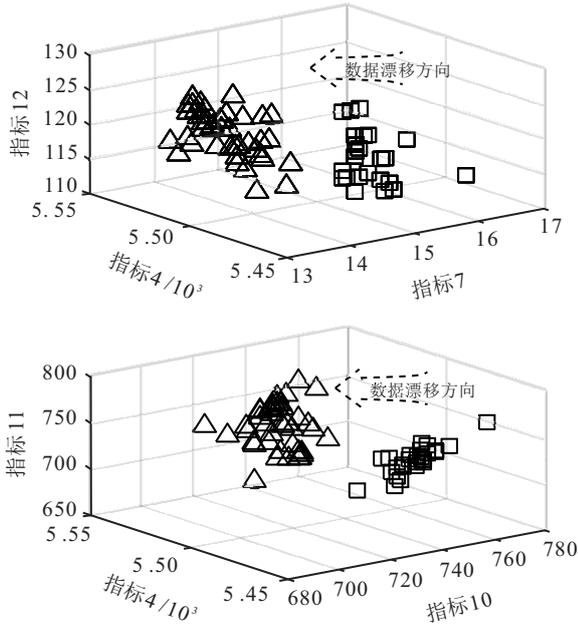


图5 实验数据分布特征

### 3.2 实验结果

实验采用对比分析. 通过GNG、GNG-A<sup>[16]</sup>、改进GNG的网络拓扑结构进行对比分析,实验拓扑结果如图6所示.

在图6中: 实心圆均为神经节点,其中较大实心圆为获胜神经节点,即离输入数据最近的节点;三角形为满足条件的原始数据;正方形为不满足条件的原始数据;箭头为燃煤锅炉动态数据漂移方向.

在图6中,燃煤锅炉数据明显发生动态漂移,数据被区分为满足要求(三角形)和不满足要求(正方形)两大类. 在对数据进行动态跟踪与监控过程中,圆点为神经节点,线条连接相互关联的节点,GNG算法和GNG-A算法无法区分已经漂移的满足需求数据与不满足需求的数据(参考依据: GNG、GNG-A网络中的无关联节点仍存在不必要的连接). 在每一次数据输入中,网络中都会有相应获胜节点,并且该节点与关联节点的误差会更新一次. 但随着网络对输入向量适应性增强,整个网络误差会在逐步减小,参考式

(4)、(9),采用网络中各神经节点平均误差 $E_{mean}$ 作为衡量算法对数据跟踪及时性的标准,如图7所示.

