

DOI: 10.19666/j.rlfed.202205097

一种SSAE+BPNN的变工况飞灰含碳量 软测量方法

刘鑫屏, 李波, 邓拓宇

(华北电力大学控制与计算机工程学院, 河北保定 071003)

[摘要] 火电机组变工况运行使数据呈现多模态特征, 导致基于浅层网络结构的回归软测量模型的预测精度下降。研究一种改进的BP神经网络(back propagation neural network, BPNN)软测量方法: 首先利用堆叠稀疏自编码器(stacked sparse autoencoder, SSAE)强大的深度学习能力提取原始数据特征, 然后再利用BPNN对提取特征进行回归分析。经实验验证, SSAE+BPNN软测量方法的均方误差为 0.1358×10^{-3} , 平方相关系数为0.9832, 其预测精度和泛化能力显著优于BPNN。将其应用于某台灵活调峰的超超临界660 MW发电机组飞灰含碳量软测量中, 预测结果的平均相对误差为0.91%, 总体相对误差控制在±5%以内, 具有良好的工程应用价值。

[关键词] 堆叠稀疏自编码器; 特征提取; 软测量; 多工况; 飞灰含碳量; 深度学习

[引用本文格式] 刘鑫屏, 李波, 邓拓宇. 一种SSAE+BPNN的变工况飞灰含碳量软测量方法[J]. 热力发电, 2023, 52(1): 66-73. LIU Xinping, LI Bo, DENG Tuoyu. A soft measurement method of carbon content in fly ash under variable operating conditions of SSAE+BPNN[J]. Thermal Power Generation, 2023, 52(1): 66-73.

A soft measurement method of carbon content in fly ash under variable operating conditions of SSAE+BPNN

LIU Xinping, LI Bo, DENG Tuoyu

(School of Control and Computer Engineering, North China Electric Power University, Baoding 071003, China)

Abstract: The variable operating condition of thermal power units makes the data show multi-modal characteristics, which leads to the decrease of prediction accuracy of the regression soft sensor model based on shallow network structure. An improved BP neural network (back propagation neural network, BPNN) soft sensor method is studied. Firstly, the original data features are extracted by using the strong deep learning ability of stacked sparse autoencoder (SSAE), and then the extracted features are analyzed by BPNN. The experimental results show that, the mean square error of the SSAE+BPNN soft sensor method is 0.1358×10^{-3} and the square correlation coefficient is 0.9832. It is proved that its prediction accuracy and generalization ability are significantly better than those of BPNN. It is applied to the soft sensor of carbon content in fly ash of a flexible peak-shaving 660 MW ultra-supercritical generator set, and the average relative error of the prediction results is 0.91%, the overall relative error is less than ±5%, indicating the method has good engineering application value.

Key words: stacked sparse autoencoder; feature extraction; soft measurement; variable operating conditions; carbon content in fly ash; deep learning

飞灰含碳量是反映锅炉燃烧状态的重要参数之一, 直接影响着锅炉的热效率^[1]。准确测量飞灰

含碳量, 对锅炉的安全运行和机组经济水平的提高具有重要的意义^[2]。目前在线监测飞灰含碳量常

收稿日期: 2022-05-10 网络首发日期: 2023-01-03

基金项目: 国家重点研发计划项目(2017YFB0902100)

Supported by: National Key Research and Development Program (2017YFB0902100)

第一作者简介: 刘鑫屏(1976), 女, 博士, 副教授, 主要研究方向为大机组智能优化控制、热力发电过程建模与状态参数检测、综合能源系统, lxp@ncepu.edu.cn.

通信作者简介: 李波(1998), 男, 硕士研究生, 主要研究方向为关键参数软测量加数据挖掘的大型火电机组燃烧优化, 18833255657@163.com.

用的方法有微波吸收法、红外测量法和灼烧失重法等^[3]，但由于测量环境恶劣且仪器成本高昂，上述方法表现出抗干扰能力差、精度低、延迟大或维护成本高等缺点^[2,4]。

目前，研究人员多采用软测量的方法对飞灰含碳量进行监测。软测量模型主要分为机理模型^[5-7]和数据驱动模型。由于影响飞灰含碳量的参数众多且相互间耦合，建立飞灰含碳量的机理模型十分困难。因此，基于数据驱动的软测量模型以无需精准的机理分析、较低的成本和满足要求的测量精度，受到众多研究人员的关注。文献[8-9]基于BP神经网络(back propagation neural network, BPNN)构建了飞灰含碳量的预测模型，得到有效结果的同时也指出了常规神经网络收敛慢、易陷入局部最优的不足。文献[10-11]采用支持向量机(support vector regression, SVR)建立了飞灰含碳量软测量模型。文献[12-13]对支持向量机的参数进行优化，采用改进后的支持向量机对飞灰含碳量进行预测，取得了较好的成果。

