

基于随机卷积核神经网络数据增强的软测量

钱 慧, 刘瑞兰

(南京邮电大学 自动化学院、人工智能学院, 江苏 南京 210023)

摘 要: 精对苯二甲酸(PTA)生产过程中PX氧化反应的副产品4-CBA难以在线测量, 只能通过离线分析获得少量样本。针对该问题, 提出一种基于随机卷积核神经网络数据增强的动态软测量模型RCKN-XGBoost。该模型首先采用随机卷积核神经网络(RCKN)进行数据增强, 扩充样本数量并改善其多样性; 然后将原始样本与扩充后的样本线性组合, 构成新的数据集; 最后采用XGBoost对网络进行训练与预测。在某化工厂PX氧化过程4-CBA含量数据集上对RCKN-XGBoost模型与XGBoost、CNN、CNN-XGBoost、Laplace-XGBoost模型进行比较, 发现RCKN-XGBoost模型的MRE指标分别降低了1.07%、0.92%、0.80%和0.65%, RMSE分别降低了27.9%、18.62%、12.58%和8.05%, 证明了该模型的有效性。

关键词: 软测量; 4-CBA; 随机卷积核神经网络; 数据增强; XGBoost

DOI: 10.11907/rjtk.231424

开放科学(资源服务)标识码(OSID):

中图分类号: TP183

文献标识码: A

文章编号: 1672-7800(2024)006-0053-06



Soft Sensor Based on Random Convolutional Kernel Neural Network Data Enhancement

QIAN Hui, LIU Ruilan

(College of Automation & College of Artificial Intelligence, Nanjing University of Posts and Telecommunications, Nanjing 210023, China)

Abstract: The by-product 4-CBA of PX oxidation reaction in the production process of purified terephthalic acid (PTA) is difficult to measure online, and only a small amount of samples can be obtained through offline analysis. A dynamic soft sensing model RCKN-XGBoost based on random convolutional kernel neural network data augmentation is proposed to address this issue. The model first uses random convolutional kernel neural network (RCKN) for data augmentation, expanding the sample size and improving its diversity; Then, the original sample is linearly combined with the expanded sample to form a new dataset; Finally, XGBoost was used to train and predict the network. On the 4-CBA content dataset of PX oxidation process in a certain chemical plant, the RCKN-XGBoost model was compared with XGBoost, CNN, CNN-XGBoost, and Laplace XGBoost models. It was found that the MRE index of the RCKN-XGBoost model decreased by 1.07%, 0.92%, 0.80%, and 0.65%, respectively, and the RMSE decreased by 27.9%, 18.62%, 12.58%, and 8.05%, proving the effectiveness of the model.

Key Words: soft sensor; 4-CBA; random convolutional kernel neural network; data enhancement; XGBoost

0 引言

精对苯二甲酸(Purified Terephthalic Acid, PTA)是制造聚酯纤维的重要有机原料。对羧基苯甲醛(4-Carboxybenzaldehyde, 4-CBA)是PTA生产过程中对二甲苯(Paraxylene, PX)氧化反应的副产物^[1]。根据反应机理, 当4-CBA含量偏高时, 将超出精制单元的负荷; 而当4-CBA含量不足时, 氧化反应对原料的消耗会增加, 使氧化反应加

深, 严重影响PTA的产品质量。然而, PTA生产过程涉及多元热力学平衡, 工艺流程复杂, 按照常规方法难以精确测量并控制4-CBA含量, 目前多采用软测量技术解决不能在线测定4-CBA含量的问题。在软测量技术中, 容易通过传统硬件传感器测量的变量称为辅助变量; 难以通过传统硬件传感器测量的变量称为主导变量。软测量的核心理念为通过容易测量的辅助变量建立数学回归模型, 对难以测量的主导变量进行预测^[2-4]。由于4-CBA含量只能通过分析仪器获得, 其样本数量很少, 因此常用的软测

收稿日期: 2023-04-24

作者简介: 钱慧(1994-), 女, 南京邮电大学自动化学院、人工智能学院硕士研究生, 研究方向为深度学习在软测量中的应用; 刘瑞兰(1972-), 女, 博士, 南京邮电大学自动化学院、人工智能学院副教授、硕士生导师, 研究方向为深度学习在软测量中的应用。

