



基于改进堆叠自动编码器的循环冷却水系统工艺介质温度预测控制方法

左为恒, 宋璐璐

引用本文:

左为恒, 宋璐璐. 基于改进堆叠自动编码器的循环冷却水系统工艺介质温度预测控制方法[J]. 控制与决策, 2020, 35(12): 2835–2844.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2019.0694>

您可能感兴趣的其他文章

Articles you may be interested in

基于改进萤火虫算法的区域交通信号配时优化

Timing optimization of regional traffic signals based on improved firefly algorithm

控制与决策. 2020, 35(12): 2829–2834 <https://doi.org/10.13195/j.kzyjc.2019.1835>

参数未知的离散系统Q-学习优化状态估计与控制

Q-learning optimal state estimation and control for discrete systems with unknown parameters

控制与决策. 2020, 35(12): 2889–2897 <https://doi.org/10.13195/j.kzyjc.2019.0180>

阴影条件下基于迁移强化学习的光伏系统最大功率跟踪

Transfer reinforcement learning based maximum power point tracker of PV systems under partial shading condition

控制与决策. 2020, 35(12): 2939–2949 <https://doi.org/10.13195/j.kzyjc.2019.0412>

复合类别航站楼分配问题的改进和声搜索算法

Solving composite airport gate allocation problem with improved harmony search

控制与决策. 2020, 35(11): 2743–2751 <https://doi.org/10.13195/j.kzyjc.2019.0242>

基于高炉炉况评价和反馈补偿的喷煤量决策优化

Decision-making optimization of coal injection volume based on evaluation of blast furnace condition

控制与决策. 2020, 35(11): 2803–2809 <https://doi.org/10.13195/j.kzyjc.2018.1553>

基于改进堆叠自动编码器的循环冷却水系统 工艺介质温度预测控制方法

左为恒[†], 宋璐璐

(重庆大学 电气工程学院, 重庆 400044)

摘 要: 循环冷却水系统中冷却供给量与工艺介质冷却需求量之间往往存在“大马拉小车”的现象, 造成大量的冷却资源浪费. 为了匹配冷却需求量与供给量, 提高循环冷却水系统能源利用率, 给出一种基于多工艺介质温度目标循环冷却水最小压差控制系统, 并将深度学习引入工艺介质温度预测研究中, 提出一种基于改进堆叠自动编码器(improved stacked auto encoders, ISAE)的工艺介质温度预测方法. 首先, 对工业现场数据进行清洗; 然后, 将多个自动编码器堆叠, 构建深度学习网络结构, 采用“逐层贪婪无监督预训练-参数微调”方法训练网络参数, 并基于均方根反向传播(root mean square back propagation, RMSProp)优化方法对网络参数进行微调, 减小陷入局部最优的概率; 最后, 利用某化工厂历史运行数据进行测试, 与浅层神经网络、未改进的SAE方法进行比较, 所得结果表明, 所提出的ISAE方法的预测准确性高, 预测的工艺介质温度平均百分比误差仅为0.85%, 且泛化能力优于未改进的SAE算法

关键词: 循环冷却水系统; 工艺介质温度; 预测控制; 改进堆叠自动编码器; 深度学习; 数据驱动

中图分类号: TP301

文献标志码: A

DOI: 10.13195/j.kzyjc.2019.0694

开放科学(资源服务)标识码(OSID):



引用格式: 左为恒, 宋璐璐. 基于改进堆叠自动编码器的循环冷却水系统工艺介质温度预测控制方法[J]. 控制与决策, 2020, 35(12): 2835-2844.

Predictive control method of process medium temperature in circulating cooling water system based on improved stacked auto encoders

ZUO Wei-heng[†], SONG Lu-lu

(School of Electrical Engineering, Chongqing University, Chongqing 400044, China)

Abstract: The designed capacity of cooling supply is much higher than demand of medium in a circulating cooling water system, which leads to the great waste of electricity energy. In order to keep balance between cooling demand and supply, and improve the energy efficiency of the circulating cooling water system, a minimum differential pressure control scheme for the multi-process medium temperature target of the circulating cooling water system is presented, and deep learning is applied to the study of the medium temperature prediction. And a temperature prediction method for media based on improved stacked auto encoders (ISAE) is proposed. Firstly, the industrial data is cleaned. Then, multiple autoencoders are stacked, and the “greedy unsupervised pre-training layer by layer” method is used to train network parameters. The root mean square back propagation (RMSProp) optimization is deployed to fine-tune network parameters to reduce the possibility of falling into local optimums. Finally, the process medium temperature prediction model is obtained using off-line training of the historical operation data of a chemical plant. Compared with the results of shallow neural networks and unmodified SAE methods, the prediction accuracy of the proposed ISAE method is high, the mean absolute percentage error (MAPE) is only 0.85 %, and the generalization ability is better than the unmodified SAE algorithm.

Keywords: circulating cooling water system; process medium temperature; predictive control; improved stacked automatic encoder; deep learning; data driving

0 引 言

为了应对全球能源危机,作为能耗占比最高的工业领域(约占据国家能耗总量70%)^[1],正不断地进行

着节能控制技术革新.循环冷却水系统是工业生产的重要组成部分,对消除生产过程中产生的废热,提高设备运行效率与寿命以及保证产品质量起到至关

收稿日期: 2019-05-19; 修回日期: 2019-09-06.

[†]通讯作者. E-mail: zwheng@126.com.