然而，随着近些年来“双碳”目标的提出，新能源机组并网规模迅速攀升，使得火电机组频繁参与调峰而长期处于变工况运行状态，其数据间的分布特征同稳态工况相比变得更加复杂，数据表现出典型的多模态特性^[14]。BPNN、SVR等传统的软测量模型受限于其浅层的网络结构，无法有效挖掘数据中更深层的隐含特征，从而无法保障所建软测量模型的性能。与之相比，深度学习由于其深层的网络结构，具有更强大的非线性数据处理能力，能够学习并提取多模态数据深层的重要特征信息。因此，基于深度学习的软测量建模逐渐兴起。如文献[15]提出了一种基于分层极限学习机的半监督深度学习模型用于预测高低电压器的CO体积分数。文献[16]提出一种基于长短时记忆神经网络的软测量方法，对燃煤电厂的NO_x排放量进行预测。文献[17]对自编码器进行改进，建立了迁移变分自编码器模型，实现了对球磨机负荷的软测量。自编码器作为一种经典的深度学习方法，因其出色的深度特征学习能力，被广泛的应用在复杂工业过程异常监测^[18-19]与关键参数软测量^[17,20]中。自编码器通过对隐含层施加不同的约束，可以进化成不同的变种，从而满足不同的任务需求，如降噪自编码器、稀疏自编码器、卷积自编码器及变分自编码器等。

本文基于以上分析，研究一种基于改进自编码

器结合BPNN回归的变工况软测量方法。首先向自编码器施加稀疏化约束以提高模型泛化能力，防止过拟合；接着根据数据维度特征将自编码器逐层堆叠，组合成堆叠稀疏自编码器(stacked sparse autoencoder, SSAE)用于原始输入数据的特征提取；然后将提取特征输入BPNN模型中进行回归分析，构建出SSAE+BPNN软测量模型。通过对某台灵活调峰的660 MW燃煤锅炉飞灰含碳量的实例分析，验证了本文所研究软测量方法的有效性。

1 飞灰含碳量机理分析

本文以某电厂灵活调峰的660 MW机组为研究对象，该机组锅炉为超超临界直流煤粉炉，采用四角切圆燃烧方式，每炉配备A—F共6台磨煤机。

1.1 飞灰含碳量的意义

锅炉效率是机组经济性的直接反映，在电厂性能指标计算中常采用反平衡法计算得到，其中较为重要的一项损失是机械未完全燃烧损失，该损失根据飞灰含碳量等参数实时计算得到，因此飞灰含碳量是直接影响锅炉效率的重要参数之一。锅炉效率反平衡计算公式如下：

$$\eta_{gl} = 100 - q_{gt} - q_{qt} - q_{py} - q_{lq} - q_{hz} \quad (1)$$

式中： q_{gt} 为未燃尽碳损失，%； q_{qt} 为气体未完全燃烧热损失，%； q_{py} 为排烟损失，%； q_{lq} 为锅炉外部冷却损失，%； q_{hz} 为灰渣物理热损失，%。

对煤粉炉来讲，因未燃尽而造成损失的固体碳分布于灰渣与飞灰之中：

$$q_{gt} = \frac{Q_{cl}}{BQ_{ar.net,p}} (G_{hz}C_{hz} + G_{fh}C_{fh}) \quad (2)$$

式中： Q_{cl} 为残留煤发热量，kJ/kg； B 为锅炉每秒燃烧的煤，kg/s； $Q_{ar.net,p}$ 为煤发热量，kJ/kg； G_{hz} 、 G_{fh} 分别为灰渣、飞灰的质量流量，kg/s； C_{hz} 、 C_{fh} 分别为灰渣、飞灰的含碳量，%。

其中，飞灰与灰渣相比，飞灰不仅份额占比更大(约9:1)，其含碳量的测量难度也更大。

1.2 影响飞灰含碳量的重要参数

锅炉燃烧过程复杂，飞灰含碳量受到许多热工参数的影响^[11]，包括煤质、锅炉负荷、总燃料量、总风量、主蒸汽压力、主蒸汽流量、主蒸汽温度、一次风压、烟气含氧量及排烟温度。由于本文研究对象为坑口电厂，其燃烧煤种长期稳定，因此忽略煤质对飞灰含碳量的影响。

将以上热工参数与飞灰含碳量做无量纲化处理后进行关联度分析, 结果见表 1。一般认为, 关联度数值超过 0.7 的参数为重要影响因素^[21]。因此选取总燃料量、总风量、主蒸汽流量、主蒸汽压力、机组负荷、排烟温度与烟气含氧量作为飞灰含碳量软测量模型的输入参数。