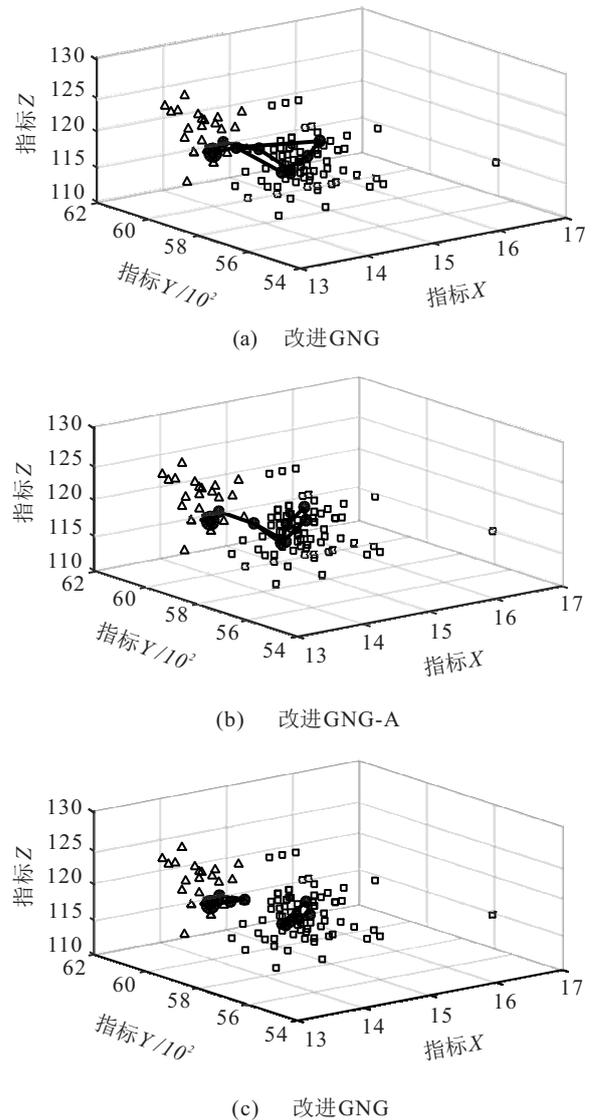


图6 实验结果可视化对比

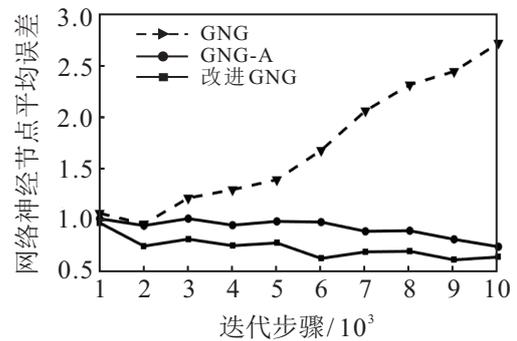


图7 实验结果对比

如图7所示: 燃煤锅炉数据在迭代步骤为2000之后出现漂移特性,由于GNG网络节点对具有漂移特性的燃煤锅炉数据并不敏感,GNG网络神经节点对数据适应性下降趋势明显,平均误差 $E_{mean}$ 随着数据漂移而呈现持续上升趋势. GNG-A算法在应对数据漂移特征时平均节点误差缓慢下降, $E_{mean}$ 稳定在

0.731~1.004,网络对数据适应性一般,平均节点误差始终高于提出的改进GNG算法;改进GNG的 $E_{\text{mean}}$ 稳定在0.6~0.96,在应对平稳、漂移数据时均表现出良好跟随性.实验数据充分说明,采用传统GNG对燃煤数据进行监督,由于网络节点无法朝着新特征方向快速移动,数据监督能力较差.采用本文改进GNG算法对动态数据进行实时跟随和监督,由于整个网络节点均能朝数据漂移方向快速迁移,始终将误差保持在较小范围内,能够充分满足对动态漂移数据稳定跟随和监督的要求.

完成动态特征的分析实验的同时,为达到对燃煤锅炉性能进行提升的目的,通过主成份(PCA)技术从20个输入指标中筛选出4个核心指标4、12、7、9.通过对核心指标的参数优化控制达到提升锅炉性能的目的,参数调整参照表2中工况1的核心指标,参数调整前后情况见表3和表4.

表3 参数调整前

工况	核心指标序号				性能指标	
	4	12	7	9	21	22
1	5456	129	14.7	16.7	<b>42</b>	<b>96</b>
⋮	⋮	⋮	⋮	⋮	⋮	⋮
92	5560	133	12.2	18.8	54	70
93	5725	151	15.1	17.2	55	85
94	5571	137	12.5	17.4	51	85
95	5748	144	10.7	17.7	62	83
96	5661	122	13.1	17.1	54	79

表4 参数调整后

工况	核心指标序号				性能指标	
	4	12	7	9	21	22
1	5456	129	14.7	16.7	<b>42</b>	<b>96</b>
⋮	⋮	⋮	⋮	⋮	⋮	⋮
92	5456	129	14.7	16.7	<b>49</b>	<b>91</b>
93	5456	129	14.7	16.7	<b>43</b>	<b>93</b>
94	5456	129	14.7	16.7	<b>47</b>	<b>90</b>
95	5456	129	14.7	16.7	<b>43</b>	<b>91</b>
96	5456	129	14.7	16.7	<b>49</b>	<b>91</b>

如表4所示,性能指标加粗为符合要求的数据.通过对表3中核心指标进行调整,调整至工况1的各指标数值,完成对锅炉性能优化控制,既降低了锅炉的氮氧化物排量,也提升了锅炉燃烧效率.