重要的作用^[2]. 在循环冷却水系统设计阶段,为满足生产要求,通常依据最大负荷并给予一定富余量而盲目提高循环冷却水系统冷却能力,与实际工业生产中工艺介质冷却需求之间往往存在“大马拉小车”现象,造成循环冷却水系统中大量冷却水的浪费^[3]. 在循环冷却水系统运行阶段,为匹配工艺介质冷却需求量与冷却供给量,本文给出一种多工艺介质温度目标循环冷却水最小压差控制系统,该节能控制方案将冷却量匹配问题转换为工艺介质温度与冷却给回水压差设定值的匹配问题.

循环冷却水系统对工艺介质降温的过程具有典型的大滞后特性,控制效果难以及时反应,对工艺介质温度控制系统的调节时间、控制精度和稳定性等方面造成较大影响^[4-5]. 解决大滞后系统控制问题的关键是消除滞后对被控量变化的影响,提前预知被控量变化趋势,因此,预测控制是控制滞后对象的有效方法之一. 文献[6]利用学习网络辨识被控量的延时时间参数,并与PID控制器相结合构成模型预测控制. 但是,PID算法属于“事后调节”,随着被控对象参数变化,控制效果将会变差^[7]. 文献[8]利用最小二乘支持向量机(support vector machine, SVM)方法对大滞后系统温度进行预测,但是, SVM是一种小样本学习方法,当样本个数和特征值种类过多时,存在运算时间久、预算精度低的缺点,难以适用于工业生产实际中大规模数据训练^[9]. 文献[10]利用BP神经网络模型实现煤层瓦斯渗透率的预测,但是, BP算法的本质为梯度下降法且初始参数随机得到,算法效率较低、收敛速度慢、泛化能力差、易陷入局部最优^[11]. 另外,上述预测方法采用的是浅层神经网络方法,对输入数据典型特征的处理能力有限,难以映射复杂情况下的输入-输出关系,过拟合或欠拟合问题突出、泛化能力较差.

区别于传统浅层学习方法,深度学习^[12]通过构建含多隐含层的人工神经网络,将原始空间的样本特征映射到新的特征空间,逐层训练,进而挖掘出大量具有代表性的有效特征信息,能够有效表征复杂函数,具有较高的预测精度和良好的泛化能力. 堆栈自动编码器(stacked autoEncoders, SAE)^[13-14]作为深度学习的一种高效算法,通过逐层贪婪无监督预训练得到网络初始化参数,然后通过反向传播的有监督学习对网络参数进行微调,有效地解决了传统神经网络参数随机初始化导致的一系列问题. SAE的这些优点为具有大延时、大惯性特征的循环冷却水工艺介质温度预测控制提供了一种新的思路.

本文为了实时匹配循环冷却水系统冷却需求量与供给量,提高循环冷却水系统能源利用率,给出一种多工艺介质温度目标循环冷却水最小压差控制系统,并将深度学习引入工艺介质温度预测研究中,提出一种基于改进堆叠自动编码器(improved stacked auto encoders, ISAE)工艺介质温度预测方法,以确定工艺介质温度与冷却给回水压差之间的高维非线性关系. 首先,对数据进行清洗;然后,确定多层神经网络参数,并利用“逐层贪婪无监督预训练-参数微调”两阶段训练方法优化网络参数,构建基于改进堆叠自动编码器的温度预测深度学习网络;最后,以某化工厂现场数据为基础,开展算例测试,与浅层神经网络以及未改进的SAE方法所得结果进行比较,从而验证所提出方法的优越性.

1 基于多工艺介质温度目标的循环冷却水最小压差控制系统

循环冷却水系统中,工艺介质与冷却水在换热器内完成热量传递. 表1为某化工厂循环冷却水系统换热器列表,工业生产现场换热器数量庞大,工艺介质种类繁多,每个换热器中工艺介质设计指标各不相同. 工艺介质温度设计指标 T_{zp} 是某化工厂技术部门综合考虑生产安全、工艺品质等因素确定的最优温度指标.

表 1 某化工厂循环冷却水系统换热器列表

序号	换热器编号	换热器名称	工艺介质温度设计指标 $T_{zp}/^{\circ}\text{C}$
1	1# 换热器	氨冷凝器	37
2	2# 换热器	空压机压冷器	100
⋮	⋮	⋮	⋮
48	48# 换热器	碳黑罐 A	70
49	49# 换热器	热再生塔冷凝器	40
⋮	⋮	⋮	⋮

面对大体量、指标互异的工艺介质温度控制指标,在图1所示的多工艺介质温度目标循环冷却水最小压差控制系统中,数据采集中心在线计算 M 个工艺介质温度检测值与其对应的温度设计指标 T_{zp} 差值,构成工艺介质温度偏差序列. 工艺介质温度最危险点选择器将温度偏差最小的工艺介质确定为工艺介质温度最危险点,即该时刻超出温度设定范围可能性最大的工艺介质,编号为 k . 将工艺介质 k 温度检测值、工艺介质 k 温度设计指标以及其他检测变量输入到工艺介质温度外环控制器,同时输出冷却给回水压差预设值. 将冷却给回水压差检测值与给定值做偏差并输入给回水压差内环PID控制器,以冷却给回水




图1 多工艺介质温度目标循环冷却水最小压差控制系统

压差偏差最小为目标函数,输出设置在冷却塔中冷却水上塔管处的上塔阀的阀门开度.通过现场调节各上塔阀的阀门开度,改变水泵处理冷却水流量,能够减少循环冷却水系统中水泵机组的能耗浪费,实现循环冷却水系统节能运行.