表 1 影响飞灰含碳量的热工参数关联度分析($\rho=0.5$)
Tab.1 Correlation degree analysis of thermal parameters affecting carbon content in fly ash ($\rho=0.5$)

热工参数	与飞灰含碳量的关联度
总燃料量	0.857 5
总风量	0.751 6
主蒸汽流量	0.734 3
主蒸汽压力	0.705 2
主蒸汽温度	0.618 7
机组负荷	0.822 9
一次风压	0.687 8
排烟温度	0.731 9
氧量	0.771 2

2 堆叠稀疏自编码器

2.1 自编码器与稀疏自编码器

自编码器^[22] (autoencoder, AE) 是一种无监督的学习算法, 一般通过神经网络来训练, 具有更强的非线性学习能力。传统的自编码器只包括输入层、单隐含层、输出层共 3 层网络, 其结构如图 1 所示。




图 1 AE 结构
Fig.1 The AE structure

自编码器共分为编码器 (encoder) 与解码器 (decoder) 2 部分。编码器由输入层与隐含层构成, 从输入层学习输入数据 \mathbf{x} 的隐含特征, 得到特征向量 \mathbf{h} , 当隐含层节点数 n 小于输入层节点数 m 时可实现数据的降维特征提取, 这也是编码器的通常用途; 解码器由隐含层与输出层构成, 利用编码器学

习的特征向量 \mathbf{h} 来重构输入数据 \mathbf{x} 得到输出数据 $\hat{\mathbf{x}}$, 因此自编码器的结构为对称结构, 即输出层的节点数一定等同于输入层的节点数:

$$\mathbf{h} = f_1(\mathbf{w}_1 \mathbf{x} + \mathbf{b}_1) \quad (3)$$

$$\hat{\mathbf{x}} = f_2(\mathbf{w}_2 \mathbf{h} + \mathbf{b}_2) \quad (4)$$

式中: f_1 、 f_2 为激活函数, 常选用 Sigmoid 函数、tanh 函数与 ReLU 函数; \mathbf{w}_1 与 \mathbf{b}_1 分别为编码权重向量和偏置向量; \mathbf{w}_2 与 \mathbf{b}_2 分别为解码权重向量和偏置向量。

一个完美的自编码器重构的输出数据 $\hat{\mathbf{x}}$ 应完全等同于输入数据 \mathbf{x} , 但是由于其对数据编码降维、解码重构的过程是有损的, 因此需构建损失函数来衡量重构误差, 本文选用均方误差 (mean squared error, MSE) 函数来作为自编码器的损失函数:

$$J_{\text{AE}}(\mathbf{w}, \mathbf{b}) = \frac{1}{m} \sum_{i=1}^m (x_i - \hat{x}_i)^2 \quad (5)$$

通过损失函数的最小化, 自编码器可实现权重向量 \mathbf{w} 与偏置向量 \mathbf{b} 的学习。

当在式(5)中加入正则化的稀疏约束项后, 自编码器进化成稀疏自编码器^[22] (sparse autoencoder, SpAE):

$$J_{\text{SpAE}}(\mathbf{w}, \mathbf{b}) = J_{\text{AE}} + \beta \sum_{j=1}^n \text{KL}(\rho \| \hat{\rho}_j) \quad (6)$$

式中: β 为稀疏项权重参数; ρ 为稀疏性比例, 控制隐含层中的每个神经元针对训练样本的平均输出值; n 为隐含层节点数; 整个稀疏约束项代表着隐含层的相对熵, 又称为 KL 散度, 见式(7)。

$$\sum_{j=1}^n \text{KL}(\rho \| \hat{\rho}_j) = (1 - \rho) \log \frac{1 - \rho}{1 - \hat{\rho}_j} + \sum_{j=1}^n \rho \log \frac{\rho}{\hat{\rho}_j} \quad (7)$$

式中: $\hat{\rho}_j$ 为所有输入数据在隐含层神经元 j 上的平均激活度, 见式(8)。

$$\hat{\rho}_j = \frac{1}{m} \sum_{i=1}^m [a_j(x_i)] \quad (8)$$

式中: a_j 为隐含层神经元 j 的激活度, 对于 Sigmoid 激活函数来说, 神经元输出接近 1 表示被激活, 输出接近 0 表示被抑制。

SpAE 通过对隐含层施加的约束限制, 能够在更恶劣的环境下学习, 且能更好表达输入数据的特征, 从而提高泛化能力, 并能更有效地对输入样本进行降维。

2.2 自编码器的堆叠

传统自编码器单隐层的结构对于输入数据更复杂、更深层隐含特征的学习表现乏力。通过将多个自编码器逐层堆叠^[23], 可大大增强网络的学习能

力。结合上一节对隐含层施加的稀疏性约束，构成 SSAE，其结构如图 2 所示。




图 2 SSAE 结构
Fig.2 The SSAE structure

由图 2 可见，SSAE 将传统自编码器的解码器替换成一个新的编码器 2，编码器 1 学习的特征向量 h_1 作为编码器 2 的输入，然后依次堆叠至 k 层，最终得到更具有代表性、维度更低的特征向量 h_k 。然后将其作为解码器 1 的输入，依次解码，最终通过解码器 k 输出重构后的数据。整个 SSAE 的结构严格对称，保证重构后的数据维度与输入样本数据相同。