量建模方法呈现出一定的局限性。

关于小样本的软测量建模方法已有部分研究成果。例如,针对小样本建立非线性系统的软测量模型问题,文献[5]将基于最小二乘支持向量机的软测量模型应用于轻柴油凝固点的预估,模型参数确定简便,求解速度较快;为解决贝叶斯网络的学习参数在小样本或样本缺失情况下容易出现局部极值的问题,文献[6]提出一种受限的最大期望(Expectation Maximization, EM)算法;文献[7]将一种新的灰色关联分析算法应用于软测量中,使样本数量较少时模型也能充分利用有效信息;文献[8]提出一种核二次型判别分析法,通过调整协方差估计解决小样本问题;为提高小样本模型的学习速度和泛化性能,文献[9]提出一种核主元分析与最小二乘支持向量机相结合的方法;文献[10]利用支持向量机对小样本回归建模的优势,基于推广性的界理论指导支持向量机回归模型参数选取,以保证模型具有最佳泛化能力。

上述研究虽然取得了良好效果,但都只局限于改进建模方法方面,没有从样本数量的角度出发提升模型的预测精度和泛化性能。为此,本文提出一种基于随机卷积核神经网络(Random Convolutional Kernel Network, RCKN)数据增强的动态软测量模型RCKN-XGBoost。该模型首先采用RCKN对工业过程中采集到的有限数据集进行数据增强,缓解软测量建模过程中数据集紧缺的问题;其次,为平衡数据多样性与数据量之间的关系,将原始样本与扩充之后的样本线性组合,构成新的数据集;最后,采用XGBoost算法对网络进行训练与预测。实验结果表明,与传统数据增强方法相比,RCKN-XGBoost可以在不增加训练时间的情况下提高数据的多样性。

1 理论基础

1.1 RCKN

2011年,文献[11]首次提出一种具有随机权重的单层卷积模型RCKN,该模型在不需要学习任何网络参数的情况下在NORB数据集上获得了具有竞争力的结果,这是由于RCKN对输入数据有一定的选择性,即频率选择性和平移不变性。一般来说,卷积神经网络(Convolutional Neural Network, CNN)由交替连接的卷积层和池化层组成^[12-13],其卷积核是固定的,且需要在训练过程中通过反向传播更新权重^[14],需要消耗大量时间训练网络参数。RCKN是一种CNN的变体,其卷积层使用的卷积核是随机生成的,即卷积核的大小 k 、偏置 B 、权重 Θ 都是随机生成的,而不是像传统CNN一样需要在训练过程中通过反向传播来学习得到。这些设计使RCKN拥有良好的泛化稳定性以及较低的设计复杂性,同时还降低了过拟合的影响。与传统CNN一样,RCKN也是通过从移动窗口中提取与时间的相关性来预测下一个时间步长的测量值,从而实现软测量模

型的动态性。

本文使用的RCKN只有一层卷积层,不需要学习卷积核的权重和偏置,因此可以节约卷积计算成本。假设输入 $X \in R^{H \times W}$, R 表示实数域, H 和 W 分别表示输入的高度和宽度;一个具有卷积核 $\Theta \in R^{k \times k}$ 的卷积层中, Θ 为随机采样权重, k 为卷积核大小, B 为偏置, $f(\cdot)$ 为卷积层激活函数,则经过卷积计算的输出 X' 表示为:

$$X' = f(X \times \Theta + B), X' \in R^{H' \times W'} \quad (1)$$

1.2 时序数据的数据增强

软测量输入数据的实质为多变量的时序数据。在图像、文本和语音处理领域,数据增强是一种常见的提效方法,但关于时序数据的数据增强方法研究较少。传统时序数据增强方法包括时间平移^[15]、数据切片^[16]、噪声添加^[17]等,这些方法虽然简单直观方便,但未考虑到数据集整体的分布特点^[18]。当数据呈现非线性或非周期性模式时,简单的数据增强方法可能会破坏数据的内在结构,使得扩充后的数据不再具有原数据的特征。文献[19]研究发现,在图像领域使用随机卷积进行数据增强可以大大提高神经网络的鲁棒性。而采用RCKN进行数据增强能够基于原始数据分布生成新的相同分布的数据,从而扩充数据集。受此启发,本文创造性地将RCKN运用于软测量领域,并提出一种简单有效的数据融合方法,即将原始数据与增强后的数据线性混合,从而构成新的数据集。