在多工艺介质温度目标循环冷却水最小压差控制系统中,根据工艺介质温度确定冷却给回水压差预设值的控制策略比较复杂,呈多变量非线性关系,且工艺介质温度预测模型对温度预测的精度直接影响整个节能控制系统的运行可靠性和节能效果.因此,利用机器学习及数据挖掘技术确定循环冷却水系统中工艺介质温度与给回水压差设定值之间的关系,对实现多工艺介质温度目标循环冷却水节能控制系统的协调稳定工作和节能优化运行具有重大意义.

2 工艺介质温度预测方案

为使循环冷却水系统工艺介质在 τ 时刻达到某一预期温度调控指标,需要在 $\tau-1$ 时刻对 τ 时刻工艺介质温度进行预测控制,而 τ 时刻工艺介质温度会受到 $\tau-1$ 至 $\tau-d$ 时刻的工艺介质历史温度的影响,本




图2 工艺介质温度预测方案

文提出的工艺介质温度预测方案如图2所示. 工艺介质温度 ISAE 网络的输入数据时间维度(工艺介质温度变化延迟参数 d)与样本数据滞后等特性相关,需要进行相关的数据预运算确定.

3 堆叠自动编码器

自动编码器(auto encoder, AE)网络是构建深度神经网络的基础,如图3所示, $\mathbf{X}_i$ 为样本集中的第 i 个训练样本,维数为 n ; $\mathbf{h}^i$ 为第 i 个样本对应的特征向量,维数为 m ; $\hat{\mathbf{X}}^i$ 为第 i 个样本对应的输出向量,维数为 n . 由输入层到隐含层的非线性变换为编码器过程,由隐含层到输出层的非线性变换为解码器过程.




图3 自动编码器结构

编码器的数学表达式如下:

$$\mathbf{H} = s_f(\mathbf{P}\mathbf{X} + \mathbf{Q}). \quad (1)$$

其中: $\mathbf{X}$ 为输入样本集合, $\mathbf{H}$ 为隐含层特征向量集合; $\mathbf{P}$ 为 AE 输入层与隐含层的权值矩阵, $\mathbf{Q}$ 为 AE 输入层与隐含层的阈值矩阵, $\mathbf{P}$ 和 $\mathbf{Q}$ 的初始权重随机生成; s_f 为编码器的神经元激活函数,通常采用 sigmoid 函数,即

$$s_f(z) = 1/(1 + \exp(-z)), \quad (2)$$

z 为输入向量.

解码器的数学表达式如下:

$$\hat{\mathbf{X}} = s_g(\mathbf{P}'\mathbf{H} + \mathbf{Q}'). \quad (3)$$

其中: $\hat{\mathbf{X}}$ 为输出向量集合; $\mathbf{P}'$ 为 AE 隐含层与输出层的权值矩阵, $\mathbf{Q}'$ 为 AE 隐含层与输出层的阈值矩阵; s_g 为解码器的神经元激活函数,通常采用 sigmoid 函数.

为了优化自动编码器参数,通过梯度下降算法不断调整网络权值和阈值,降低重构误差. 重构误差公式和梯度下降算法分别如下所示:

$$L(\mathbf{X}^i, \hat{\mathbf{X}}^i) = \frac{1}{N} \sum_{i=1}^N \|\mathbf{X}^i - \hat{\mathbf{X}}^i\|^2, \quad (4)$$

$$\begin{cases} \mathbf{P} \leftarrow \mathbf{P} - l \frac{\partial L(\mathbf{X}, \hat{\mathbf{X}})}{\partial \mathbf{P}}, \\ \mathbf{Q} \leftarrow \mathbf{Q} - l \frac{\partial L(\mathbf{X}, \hat{\mathbf{X}})}{\partial \mathbf{Q}}. \end{cases} \quad (5)$$

其中: N 为样本数目; l 为学习率; $\partial L(\mathbf{X}, \hat{\mathbf{X}})/\partial \mathbf{P}$ 表示 $L(\mathbf{X}, \hat{\mathbf{X}})$ 对权值 $\mathbf{P}$ 求偏导, $\partial L(\mathbf{X}, \hat{\mathbf{X}})/\partial \mathbf{Q}$ 表示 $L(\mathbf{X}, \hat{\mathbf{X}})$ 对阈值 $\mathbf{Q}$ 求偏导.

堆叠自动编码器(stacked auto encoders, SAE)由多个 AE 逐层堆叠,如图4所示,底层 AE 的输入为原始数据,隐含层输出数据作为上层 AE 的输入数据, $\mathbf{W}_\sigma$ 为 SAE 第 $\sigma - 1$ 层隐含层与第 σ 层隐含层的权重矩阵, $\mathbf{B}_\sigma$ 为 SAE 第 $\sigma - 1$ 层隐含层与第 σ 层隐含层的阈值矩阵,其中 $1 \leq \sigma \leq w + 1$, w 为隐含层层数.




图4 堆叠自动编码器架构

SAE 训练过程分为逐层贪婪无监督预训练和有监督微调两个步骤. 其中: SAE 逐层贪婪无监督预训练流程如下面的图5中所示,逐层贪婪无监督预训练通过逐层训练得到网络的权重和阈值.