SSAE 集合了堆叠自编码器与稀疏自编码器的优势：多层次的结构能够更有效地提取输入数据的隐含特征；对隐含层的稀疏约束项又能够防止训练过程的过拟合问题，提升整个自编码器网络的泛化能力。

3 SSAE+BPNN 软测量模型

由于 SSAE 的训练过程是无监督的，此时整个 SSAE 相当于一个输入数据的生成模型。为实现对软测量参数的回归拟合，删除解码器部分，将编码器 k 最终学习到的特征向量 h_k 输入 BPNN 回归模型中，并通过对整个多层网络执行反向传播，以有监督的方式基于训练数据对网络进行微调，优化网络结构，即可实现参数的软测量。其结构如图 3 所示，此时，SSAE 相当于样本数据的深度特征提取器。

SSAE+BPNN 的软测量模型建立步骤如下：

1) 数据预处理。将火电厂厂级监控信息系统

(SIS) 中采集的样本数据做归一化处理以降低训练成本和避免梯度爆炸，然后划分为训练样本集 X_x 、 Y_x 和测试样本集 X_c 、 Y_c ；




图 3 SSAE+BPNN 软测量模型
Fig.3 The SSAE+BPNN soft sensor model

2) 根据 X_x 的维度，合理确定 SSAE 的堆叠层数与每层的节点数，使用 k 折交叉验证^[24]法确定 BPNN 的最优模型参数；

3) 使用训练样本集 X_x 逐层训练编码器，并使用得到的特征向量 H_x 与 Y_x 训练 BPNN；

4) 将所有编码器与 BPNN 组成堆叠网络，使用训练样本集 X_x 、 Y_x 微调 SSAE+BPNN 网络，优化网络结构；

5) 通过训练好的 SSAE+BPNN 模型，对测试样本集 X_c 、 Y_c 进行软测量测试，以验证模型性能。选取均方误差 MSE (式(5)) 和平方相关系数 R^2 作为模型的评价指标。

$$R^2 = 1 - \frac{\sum_{i=1}^m (\hat{y}_i - y_i)^2}{\sum_{i=1}^m (y_i - \bar{y})^2} \quad (9)$$

式中： m 为样本个数； \hat{y}_i 为第 i 个样本的预测值； y_i 为第 i 个样本的标签数据，即真实输出值； \bar{y} 为全部真实输出值的均值。

4 火电厂实例分析

4.1 数据预处理与工况划分

从某电厂 SIS 数据库中以 20 s 采样间隔导出一个月的相关参数现场数据，经过数据预处理后得到离线数据集共 129 600 组。考虑到不同工况的磨煤机运行方式不一定相同，将 1.2 节参数分析结果中的总燃料量、总风量替换成 A、B、C、D、E、F 磨煤机给煤量与磨煤机入口一次风量。因此飞灰含碳量软测量模型的输入参数最终定为 A—F 磨煤机给煤量 x_1 — x_6 、A—F 磨煤机入口一次风量 x_7 — x_{12} 、主蒸汽流量 x_{13} 、主蒸汽压力 x_{14} 、机组负荷 x_{15} 、排烟温度 x_{16} 与烟气含氧量 x_{17} ，输出参数为飞灰含碳量 y 。

研究不同工况下的飞灰含碳量软测量，首先要对机组运行工况进行划分。考虑到机组负荷、主蒸汽流量与总燃料量是影响机组运行状态的主要因

素,采用对其模糊聚类的方法来划分锅炉工况。同时为了保证聚类结果能最有效地划分工况,选择能够根据参数特征自主优化该参数聚类数目的竞争凝聚算法^[25]进行模糊聚类分析。将聚类结果的每一类作为一种工况,并分析每种工况的磨煤机组合方式,最终得到10种工况,见表2。

表2 工况划分结果
Tab.2 The result of operating conditions division

工况	负荷/MW	主蒸汽流量/(t·h ⁻¹)	总燃料量/(t·h ⁻¹)	常见磨组合
1	652.56	1 931.91	239.53	ABCDE
2	617.73	1 825.73	230.88	ABCDE
3	555.07	1 634.69	204.80	ABCDE
4	504.51	1 480.54	185.87	ABCDE
5	451.73	1 319.63	166.96	ABCDE
6	401.63	1 166.88	150.38	ABCD/ABCDE
7	351.37	1 013.65	135.30	ABCD
8	331.00	951.55	127.41	ABCD
9	269.73	764.75	105.86	ABCD
10	213.46	593.20	87.73	ABC