1.3 XGBoost算法

2014年,Chen等^[20-21]提出在梯度提升决策树(Gradient Boosting Decision Tree, GBDT)算法基础上进行改进的XGBoost算法。XGBoost是一种高效、准确、可解释和兼容性强的机器学习框架,被广泛应用于各种数据挖掘与机器学习任务中。XGBoost的基本原理是将多个弱学习器(例如决策树)组合成一个强学习器,通过不断迭代优化损失函数来提高模型的准确性。在每一轮迭代中,XGBoost根据前一轮的预测结果计算残差,并将残差作为新的目标来训练下一个弱学习器。同时,XGBoost通过正则化技术控制模型的复杂度,以避免过拟合。与一些浅层算法相比,XGBoost具有运算速度更快、准确度更高的优点。

2 4-CBA含量动态软测量模型

2.1 数据预处理

目前,绝大部分的软测量模型都只考虑了系统的静态特性,无法反映工业生产中的动态变化^[22]。为了在模型中考虑工业生产的动态特性,模型输入应包括影响 k 时刻输出的输入以及未完成过渡过程的输入,还需要对未完成过渡过程的输入进行滞后处理,滞后时间计算采用最大相关系数法^[23]。PX氧化过程中影响4-CBA含量的因素较多,根据现场经验,本文选取5个辅助变量作为动态软测量模型的输入变量。如式(2)所示,模型以输入变量的时间序

列数据块 X 作为输入。

$$X = \begin{bmatrix} x_1(k - \tau_1) & \cdots & x_5(k - \tau_5) \\ x_1(k - \tau_1 - 1) & \cdots & x_5(k - \tau_5 - 1) \\ \vdots & \ddots & \vdots \\ x_1(k - \tau_1 - N) & \cdots & x_5(k - \tau_5 - N) \end{bmatrix} \quad (2)$$

式中: x_1, x_2, x_3, x_4, x_5 为模型的 5 个输入变量; $N = t/T$, t 为过渡时间长度, $t = 30 \text{ min}$, T 为数据的采样周期, $T = 30 \text{ s}$, 由计算可得 $N = 60$; τ 为滞后时间, 通过最大相关系数法求得 $\tau_1 = 150 \text{ min}$, $\tau_2 = 144 \text{ min}$, $\tau_3 = 102 \text{ min}$, $\tau_4 = 114 \text{ min}$, $\tau_5 = 18 \text{ min}$ 。

2.2 RCKN-XGBoost 动态软测量模型

动态软测量模型 RCKN-XGBoost 结构如图 1 所示。该模型包含基于随机卷积核的数据增强器 RCKN 和基于 XGBoost 的线性回归器两部分。首先, 将经过预处理的样本数据块 X 传递至 RCKN 数据增强器中作为输入, 进行卷积运算得到 X' 。本文使用的 RCKN 是一个具有随机权重的单层网络结构, 其只有一层卷积层, 没有池化层和全连接层, 采用 ReLU 作为非线性激活函数, 卷积核的窗口滑动步长为 1, 卷积核大小 k 从 1、3、5、7、9、11 中随机取得, 偏置 B 初始化为 0。具体参数如表 1 所示。




Fig. 1 RCKN-XGBoost model

图 1 RCKN-XGBoost 模型

由于 RCKN 只有一层卷积层, 且不需要通过反向传播来更新权重, 本文采用 Kaiming 初始化的前向传播, 即卷积核的权重 $\Theta \sim U\left[0, \frac{2}{k \times k}\right]$, 其中 k 为卷积核大小。为平衡数据多样性与数据量之间的关系, 本文将原始输入样本 X 与 RCKN 的输出 X' 进行线性混合。表示为:

$$\alpha X + (1 - \alpha) X' \quad (3)$$

式中: 混合参数 α 从 0 - 1 的均匀分布中随机采样

Table 1 Parameter settings of RCKN

表 1 RCKN 参数设置

参数名称	取值范围
卷积核的大小 k	$k = \{1, 3, 5, 7, 9, 11\}$
卷积核的权重 Θ	$\Theta \sim U\left[0, \frac{2}{k \times k}\right]$
原始数据所占比例 α	$\alpha \sim U[0, 1]$
卷积层数 n	1
激活函数	ReLU
滑动步长 S	1
偏置 B	初始化为 0

得到。

将原始样本 X 与混合而成的数据 $\alpha X + (1 - \alpha) X'$ 作为输入, 通过 XGBoost 线性回归器进行回归训练, 其输出即为预测值。XGBoost 算法参数如表 2 所示。