当逐层贪婪无监督预训练完成后,将隐含层堆叠,其输入数据与输出数据关系为

$$\check{\mathbf{y}}^i = f_{(\mathbf{W}, \mathbf{B})}(\mathbf{X}^i). \quad (6)$$

其中: f 为激活函数; $\mathbf{X}^i$ 为第 i 个训练样本的输入变量; $\mathbf{W}$ 、 $\mathbf{B}$ 分别为堆叠编码器各层网络权重和阈值集合, $\mathbf{W} = \{\mathbf{W}_1, \mathbf{W}_2, \dots, \mathbf{W}_w\}$, $\mathbf{B} = \{\mathbf{B}_1, \mathbf{B}_2, \dots, \mathbf{B}_w\}$; $\check{\mathbf{y}}^i$ 为第 i 个样本的预测值.

未改进的 SAE 有监督微调采用 BP 反向传播算法,通过构造参数优化目标函数,即实际值与预测值的误差损失函数,有

$$\min E(\mathbf{W}, \mathbf{B}) = \sum_{i=1}^N (\mathbf{y}^i - f_{(\mathbf{W}, \mathbf{B})}(\mathbf{X}^i))^2. \quad (7)$$

其中: N 为样本总个数, $\mathbf{y}^i$ 为第 i 个样本的实际值. 从而实现自上而下的反向传播,对整个网络权重和阈值进行微调,以减小预测值与实际值的误差.



图5 基于ISAE的 $p\#$ 工艺介质温度预测控制算法流程

图6 在线应用方案

4 基于ISAE的循环冷却水系统工艺介质温度预测控制算法

图5为基于ISAE的 $p\#$ 工艺介质温度预测控制流程,主要分为离线训练和在线应用两大功能模块,在线应用方案如图6所示。为了提高算法效率,本文在SAE参数微调过程中引入了RMSProp优化策略。

4.1 工业数据清洗

工厂通常处于强电环境中,难以避免电磁等干扰,造成通讯中数据紊乱,虽然使用校验手段可以提高数据传输的准确性,但由于数据量巨大,仍可能存在能够通过校验的“脏数据”,从而影响数据分析结果^[15-16]。因此,为提高预测的准确性,给预测算法提供

正确的分析数据,需要对大量采集数据进行清洗.某化工厂循环冷却水系统生产现场下位机每1 min采集一次数据,由该系统历史记录数据可知,各变量数据变化间隔时间较长,具有连续变化特性,因此,根据数据变化特性,从生产开始,除去开始及结束两个时间点数据,每5个点取平均,作为该点的值.

图7为7月1日(00:00~23:59)1#换热器内工艺介质温度数据清洗前后对比情况.宏观上看,在夜间(00:00~05:00)和中午(12:00~15:00)时间段内,工艺介质温度较高的原因分别是夜间生产负荷相对城市正常工作用电时间增加,午间的环境温度处于一天中的巅峰;微观上看,原始数据中的突变点被平滑,有利于减少数据污染.




图7 7月1日(00:00~23:59)1#换热器内工艺介质温度数据清洗前后对比

4.2 离线训练

step 1: 将丰富的工业生产现场循环冷却水系统运行的历史数据库经数据清洗后作为数据样本集.

step 2: 将工业历史运行记录数据: $t-1$ 时刻循环冷却水系统冷却给水温度检测值 T_{gs}^{t-1} 、 $t-1$ 时刻循环冷却水系统冷却回水温度检测值 T_{hs}^{t-1} 、 $t-1$ 时刻循环冷却水系统冷却给水压力检测值 P_{gs}^t 、 $t-1$ 时刻循环冷却水系统冷却回水压力检测值 P_{hs}^t 以及 $t-1 \sim t-d$ 时刻1#换热器内工艺介质温度检测值 $T_{jc,p}^{t-d} \dots T_{jc,p}^{t-1}$ 作为输入数据, T 时刻1#换热器内工艺介质温度检测值 $T_{jc,p}^t$ 作为输出数据,并将数据样本集分为训练样本集和测试样本集两部分,利用下式对输入数据和输出数据进行归一化处理以消除各个变量之间量级差异影响:

$$\hat{x}_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}}. \quad (8)$$

其中: x_i 为第 i 个变量, $x_{\max}$ 、 $x_{\min}$ 分别为变量 x_i 的最大值和最小值, $\hat{x}_i$ 为归一化后的变量.

step 3: 逐层贪婪无监督预训练.由于样本量巨大,可将训练样本划分为若干组小批量的数据集,依次进行训练以提高效率.以训练样本的特征向量作为输入数据,依次迭代,逐层训练,得到网络初始化的

权值和阈值,如图7所示.

step 4: 参数微调. RMSProp优化方法相比于传统的BP反向传播方法,是一种自适应学习率算法,通过增加累计平方梯度加速算法收敛,有利于提高网络结构泛化能力.因此,本文采用RMSProp优化方法对经逐层贪婪无监督预训练的网络权重 $\mathbf{W}$ 和阈值 $\mathbf{B}$ 进行微调,直到迭代次数达到设定值为止.其具体步骤如下:

1) 设置全局学习率 $g = 0.5$ 、衰减速率 $\rho = 0.9$,初始化矩阵累计平方梯度 $r_1 = 0$ 、阈值矩阵累计平方梯度 $r_2 = 0$ ^[17-19].