4.2 SSAE+BPNN 与 BPNN 对比验证

由于深度学习模型需要大量且覆盖面广的训练样本,因此从各工况数据中分别随机选取1000组数据用于模型训练,从离线数据集中随机选取除训练数据外的连续1000组数据作为测试样本。为验证SSAE-BPNN模型的优越性,将其与单独的BPNN软测量模型进行比较。根据输入参数的维度,设置SSAE-BPNN的编码器层数为3,其隐含层节点数分别为12、8、4,根据k折交叉验证法确定稀疏项参数为4,稀疏性比例为0.10,BP神经网络的隐含层节点数为4,训练精度为0.0001,学习速率为0.01。对于单独的BPNN模型的参数,训练精度与学习速率设置同上,同样使用k折交叉验证法求得最优隐含层节点数为10。

通过分析SSAE+BPNN、BPNN模型对飞灰含碳量测试样本的预测结果,得到软测量模型的评价指标见表3。

表3 SSAE-BPNN、BPNN模型评价指标
Tab.3 Evaluation index of the SSAE-BPNN and BPNN model

模型	SSAE+BPNN	BPNN
MSE/10 ⁻³	0.135 8	0.799 1
R ²	0.983 2	0.901 3

当MSE的值越小、R²的值越接近1时,模型的性能越好。由表3可知,SSAE+BPNN模型的性能越好。由表3可知,SSAE+BPNN模型的性能越好。

与R²评价指标表现均优于BPNN模型。SSAE+BPNN、BPNN模型预测结果分别与现场测量真实值的对比如图4所示,对应的相对误差如图5所示。

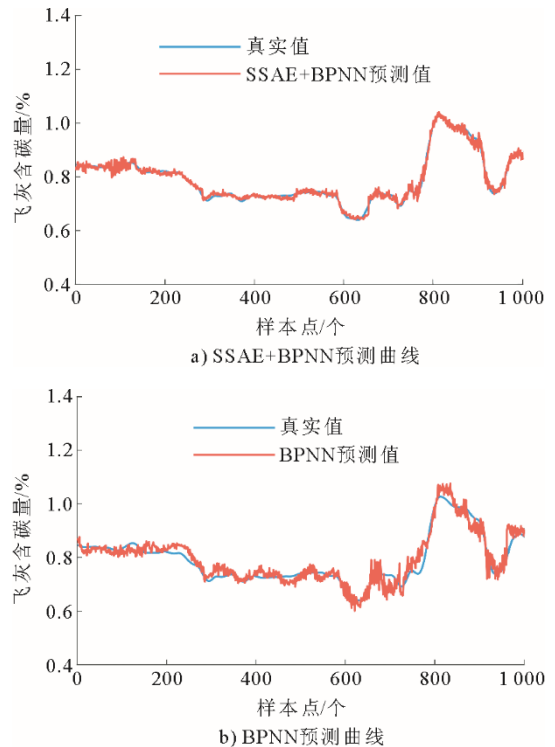


图4 预测曲线与真实曲线对比
Fig.4 Comparison between the prediction curve and real curve

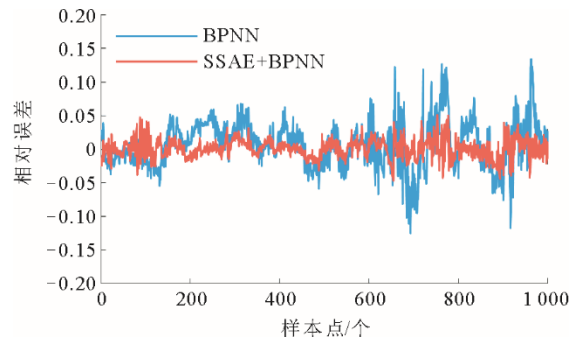


图5 SSAE+BPNN、BPNN相对误差曲线
Fig.5 Relative error curve of the SSAE+BPNN and BPNN model

由图4a)可见,SSAE+BPNN模型的预测曲线较为贴近真实曲线,二者变化趋势一致,且预测曲线毛刺较少,这表明SSAE提取的特征向量能够较好地表征原输入参数。相比之下,图4b)中BPNN模型的预测曲线虽然也能反映出真实曲线的变化趋势,但是曲线毛刺较多,在真实值附近波动剧烈。