Table 2 Parameters of the XGBoost algorithm

表 2 XGBoost 算法参数

参数	取值
学习速率	0.05
树的深度	2
生成树模型的随机抽取比例	0.6
特征的子样本比例	0.3
gamma	0.97

3 应用实验

3.1 实验数据与评价指标

采用某化工厂 PX 氧化过程中 4-CBA 含量的数据集进行验证, 共包含 201 组数据, 选取前 160 组数据作为训练集, 用于建立动态软测量模型; 后 41 组数据作为测试集, 用于测试模型的泛化能力。数据集详细信息如表 3 所示。为提高模型的泛化能力和鲁棒性, 同时避免过拟合和失去数据的真实性, 本文仅对训练集进行数据增强, 测试集不作增强。根据现场经验, 选取反应生成的二氧化碳含量、混合罐进料流量、反应器液位、反应器温度、第一结晶器温度约束共 5 个辅助变量作为软测量模型的输入变量。模型输入选取滞后时间为 1~2 h 的数据, 由于每分钟采集一次数据, 数据块尺寸大小设为 60×5 。

Table 3 Dataset details

表 3 数据集详细信息

数据集名称	样本总量	训练集	测试集	辅助变量	输入数据块的大小
4-CBA	201 组	160 组	41 组	5 个	60×5

为了更加直观地判断模型的泛化能力, 采用平均相对误差 (Mean Relative Error, MRE) 作为性能评价指标。计算公式为:

$$MRE = \frac{1}{N} \sum_{i=1}^N \frac{|y_i - y_i'|}{y_i} \times 100\% \quad (4)$$

式中: y_i 为真实值, y_i' 为软测量模型的预测值, N 为样

本个数。

3.2 参数优化

本文仿真实验基于 Python 展开。考虑到样本数量会影响 RCKN-XGBoost 软测量模型的训练效果,现将原始的 160 组训练样本分别增强 1~6 倍进行比较分析。此外,原始数据所占比例 α 也会决定生成数据的质量, α 越大,说明原始数据所占比例越高,卷积之后得到的数据所占比例越低,反之则相反。因此,对 α 分别为 0、0.2、0.4、0.6、0.8 和 1 情况下的模型预测结果进行比较。表 4 为训练集输入样本增强 1~6 倍,以及原始数据所占比例 α 为 0、0.2、0.4、0.6、0.8 和 1 情况下 RCKN-XGBoost 模型预测结果的 MRE。为了更加直观地进行比较,将表 4 中的数据绘制成曲线图,具体如图 2 所示。

Table 4 Prediction result MRE of RCKN-XGBoost model under different enhancement factors and proportion of raw data

表 4 不同增强倍数以及原始数据占比下 RCKN-XGBoost 模型预测结果 MRE (%)

增强倍数	原始数据占比 α					
	0	0.2	0.4	0.6	0.8	1
1	5.59	5.54	5.55	5.76	5.99	6.10
2	5.52	5.99	6.01	6.38	6.28	5.89
3	5.66	6.08	6.06	6.15	6.19	5.85
4	5.71	5.49	5.42	6.34	6.04	5.96
5	5.56	5.29	5.98	6.18	7.08	6.26
6	5.67	5.46	5.80	6.61	6.56	6.33

首先比较不同增强倍数对模型预测结果的影响。由表 4 可以看出,随着训练样本增强倍数的增加,模型的预测误差呈现先上升后下降的趋势。选择 $\alpha = 0.2$ 这一列数据进行观察,当样本增强倍数增加至 5 (即 960 组数据) 时,模型的预测误差下降到最低点,模型测试样本的 MRE 为 5.29%。之后随着训练样本增强倍数的增加,模型的误差呈现上升趋势。当样本增强倍数增加至 6 (即 1 120 组数据) 时,模型测试样本 MRE 为 5.46%。

然后对原始数据所占比例 α 进行分析。可以看出,随着原始数据所占比例的减少,模型的预测误差呈现先下降

后上升的趋势。选择增强倍数为 5 这一行数据进行观察,当 $\alpha = 0.2$ 时,模型的预测误差下降至最低点,模型测试样本的 MRE 为 5.29%。之后随着 α 继续减少,模型的预测误差呈上升趋势。当 $\alpha = 1$ 时,模型测试样本的 MRE 为 6.26%。

由图 2 可以看出,4-CBA 数据集在 $\alpha = 0.2$,对样本数据增强 5 倍时建立的 RCKN-XGBoost 动态软测量模型的预测误差最小。此时模型测试样本 MRE 为 5.29%。图 3 为 4-CBA 数据集在 $\alpha = 0.2$,样本数据增强 5 倍情况下 RCKN-XGBoost 模型的预测结果。