2) 从训练集中选取包含 m_s 个样本的小批量数据集,根据误差损失函数计算第 w 层隐含层与输出层之间的权值矩阵和阈值矩阵的梯度,有

$$\begin{cases} \mathbf{W}_{w+1} \leftarrow \frac{1}{m_s} \frac{\partial \sum_{i=1}^{m_s} (y^i - f(\mathbf{W}, \mathbf{B})(\mathbf{X}^i))^2}{\partial \mathbf{W}_{w+1}}, \\ \mathbf{b}_{w+1} \leftarrow \frac{1}{m_s} \frac{\partial \sum_{i=1}^{m_s} (y^i - f(\mathbf{W}, \mathbf{B})(\mathbf{X}^i))^2}{\partial \mathbf{B}_{w+1}}. \end{cases} \quad (9)$$

其中: $\mathbf{W}_{w+1}$ 、 $\mathbf{b}_{w+1}$ 分别表示第 w 层隐含层与输出层之间的权值矩阵和阈值矩阵的梯度, $\mathbf{W}_{w+1}$ 、 $\mathbf{B}_{w+1}$ 分别表示第 w 层隐含层与输出层之间的权重矩阵和阈值矩阵, y^i 、 $f(\mathbf{W}, \mathbf{B})(\mathbf{X}^i)$ 分别表示第 i 个样本的频率指标的实际值矩阵和堆栈降噪自动编码器的频率指标预测值矩阵, $\mathbf{X}^i$ 表示第 i 个样本的输入参数.

$$\begin{cases} \mathbf{W}_\sigma \leftarrow \mathbf{W}_{\sigma+1} \frac{\partial (\mathbf{W}_{\sigma+1} \mathbf{H}_\sigma + \mathbf{B}_{\sigma+1})}{\partial \mathbf{W}_\sigma}, \\ \mathbf{b}_\sigma \leftarrow \mathbf{b}_{\sigma+1} \frac{\partial (\mathbf{W}_{\sigma+1} \mathbf{H}_\sigma + \mathbf{B}_{\sigma+1})}{\partial \mathbf{W}_\sigma}. \end{cases} \quad (10)$$

其中: $\mathbf{H}_\sigma$ 为第 σ 层隐含层的特征向量; σ 介于1与 $w+1$ 之间时, $\mathbf{W}_\sigma$ 、 $\mathbf{b}_\sigma$ 分别表示第 $\sigma-1$ 层隐含层与第 σ 层隐含层之间的权值矩阵和阈值矩阵的梯度, $\mathbf{H}_\sigma = s_f(\mathbf{W}_\sigma \mathbf{H}_{\sigma-1} + \mathbf{B}_\sigma)$; σ 取值为1时, $\mathbf{W}_\sigma$ 、 $\mathbf{b}_\sigma$ 分别表示第1层隐含层与输入层之间的权值矩阵和阈值矩阵的梯度, $\mathbf{H}_1 = s_f(\mathbf{W}_1 \mathbf{X}^i + \mathbf{B}_1)$.

3) 基于权值矩阵和阈值矩阵的梯度计算每组权值矩阵和阈值矩阵所对应的累计平方梯度,即

$$\begin{cases} r_1 = \rho r_1 + 1(1 - \rho) \mathbf{W} \odot \mathbf{W}, \\ r_2 = \rho r_2 + 1(1 - \rho) \mathbf{b} \odot \mathbf{b}, \end{cases} \quad (11)$$

其中 $\odot$ 为逐元素乘积符号.

4) 根据权重矩阵和阈值矩阵更新公式更新每组权重矩阵和阈值矩阵,权重矩阵和阈值矩阵的更新公式如下:

$$\begin{cases} \mathbf{W} = \mathbf{W} - \frac{g}{\sqrt{r_1}} \odot \mathbf{w}, \\ \mathbf{B} = \mathbf{B} - \frac{g}{\sqrt{r_2}} \odot \mathbf{b}. \end{cases} \quad (12)$$

5) 当迭代次数达到要求时, 停止运算, 否则返回第2)步继续执行计算。

step 5: 使用测试样本数据集测试训练之后的ISAE. 采用平均百分比误差(MAPE)作为衡量ISAE评估性能的标准, 表达式为

$$\text{MAPE} = \frac{1}{N} \sum_{i=1}^N \left| \frac{\mathbf{y}^i - \hat{\mathbf{y}}^i}{\mathbf{y}^i} \right| \times 100\%, \quad (13)$$

其中 $\mathbf{y}^i$ 、 $\hat{\mathbf{y}}^i$ 分别为第 i 个样本工艺介质温度的实际值和通过ISAE得到的预测值。

离线训练迭代次数的设置策略为: 在所得到的网络参数基础上, 逐步增加迭代轮数(每轮迭代次数可设为250), 然后返回step 4, 继续执行网络参数微调. 若所得到的测试样本集MAPE值减小, 则继续增加迭代次数; 若MAPE值变大, 则将未增加迭代次数前所对应的迭代次数作为设定值, 以该设定的迭代次数下得到的网络作为训练好的深度学习网络。