由图5可见,SSAE+BPNN模型预测结果的相对误差较小,总体控制在±5%之内,BPNN模型预

测结果的相对误差较大, 最大达到 12.5%。

以上分析表明, SSAE+BPNN 模型具有较强的非线性和隐含特征学习能力, 对飞灰含碳量的预测精度和模型泛化能力均显著优于 BPNN 模型。

4.3 现场应用

将 SSAE+BPNN 模型应用于某电厂 660 MW 机

组的飞灰含碳量软测量任务, 模型使用提取的包含全工况数据的离线数据集训练。在某日机组连续变负荷操作时进行飞灰含碳量软测量测试, 将预测结果数据与输入参数的现场数据以 20 s 采样间隔导出以分析模型表现, 共得到 4 320 组数据。部分现场数据见表 4。当日的机组负荷变化曲线如图 6 所示。

表 4 现场数据
Tab.4 The field data

样本点	$x_1/(t \cdot h^{-1})$	$x_2/(t \cdot h^{-1})$	$x_3/(t \cdot h^{-1})$	$x_4/(t \cdot h^{-1})$	$x_5/(t \cdot h^{-1})$	$x_6/(t \cdot h^{-1})$	$x_7/(t \cdot h^{-1})$	$x_8/(t \cdot h^{-1})$	$x_9/(t \cdot h^{-1})$
1	35.684	35.558	35.627	35.733	0	0	88.977	85.998	86.671
2	35.807	35.734	35.830	35.715	0	0	82.743	87.236	86.024
3	35.686	35.620	35.535	35.500	0	0	88.291	85.734	86.960
...
4 319	47.338	47.411	0	44.453	47.194	47.457	101.665	100.323	0
4 320	47.206	47.437	0	44.364	47.191	47.037	99.760	100.369	0

样本点	$x_{10}/(t \cdot h^{-1})$	$x_{11}/(t \cdot h^{-1})$	$x_{12}/(t \cdot h^{-1})$	$x_{13}/(t \cdot h^{-1})$	x_{14}/MPa	x_{15}/MW	$x_{16}/^{\circ}C$	$x_{17}/\%$	$y/\%$
1	85.911	88.026	6.237	1 159.502	20.998	410.052	115.050	4.519	0.729
2	86.737	86.509	5.978	1 169.749	20.883	406.677	115.150	4.559	0.725
3	85.794	84.247	6.171	1 151.444	20.784	404.034	115.250	4.724	0.720
...
4 319	96.429	102.275	99.374	1 952.696	27.158	657.748	111.700	2.762	1.078
4 320	97.437	100.486	99.277	1 942.549	27.166	658.085	111.750	2.983	1.077




图 6 一日内负荷变化曲线
Fig.6 The one-day load variation curve

由图 6 和表 2 可知, 24 h 内机组运行工况共改变了 5 次, 依次变到工况 8、工况 6、工况 5 和工况 1。SSAE+BPNN 模型对于该连续变工况过程中的飞灰含碳量的预测结果如图 7 所示, 与现场测量真实值的相对误差如图 8 所示。经计算, 评价指标 MSE 值为 0.113 5, R^2 值为 0.988 2, 均处于较好水平。

由图 7 可见, SSAE+BPNN 模型对于飞灰含碳量的预测结果十分贴近飞灰含碳量真实值的变化趋势, 对于飞灰含碳量细小的扰动均能够较为精准的预测。

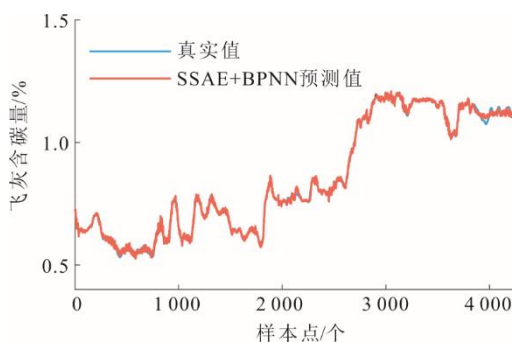


图 7 飞灰含碳量预测曲线
Fig.7 The prediction curve of carbon content in fly ash




图 8 飞灰含碳量预测相对误差曲线
Fig.8 The prediction relative error curve of carbon content in fly ash

由图8可见,飞灰含碳量预测相对误差总体控制在±5%以内,对于波动较缓的部分曲线,预测结果的相对误差则可以控制在±3%以内,经计算,平均相对误差为0.91%。以上结果表明,SSAE+BPNN模型能够实现对机组变负荷运行下的飞灰含碳量高精度软测量。

5 结 论

1) 通过SSAE对原始输入数据进行特征提取,不仅降低了输入维度,简化了BPNN模型结构,其深层带约束的网络结构还有助于提高模型的泛化能力。经过大量随机选取的离线数据样本测试,结果表明,SSAE+BPNN模型的评价指标MSE为 0.1358×10^{-3} , R^2 为0.9832,相对误差在±5%之内,均显著优于BPNN模型,具有更高的预测精度和更好的泛化能力。