## 4 结论

本文研究和分析了生长神经气(GNG)算法原理及特点,针对传统跟踪与监督算法无法准确、快速适应动态数据变化,提出了一种基于改进GNG算法的自适应聚类数学模型,建立了基于概率、范围搜寻、节

点平均距离的节点生成、删除机制,并验证了该模型和算法的可行性和有效性.最后以电厂燃煤锅炉动态数据检测和控制为例,通过燃煤锅炉多项指标进行聚类分析,并以GNG、GNG-A算法为参照进行了对比实验,结果表明本文中改进GNG算法是有效可行的,在适应非平稳数据、跟随与监督数据上更具优势,能有效完成对锅炉燃烧性能分析和控制,既能够降低锅炉的氮氧化物排量也提升了锅炉燃烧效率,进而为决策者/管理者提供理论技术支持.

## 参考文献(References)

- [1] Agbor E, Zhang X L, Kumar A. A review of biomass co-firing in North America[J]. *Renewable and Sustainable Energy Reviews*, 2014, 40: 930-943.
- [2] Chongwatpol J, Phurithititanapong T. Applying analytics in the energy industry: A case study of heat rate and opacity prediction in a coal-fired power plant[J]. *Energy*, 2014, 75: 463-473.
- [3] Lv L, Liu J Z, Yang T T, et al. A novel least squares support vector machine ensemble model for  $\text{NO}_x$  emission prediction of a coal-fired boiler[J]. *Energy*, 2013, 55(1): 319-329.
- [4] Ahmed F, Cho H J, Kim J K, et al. Prediction of  $\text{NO}_x$  emission from coal fired power plant based on real-time model updates and output bias update[J]. *Journal of Chemical Engineering of Japan*, 2015, 48(1): 35-43.
- [5] Wang F, Ma S X, Wang H, et al. Prediction of  $\text{NO}_x$  emission for coal-fired boilers based on deep belief network[J]. *Control Engineering Practice*, 2018, 80: 26-35.
- [6] Xu X Y, Chen Q, Ren M F, et al. Combustion optimization for coal fired power plant boilers based on improved distributed ELM and distributed PSO[J]. *Energies*, 2019, 12(6): 1-24.
- [7] Shi Y A, Wang J C. Ash fouling monitoring and key variables analysis for coal fired power plant boiler[J]. *Thermal Science*, 2015, 19(1): 253-265.
- [8] Xiaoying H Y, Wang J C, Zhang L W, et al. Data-driven modelling and fuzzy multiple-model predictive control of oxygen content in coal-fired power plant[J]. *Transactions of the Institute of Measurement and Control*, 2017, 39(11): 1631-1642.
- [9] Gu H, Zhu H X, Cui Y F, et al. Optimized scheme in coal-fired boiler combustion based on information entropy and modified  $K$ -prototypes algorithm[J]. *Results in Physics*, 2018, 9: 1262-1274.
- [10] Loglisci C, Ceci M, Impedovo A, et al. Mining microscopic and macroscopic changes in network data streams[J]. *Knowledge-Based Systems*, 2018, 161:

- 294-312.
- [11] Lobo J L, Laña I, Del Ser J, et al. Evolving spiking neural networks for online learning over drifting data streams[J]. *Neural Networks*, 2018, 108: 1-19.
- [12] Fritzke B. A growing neural gas network learns topologies[C]. *Advances in Neural Information Processing Systems*. Cambridge: MIT Press, 1995: 625-632.
- [13] Aljoubouri H K, Jaber H A, Koçak O M, et al. Clustering fMRI data with a robust unsupervised learning algorithm for neuroscience data mining[J]. *Journal of Neuroscience Methods*, 2018, 299: 45-54.
- [14] 曾锋, 杨通, 姚山. 点云重构三角网格的生长型神经气算法[J]. *软件学报*, 2013, 24(3): 651-662.  
(Zeng F, Yang T, Yao S. From point cloud to triangular mesh by growing neural gas[J]. *Journal of Software*, 2013, 24(3): 651-662.)
- [15] 任伟建, 刘东辉, 王显伟, 等. 基于改进GNG网络的机器人路径规划方法[J]. *系统仿真学报*, 2014, 26(5): 1000-1005.  
(Ren W J, Liu D H, Wang X W, et al. Robot path planning method based on improved GNG neural network[J]. *Journal of System Simulation*, 2014, 26(5): 1000-1005.)
- [16] Bouguelia M R, Nowaczyk S, Payberah A H. An adaptive algorithm for anomaly and novelty detection in evolving data streams[J]. *Data Mining and Knowledge Discovery*, 2018, 32(3): 1597-1633.
- [17] Martinetz T. Competitive Hebbian learning rule forms perfectly topology preserving maps[C]. *International Conference on Artificial Neural Networks*. London: Springer, 1993: 427-434.
- [18] 潘吴斌, 程光, 郭晓军, 等. 基于信息熵的自适应网络流概念漂移分类方法[J]. *计算机学报*, 2017, 40(7): 1556-1571.  
(Pan W B, Cheng G, Guo X J, et al. An adaptive classification approach based on information network traffic in presence of concept drift[J]. *Chinese Journal of Computers*, 2017, 40(7): 1556-1571.)
- [19] 毕安琪, 董爱美, 王士同. 基于概率和代表点的数据流动态聚类算法[J]. *计算机研究与发展*, 2016, 53(5): 1029-1042.  
(Bi A Q, Dong A M, Wang S T. A dynamic data stream clustering algorithm based on probability and exemplar[J]. *Journal of Computer Research and Development*, 2016, 53(5): 1029-1042.)
- [20] 邹鹏, 于渤, 王宪全. 面向数据漂移的代价敏感客户细分[J]. *哈尔滨工业大学学报*, 2011, 43(1): 119-124.  
(Zou P, Yu B, Wang X Q. Cost-sensitive learning method with data drift in customer segmentation[J]. *Journal of Harbin Institute of Technology*, 2011, 43(1): 119-124.)
- [21] 刘玉敏, 张帅. 基于多主元特征与支持向量机的动态过程质量异常监控模型[J]. *计算机集成制造系统*, 2018, 24(3): 703-710.  
(Liu Y M, Zhang S. Quality abnormal pattern monitoring model in dynamic process based on MPC and SVM[J]. *Computer Integrated Manufacturing Systems*, 2018, 24(3): 703-710.)
- [22] 文益民, 唐诗淇, 冯超, 等. 基于在线迁移学习的重现概念漂移数据流分类[J]. *计算机研究与发展*, 2016, 53(8): 1781-1791.  
(Wen Y M, Tang S Q, Feng C, et al. Online transfer learning for mining recurring concept in data stream classification[J]. *Journal of Computer Research and Development*, 2016, 53(8): 1781-1791.)

### 作者简介

吴永明(1982—), 男, 教授, 博士生导师, 从事数据挖掘、制造系统自动化等研究, E-mail: wu20811055@163.com;

陈琳升(1994—), 男, 硕士生, 从事数据挖掘的研究, E-mail: clsnnqns@163.com;

李少波(1973—), 男, 教授, 博士生导师, 从事计算设计、制造大数据与制造信息系统等研究, E-mail: lishaobo@gzu.edu.cn.

(责任编辑: 闫妍)