4.3 在线应用

利用离线训练完成的ISAE工艺介质温度预测模型, 实现对工艺介质温度最危险点 k 的在线温度预测. 图6为在线应用方案图, 将通过在线检测获得的 $\tau-1$ 时刻现场检测值、 $\tau-d$ 至 $\tau-2$ 时刻工艺介质 k 温度作为输入数据, 输出数据为 τ 时刻给回水压差预设值 ΔP_{js}^τ . 图6中, 计数参数 q 的初始值为0, δ 为最小压差变化梯度. 将上述输入数据进行归一化处理, 输入到编号为 k 的换热器内工艺介质温度预测模型中, 然后将输出数据进行反归一化处理, 得到 τ 时刻 k 换热器内工艺介质温度预测值, 并与 k 换热器内工艺介质温度设定指标作差. 若 $|e_{k,y}^\tau| < |e_s|$, 则输出 τ 时刻给回水压差预设值 ΔP_{js}^τ ; 否则, q 值自动加1, 重新进行温度预测, 循环预测至符合输出条件. 其中: $e_{k,y}^\tau$ 为 τ 时刻 k 换热器内工艺介质温度预测偏差, e_s 是设定的最大工艺介质温度偏差值。

5 算例分析

在Matlab平台上编写本文所提出的算法, 计算机配置为CPU Intel Core i5、内存4 GB. 基于某化工厂循环冷却水系统历史运行数据开展测试, 本算例以表1中1#换热器(氨冷凝器)内工艺介质温度为控制对象, 建立1#换热器内工艺介质温度预测控制模型。

5.1 样本数据集的构造

统计某化工厂2018年夏季(6月1日~8月31日)1#换热器内工艺介质温度以及循环冷却水系统

运行历史数据, 现场设置的智能传感器采样周期为1 min, 数据集较大, 共有132 480组样本数据, 选取5个点进行平均, 数据清洗后剩余26 496组数据, 本文随机选取其中20 000组数据作为训练样本集, 另外6 496组数据作为测试样本集。

5.2 小批量数据集数量的确定

深度学习算法在逐层贪婪无监督训练中通常通过小批量随机抽取 m_s 个训练样本进行离线训练, 称为小批量随机方法. 由于在逐层贪婪无监督训练中希望梯度估计是互相独立的, 实践中一般会将样本顺序随机打乱, 然后选取训练样本和测试样本^[20]. 小批量方法的优点在于: 1) 减少了迭代时计算机内存的占用率, 为实现海量数据的训练学习提供了可能; 2) 可以使收敛结果更加接近梯度下降的效果. 通常将样本设置为20~100批量^[21-22], 每次随机选取的 m_s 样本数为 $m_s = \text{总训练样本 } N / \text{小批量组数 } \mu_s$, 每一次迭代需要遍历整个数据集. 该思路与参数微调中将训练样本划分为若干组小批量的数据集, 依次进行训练的思想是一样的。

小批量随机方法对深度神经网络的影响效果可以通过相同训练次数下的训练时间以及工艺介质温度MAPE值进行对比分析. 表2比较了迭代次数为1 000时, 采用不同批量[1 ($m_s = 20\,000$)、10 ($m_s = 2\,000$)、20 ($m_s = 1\,000$)、40 ($m_s = 500$)、50 ($m_s = 400$)、60 ($m_s = 333$)、80 ($m_s = 250$)、100 ($m_s = 200$)]对20 000组训练数据进行训练的结果。

表2 1 000次迭代训练下, 不同样本数的训练时间及MAPE值对比

样本数	训练时间/min	工艺介质温度 MAPE/%
20 000	11.68	1.63
2 000	9.72	1.52
1 000	9.86	1.58
500	9.37	1.26
400	8.56	1.36
333	8.12	1.56
250	10.28	1.48
200	10.52	1.45

由表2可以看出: 当以20 000组数据进行训练时, 相同的迭代次数下训练时间最长, 达到11.68 min; 而采取小批量随机方法, 可以减少训练时间, 并且可以减少工艺介质温度的MAPE值. 当 $m_s = 500$ 时, 相同的迭代次数下, 工艺介质温度的MAPE值最低, 因此, 本文选取的 m_s 值为500, 训练时间为9.37 min. 相比于以20 000组数据进行训练, 训练时间节约了2.31 min, 工艺介质温度的MAPE提高了0.37%。

5.3 多层神经网络的参数选择

堆叠编码器应用过程中,不可避免地要确定该网络的模型结构(包括隐含层层数 w 和隐含层神经元个数 s),该问题不仅是本文研究过程所遇到的问题,而且也是神经网络研究和应用过程中普遍存在的问题.另外,循环冷却水系统对工艺介质进行降温的过程属于大滞后过程,很难确定系统当前时刻的工艺介质温度与先前多少个时刻的工艺介质温度有关,亦即循环冷却水系统工艺介质温度变化延迟参数 d 未知.

本文利用贝叶斯优化算法确定多层神经网络的隐含层层数和神经元个数,详细的贝叶斯优化原理可参见文献[23-24].根据贝叶斯优化方法最终确定的隐含层层数为4,每层的神经元个数分别为542、375、418以及236.

在上文确定的隐含层层数和神经元个数的基础上改变延迟参数 d ,由初始 $d = 1$ 依次增加1至 $d = 5$ 进行网络训练.由表3不同延迟系数的温度预测结果误差和可以看出:随着延迟系数由1增至5,训练时间逐渐增加,预测温度误差和逐渐减小,当延迟系数为1、2时,预测误差和偏大,排除;当延迟系数为5时,虽然预测误差和最小,但是训练时间长达24.83 min,约是 $d = 3$ 的训练时间的2倍,而预测误差和仅相差0.21℃,排除;再由图8不同延迟系数 d 下工艺介质温度预测误差分布可知:当 $d = 3$ 时,误差分布以 $< 0.1℃$ 为主;当 $d = 4$ 时,误差分布以 $0.1 \sim 0.2℃$ 为主.因此,综合考虑训练时间、预测误差和以及预测误差分布,确定该数据样本的延迟系数 d 取3.