2) 将SSAE+BPNN软测量方法应用于某660 MW灵活调峰机组,在连续变工况下,该方法预测飞灰含碳量的平均相对误差为0.91%,总体相对误差控制在±5%以内,预测精度能够满足工程应用要求,对促进机组清洁高效运行有一定意义。

[参 考 文 献]

- [1] 李霞,牛培峰,刘建平,等.基于量子迭代混沌的涡流搜索算法预测锅炉飞灰含碳量[J].动力工程学报,2019,39(7):531-540.
LI Xia, NIU Peifeng, LIU Jianping, et al. Prediction of carbon content in boiler fly ash based on quantum and iterative chaos vortex search algorithm[J]. Journal of Chinese Society of Power Engineering, 2019, 39(7): 531-540.
- [2] 王月兰,马增益,尤海辉,等.基于自适应神经模糊推理系统的煤粉锅炉飞灰含碳量建模[J].热力发电,2018,47(1):26-32.
WANG Yuelan, MA Zengyi, YOU Haihui, et al. Modelling for unburned carbon content in fly ash from coal-fired boilers based on adaptive neuro-fuzzy inference system[J]. Thermal Power Generation, 2018, 47(1): 26-32.
- [3] 牛玉广,任丹彤,李建军.自由空间反射法检测飞灰含碳量的实验研究[J].仪器仪表学报,2018,39(10):126-133.
NIU Yuguang, REN Dantong, LI Jianjun. Experimental research on measuring carbon content of fly ash by free space reflection method[J]. Chinese Journal of Scientific Instrument, 2018, 39(10): 126-133.
- [4] 彭道刚,李丹阳,顾立群,等.基于ADQPSO-SVR的锅炉飞灰含碳量预测研究[J].计算机仿真,2020,37(3):72-77.
PENG Daogang, LI Danyang, GU Liqun, et al. Research on prediction of carbon content in boiler fly ash based on ADQPSO-SVR[J]. Computer Simulation, 2020, 37(3): 72-77.
- [5] 田亮,霍秋宝,刘鑫屏,等.电站锅炉总风量软测量[J].中国电机工程学报,2014,34(8):1261-1267.
TIAN Liang, HUO Qiubao, LIU Xinping, et al. Soft-sensors of the total air volume in utility boilers[J]. Proceedings of the CSEE, 2014, 34(8): 1261-1267.
- [6] 田亮,王桐.供热机组汽轮机低压缸排汽流量软测量[J].系统仿真学报,2018,30(5):1803-1811.
TIAN Liang, WANG Tong. Soft-sensor method of low pressure cylinder exhaust flow of heating units[J]. Journal of System Simulation, 2018, 30(5): 1803-1811.
- [7] 李泽铭,田亮.基于卡尔曼滤波器的循环流化床机组燃料发热量软测量[J].华北电力大学学报(自然科学版),2021,48(2):89-95.
LI Zeming, TIAN Liang. Soft measurement of fuel calorific value of circulating fluidized bed based on kalman filter[J]. Journal of North China Electric Power University(Natural Science Edition), 2021, 48(2): 89-95.
- [8] 赵健,袁瀚,梅宁.燃煤锅炉飞灰含碳量的BP神经网络模型[J].热科学与技术,2016,15(6):499-504.
ZHAO Jian, YUAN Han, MEI Ning. BP neural network model of fly ash carbon content of coal-fired boiler[J]. Journal of Thermal Science and Technology, 2016, 15(6): 499-504.
- [9] 乔源,王建峰,杨永存,等.基于神经网络的飞灰含碳量软测量模型及实现[J].电力科学与工程,2019,35(11):55-61.
QIAO Yuan, WANG Jianfeng, YANG Yongcun, et al. Soft measurement model and implementation of fly ash carbon content based on neural network[J]. Electric Power Science and Engineering, 2019, 35(11): 55-61.
- [10] 王春林,周昊,周樟华,等.基于支持向量机的大型电厂锅炉飞灰含碳量建模[J].中国电机工程学报,2005,25(20):72-76.
WANG Chunlin, ZHOU Hao, ZHOU Zhanghua, et al. Support vector machine modeling on the unburned carbon in fly ash[J]. Proceedings of the CSEE, 2005, 25(20): 72-76.
- [11] 卞和营,方彦军.基于支持向量回归的飞灰含碳量软测量[J].热力发电,2014,43(10):46-50.
BIAN Heying, FANG Yanjun. SVR-based study on soft-sensing measurement of carbon content in fly ash[J]. Thermal Power Generation, 2014, 43(10): 46-50.
- [12] 王伟,常浩,王宝玉.飞灰含碳量自适应校正WLSSVM软测量模型[J].热力发电,2013,42(8):75-80.
WANG Wei, CHANG Hao, WANG Baoyu. A WLSSVM based self-adaptive correction soft-sensing model for carbon content measurement in fly ash[J]. Thermal Power Generation, 2013, 42(8): 75-80.
- [13] 麻红波,余瑞锋,倪艳红,等.基于GSA-LSSVM的循环流化床锅炉飞灰含碳量预测[J].锅炉技术,2016,47(2):53-56.
MA Hongbo, YU Ruifeng, NI Yanhong, et al. The prediction of the carbon content of fly ash of circulating fluidized bed boilers based on GSA-LSSVM[J]. Boiler Technology, 2016, 47(2): 53-56.
- [14] 徐志强,任蜜蜂,程兰,等.基于时间近邻拉氏正则的多工况软测量回归[J].仪器仪表学报,2021,42(11):279-287.
XU Zhiqiang, REN Mifeng, CHENG Lan, et al. Multi-conditions soft sensor regression based on the time-nearest neighbor Laplacian regularization[J]. Chinese Journal of Scientific Instrument, 2021, 42(11): 279-287.