表3 不同延迟系数的温度预测结果误差和

延迟系数 d	训练时间 / min	预测误差和 / ℃
1	11.32	52.4
2	12.32	14.78
3	13.42	10.12
4	15.13	9.36
5	24.83	9.91




图8 不同延迟系数 d 的工艺介质温度预测误差分布

5.4 不同学习方法预测工艺介质温度结果对比与分析

根据5.3节确定的网络参数对训练样本集进行深度学习,得到训练好的1#换热器内工艺介质温度预测模型.为验证ISAE算法的有效性,采用浅层神经网络方法(BP、ELM、RBF)对相同的样本集进行训练和测试,并将所得结果的平均百分比误差与本文方法进行对比分析(见表4).由表4可以看出,ISAE算法所得到冷却给回水压差的MAPE均最小,其次是SAE算法,BP算法的MAPE最大,RBF算法的工艺介质温度MAPE介于SAE算法与ELM算法两者之间,SAE、RBF、ELM和BP算法所得到的MAPE值分别是ISAE的2.35倍、5.76倍、18.15倍、72.09倍.

表4 5种算法的温度预测结果MAPE比较

预测方法	工艺介质温度 MAPE / %
ISAE	0.82
SAE	1.93
RBF	4.73
ELM	14.89
BP	59.12

图9为ISAE、SAE、RBF、ELM和BP五种方法所得工艺介质温度的预测误差分布.BP算法所得工艺介质温度误差在 $0.5℃$ 以上的样本占比高达89.7%(样本个数为5827),误差超过 $1℃$ 的样本占比达到63.5%(样本个数为4126),误差超过 $1.5℃$ 的样本占比也达到37.7%(样本个数为2453),可见,基于BP算法的工艺介质温度预测精度很低,难以满足应用需求.ELM算法的精度较BP算法有所提升,但工艺介质温度的误差在 $0.5℃$ 以上的样本仍然达到43%(样本个数为2795).RBF算法的精度比ELM算法的有进一步提高,工艺介质温度的误差在 $0.5℃$ 以上的样本占8.9%(样本个数为583).相较于浅层神经网络,未改进的SAE方法的预测精度有较多提升,但是工艺介质温度的误差高于 $0.2℃$ 的比例为3.5%(样本个数为155),相较于ISAE算法所得结果,仍有一定的精度差距.采用ISAE算法所得到的工艺介质温度的误差均极小,非常接近于真实值.由以上结果可以看出,基于ISAE的工艺介质温度预测控制精度远远优于其他神经网络算法.

泛化能力是指机器学习算法对新鲜样本的适应能力,为了验证本文所提出利用RMSProp优化方法进行参数微调对网络结构泛化能力的影响,将本文算法与未改进的SAE算法所得结果进行对比分析.选择某化工厂2018年10月20日~10月25日1#换热




图9 ISAE、SAE、RBF、ELM和BP五种方法预测工艺介质温度的预测误差分布

器内工艺介质温度以及循环冷却水系统运行历史数据,经过数据处理共计1440组测试数据,将测试数据输入到训练好的深度学习网络中。由表5可以看出,ISAE与未改进的SAE的计算耗时基本一致,但未改进的SAE算法所得工艺介质温度MAPE是本文ISAE算法的1.43倍。因而,本文采用的改进策略可有效提高SAE深度学习网络的泛化能力,提高工艺介质温度预测精度,更适用于循环冷却水系统节能改造实际应用。

表5 ISAE与未改进的SAE泛化能力比较

评估方法	时间/s	工艺介质温度MAPE/%
ISAE	0.07	1.65
SAE	0.09	2.36

6 结论

本文提出了一种基于改进堆栈自动编码器的循环冷却水系统工艺介质温度预测方法,利用某化工厂历史运行数据离线训练得到工艺介质温度预测模型,通过真实值与预测值的对比结果表明了所构建的ISAE模型预测精度较高。与浅层神经网络以及未改进的SAE方法所得结果对比,ISAE模型的误差最小,回归拟合效果最优;对比于未改进的SAE,利用RMSProp进行参数优化的ISAE算法的泛化能力更强。本文所提出的ISAE模型适用于对具有滞后变化特性的工业参数的预测,应用于工业控制系统,能够促进工业节能,提高能源利用率。

参考文献(References)

- [1] 宋宝琳, 白士杰, 郭媛. 经济增长、能源消耗与产业结构升级关系的实证分析[J]. 统计与决策, 2018, 34(20): 142-144.
(Song B L, Bai S J, Guo Y. An empirical analysis

of the relationship between economic growth, energy consumption and industrial structure upgrading[J]. Statistics & Decision, 2018, 34(20): 142-144.)

- [2] Sun J, Feng X, Wang Y F, et al. Pump network optimization for a cooling water system[J]. Energy, 2014, 67(4): 506-513.
- [3] 雷哲, 冯霄. 循环冷却水最小流率目标值的确定[J]. 化工学报, 2011, 62(4): 1006-1013.
(Lei Z, Feng X. Targeting minimal flow rate of circulating cooling water[J]. CIESC Journal, 2011, 62(4): 1006-1013.)
- [4] Li X M, Zhao T Y, Zhang J L, et al. Predication control for indoor temperature time-delay using Elman neural network in variable air volume system[J]. Energy and Buildings, 2017, 154(4): 545-552.
- [5] 徐江华, 孙荣, 邵惠鹤. 大滞后过程的PI控制器整定[J]. 控制与决策, 2004, 19(1): 99-102.
(Xu J H, Sun R, Shao H H. PI controller tuning for large dead-time processes[J]. Control and Decision, 2004, 19(1): 99-102.)
- [6] 董昌春. 主机冷却水温度控制系统的神经网络PID控制研究[D]. 上海: 上海海事大学物流科学与工程学院, 2005.
(Dong C C. Research on neural network pid control of cooling water temperature control system of main engine. Shanghai: School of Control Science and Engineering, Shanghai Maritime University, 2005.)
- [7] Liu J F, Xia J J, Hu B A, et al. Control study of improvement on grey predictive model in large time delay process[C]. Control and Decision Conference. Taiyuan, 2012: 896-898.
- [8] 金秀章, 魏琳, 王真. 基于最小二乘支持向量机的锅炉炉膛温度在线预测[J]. 热力发电, 2016, 45(7): 93-97.
(Jin X Z, Wei L, Wang Z. Online prediction of

- furnace temperature based on least square support vector machine[J]. Thermal Power Generation, 2016, 45(7): 93-97.)
- [9] Yang H J, Wang Y J, Yang Y N. Adaptive control for large-scale nonlinear systems with time delays and unmodeled dynamics[J]. IEEE Access, 2016, 99: 938-945.
- [10] 尹光志, 李铭辉, 李文璞, 等. 基于改进BP神经网络的煤体瓦斯渗透率预测模型[J]. 煤炭学报, 2013, 38(7): 1179-1184.
(Yin G Z, Li M H, Li W P, et al. Model of coal gas permeability prediction based on improved BP neural network[J]. Journal of China Coal Society, 2013, 38(7): 1179-1184.)
- [11] Abbaszadeh A, Arab Khaburi D, Rodríguez José. Predictive control of permanent magnet synchronous motor with non-sinusoidal flux distribution for torque ripple minimisation using the recursive least square identification method[J]. IET Electric Power Applications, 2017, 11(5): 847-856.
- [12] Schmidhuber J. Deep learning in neural networks: An overview[J]. Neural Network, 2015, 61(8): 85-117.
- [13] 段艳杰, 吕宜生, 张杰, 等. 深度学习在控制领域的研究现状与展望[J]. 自动化学报, 2016, 42(5): 643-654.
(Duan Y J, Lv Y S, Zhang J, et al. Deep learning for control: The state of the art and prospects[J]. Acta Automatica Sinica, 2016, 42(5): 643-654.)
- [14] 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(4): 377-388.
- [15] 程艳云, 张守超, 杨杨, 等. 基于大数据的时间序列异常点检测研究[J]. 计算机技术与发展, 2016, 26(5): 139-144.
(Cheng Y Y, Zhang S C, Yang Y, et al. Research on time series outlier detection based on large data[J]. Computer Technology and Development, 2016, 26(5): 139-144.)
- [16] Wang J, Zhang H, Fang B, et al. A survey on data cleaning methods in cyberspace[C]. 2017 IEEE 2nd International Conference on Data Science in Cyberspace. Shenzhen, 2017: 74-81.
- [17] Arcos-García Á, Álvarez-García J A, Soria-Morillo L M. Deep neural network for traffic sign recognition systems: An analysis of spatial transformers and stochastic optimisation methods[J]. Neural Networks, 2018, 99(3): 158-165.
- [18] Zhao J D, Yuan Gao, Yang Z Z, et al. Truck traffic speed prediction under nonrecurrent congestion: Based on optimized deep learning algorithms and GPS data[J]. IEEE Access, 2019, 7: 9116-9127.
- [19] Sun Y Y, Zhang W, Gu H, et al. Convolutional neural network based models for improving super-resolution imaging[J]. IEEE Access, 2019, 7: 43042-43051.
- [20] Lan G, Yoshua B, Aaron C. Deep learning[M]. Massachusetts: Massachusetts Institute of Technology Press, 2016: 170-173.
- [21] Konecny J, Liu J, Richtarik P, et al. Mini-batch semi-stochastic gradient descent in the proximal setting[J]. IEEE Journal of Selected Topics in Signal Processing, 2016, 10(2): 242-255.
- [22] Dekel O, Gilad-Bachrach R, Shamir O, et al. Optimal distributed online prediction using mini-batches[J]. Journal of Machine Learning Research, 2010, 13(1): 165-202.
- [23] Lyu W, Pan X, Fan Y, et al. An efficient bayesian optimization approach for automated optimization of analog circuits[J]. IEEE Transactions on Circuits & Systems I Regular Papers, 2017(99): 1-14.
- [24] Shahriari B, Swersky K, Wang Z, et al. Taking the human out of the loop: A review of bayesian optimization[J]. Proceedings of the IEEE, 2016, 104(1): 148-175.

作者简介

左为恒(1961—), 男, 副教授, 硕士, 从事计算机过程控制系统开发、智能控制算法等研究, E-mail: zwheng@126.com;

宋璐璐(1994—), 女, 硕士生, 从事工业电气节能控制系统的研究, E-mail: 30660533@qq.com.

(责任编辑: 李君玲)