- [15] YAO L, GE Z Q. Deep learning of semisupervised process data with hierarchical extreme learning machine and soft sensor application[J]. IEEE Transactions on Industrial Electronics, 2018, 65(2): 1490-1498.
- [16] 潘红光, 裴嘉宝, 苏涛, 等. 基于 LSTM 的燃煤电厂 NO_x 排量软测量[J]. 西安科技大学学报, 2022, 42(2): 362-370.
PAN Hongguang, PEI Jiabao, SU Tao, et al. LSTM-based soft sensor of NO_x emissions from coal-fired power plants[J]. Journal of Xi'an University of Science and Technology, 2022, 42(2): 362-370.
- [17] 支恩玮, 闫飞, 任密峰, 等. 基于迁移变分自编码器-标签映射的湿式球磨机负荷参数软测量[J]. 化工学报, 2019, 70(增刊 1): 150-157.
ZHI Enwei, YAN Fei, REN Mifeng, et al. Soft sensor of wet ball mill load parameters based on transfer variational autoencoder-label mapping[J]. CIESC Journal, 2019, 70(Suppl.1): 150-157.
- [18] LU C, WANG Z Y, QIN W L, et al. Fault diagnosis of rotary machinery components using a stacked denoising autoencoder-based health state identification[J]. Signal Processing, 2017, 130: 377-388.
- [19] YU J, ZHOU X. One-dimensional residual convolutional autoencoder based feature learning for gearbox fault diagnosis[J]. IEEE Transactions on Industrial Informatics, 2020, 16(10): 6347-6358.
- [20] 李江坤, 黄海燕. 互信息深度稀疏自编码融合 DLSTM 预测网络[J]. 计算机工程与应用, 2022, 58(20): 277-285.
LI Jiangkun, HUANG Haiyan. Mutual information deep sparse auto-encoding hybrid DLSTM prediction network[J]. Computer Engineering and Applications, 2022, 58(20): 277-285.
- [21] 孙林凯, 金家善, 耿俊豹. 基于修正邓氏灰色关联度的设备费用影响因素分析[J]. 数学的实践与认识, 2012, 42(8): 140-145.
SUN Linkai, JIN Jiashan, GENG Junbao. Analysis of influencing factors of equipment cost based on modified Deng's grey relational degree[J]. Mathematics in Practice and Theory, 2012, 42(8): 140-145.
- [22] 袁非牛, 章琳, 史劲亭, 等. 自编码神经网络理论及应用综述[J]. 计算机学报, 2019, 42(1): 203-230.
YUAN Feiniu, ZHANG Lin, SHI Jinting, et al. Theories and applications of auto-encoder neural networks: a literature survey[J]. Chinese Journal of Computers, 2019, 42(1): 203-230.
- [23] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504-507.
- [24] CAI H H, WU Z H, HUANG C, et al. Wind power forecasting based on ensemble empirical mode decomposition with generalized regression neural network based on cross-validated method[J]. Journal of Electrical Engineering & Technology, 2019, 14(5): 1823-1829.
- [25] 康英伟, 周昊, 郭为民, 等. 基于模糊关联规则的脱硫系统运行优化[J]. 热能动力工程, 2020, 35(7): 145-151.
KANG Yingwei, ZHOU Hao, GUO Weimin, et al. Operation optimization of desulfurization system based on fuzzy association rules[J]. Journal of Engineering for Thermal Energy and Power, 2020, 35(7): 145-151.

(责任编辑 邓玲惠)