3.3 比较实验

为进一步验证 RCKN-XGBoost 软测量模型的预测效果,采用 $\alpha = 0.2$,数据增强 5 倍情况下的 RCKN-XGBoost 模型与未进行数据增强的 XGBoost 软测量模型、基于传统 CNN 的软测量模型 (CNN)、基于 CNN 与 XGBoost 的软测量模型 (CNN-XGBoost)、基于拉普拉斯噪声数据增强的软测量模型 (Laplace-XGBoost) 的预测效果进行比较分析。其中,传统 CNN 模型由 3 层卷积层、3 层池化层和 1 层全连接层组成,激活函数选择 tanh 函数;CNN-XGBoost 模型首先采用传统 CNN 作为特征提取器,然后利用 XGBoost 对提取特征进行训练;Laplace-XGBoost 模型首先利用拉普拉斯噪声进行数据增强,添加的信噪比为 60,数据扩充 5 倍,然后利用 XGBoost 进行训练。

为更好地比较各模型的预测效果,增加均方根误差 (Root Mean Squared Error, RMSE) 作为性能评价指标。具体计算公式为:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - y_i')^2} \quad (5)$$

式中: y_i 为真实值, y_i' 为软测量模型的预测值, N 为样本个数。

图 4 为 5 种软测量模型在 4-CBA 数据集集中的预测结果比较。可以看出, XGBoost、CNN、CNN-XGBoost 以及 Laplace-XGBoost 模型预测值曲线与真实值曲线之间的误差较大,而 RCKN-XGBoost 模型预测值曲线与真实值曲线很接近,拟合程度较高。




Fig. 2 Prediction result MRE curve of RCKN-XGBoost model under different enhancement factors and proportion of raw data

图 2 不同增强倍数以及原始数据占比下 RCKN-XGBoost 模型预测结果 MRE 曲线




Fig. 3 Prediction result of RCKN-XGBoost model in the case of $\alpha = 0.2$, sample data enhanced by 5 times

图 3 $\alpha = 0.2$, 样本数据增强 5 倍情况下 RCKN-XGBoost 模型预测结果




Fig. 4 Comparison of prediction results of 5 soft sensing models in the 4-CBA dataset

图 4 5 种软测量模型在 4-CBA 数据集集中的预测结果比较

表 5 为 5 种软测量模型在 4-CBA 数据集中训练结果与预测结果的 MRE 和 RMSE 比较。XGBoost、Laplace-XG-Boost、CNN-XGBoost、RCKN-XGBoost 均使用 XGBoost 建立软测量模型,其中 XGBoost 未进行数据增强,Laplace-XG-Boost 采用拉普拉斯噪声进行数据增强,CNN-XGBoost 采用 CNN 进行数据增强,RCKN-XGBoost 采用随机卷积核进行数据增强。由表 5 可以看出,未进行数据增强时模型预测误差最大,泛化能力最差;进行数据增强时,随机卷积核的数据增强效果优于拉普拉斯噪声和 CNN 数据增强。

总体来说,混合模型相较单一模型具有优越性,且混合模型中的 RCKN-XGBoost 模型拥有最高的预测精度,满足实际工业生产需求。

4 结语

本文利用随机卷积神经网络进行数据增强、XG-Boost 进行训练的混合方法预测 4-CBA 含量,并将预测结

Table 5 MRE and RMSE comparison of training results and prediction results of five soft sensing models

表 5 5 种软测量模型训练结果与预测结果 MRE 和 RMSE 比较

模型	训练误差		预测误差	
	MRE/%	RMSE	MRE/%	RMSE
XGBoost	5.98	270.26	6.36	288.54
CNN	5.63	263.45	6.21	279.26
CNN-XGBoost	4.76	259.62	6.09	273.22
Laplace-XGBoost	4.45	252.76	5.94	268.69
RCKN-XGBoost	4.18	248.12	5.29	260.64

果与其他 4 种软测量模型进行比较,证实了该方法具有较高的预测精度。然而本文是通过手动调整数据增强倍数以及原始数据所占比例,从而得到性能最佳的 RCKN 模型,过程耗时且繁琐。未来可以考虑使用 AutoML 进行超参数调优,以便快速找到最优超参数组合,从而加速模型调优进程。

参考文献:

[1] MAO Y S, YANG K X, WANG L J. Real-time optimization and advanced

- control for PTA oxidation process[J]. Control & Instruments in Chemical Industry, 2012, 39(9): 1128–1132.
- 冒永生, 杨开香, 王丽军. PTA 装置氧化过程实时优化与先进控制[J]. 化工自动化及仪表, 2012, 39(9): 1128–1132.
- [2] SHANG C, YANG F, HUANG D, et al. Data-driven soft sensor development based on deep learning technique[J]. Journal of Process Control, 2014, 24(3): 223–233.
- [3] WANG J, ZHAO C. Mode-cloud data analytics based transfer learning for soft sensor of manufacturing industry with incremental learning ability[J]. Control Engineering Practice, 2020, 98: 104392.
- [4] ZHAO C, WANG F, MAO Z, et al. Quality prediction based on phase-specific average trajectory for batch processes[J]. AIChE Journal, 2008, 54(3): 693–705.
- [5] YAN W W, ZHU H D, SHAO H H. Soft sensor modeling based on support vector machines[J]. Journal of System Simulation, 2003, 15(10): 1494–1496.
- 阎威武, 朱宏栋, 邵惠鹤. 基于最小二乘支持向量机的软测量建模[J]. 系统仿真学报, 2003, 15(10): 1494–1496.
- [6] LIAO W, JI Q. Learning bayesian network parameters under incomplete data with domain knowledge[J]. Pattern Recognition, 2009, 42(11): 3046–3056.
- [7] LI Y, SHAO C. Application of a novel grey relation analysis algorithm to soft sensor[J]. Acta Automatica Sinica, 2006, 32(2): 311–317.
- 李勇, 邵诚. 一种新的灰关联分析算法在软测量中的应用[J]. 自动化学报, 2006, 32(2): 311–317.
- [8] WANG J, PLATANIOTIS K N, LU J, et al. Kernel quadratic discriminant analysis for small sample size problem[J]. Pattern Recognition, 2008, 41(5): 1528–1538.
- [9] ZHOU L C, YANG H Z. Soft sensor modeling based on KPCA and support vector machines[J]. Computer Simulation, 2008, 25(10): 94–97.
- 周林成, 杨慧中. 基于 KPCA 和最小二乘支持向量机的软测量建模[J]. 计算机仿真, 2008, 25(10): 94–97.
- [10] CHEN G, ZHOU J. Research on parameters and forecasting interval of support vector regression model to small sample[J]. Acta Metrologica Sinica, 2008, 29(1): 92–96.
- 陈果, 周伽. 小样本数据的支持向量机回归模型参数及预测区间研究[J]. 计量学报, 2008, 29(1): 92–96.
- [11] SAXE A M, KOH P W, CHEN Z, et al. On random weights and supervised feature learning[C]//Proceedings of the 28th International Conference on International Conference on Machine Learning, 2011: 1089–1096.
- [12] SHARMA G, JURIE F, SCHMID C. Discriminative spatial saliency for image classification[C]//2012 IEEE Conference on Computer Vision and Pattern Recognition, 2012: 3506–3513.
- [13] LAZEBNIK S, SCHMID C, PONCE J. Beyond bags of features: spatial pyramid matching for recognizing natural scene categories[C]//IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2006: 2169–2178.
- [14] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278–2324.
- [15] CHENG C H, FAN C C, LIU C, et al. Investigation of gate-stress engineering in negative capacitance FETs using ferroelectric hafnium aluminum oxides[J]. IEEE Transactions on Electron Devices, 2019, 66(2): 1082–1086.
- [16] XIU F, YUAN X. Chiral Landau levels in Weyl semimetal NbAs with multiple topological carriers[C]//APS March Meeting Abstracts, 2019: P04.009.
- [17] ISSERSTEDT P, BUBALLA M, FISCHER C S, et al. Baryon number fluctuations in the QCD phase diagram from Dyson–Schwinger equations[J]. Physical Review D, 2019, 100(7): 074011.
- [18] GE Y Z, XU X, YANG S R, et al. Survey on sequence data augmentation[J]. Journal of Frontiers of Computer Science and Technology, 2021, 15(7): 1207–1219.
- 葛轶洲, 许翔, 杨锁荣, 等. 序列数据的数据增强方法综述[J]. 计算机科学与探索, 2021, 15(7): 1207–1219.
- [19] XU Z, LIU D, YANG J, et al. Robust and generalizable visual representation learning via random convolutions[DB/OL]. <https://arxiv.org/abs/2007.13003>.
- [20] CHEN T, GUESTRIN C. XGBoost: a scalable tree boosting system[C]//Proceedings of the 22nd ACM Sigkdd International Conference on Knowledge Discovery and Data Mining, 2016: 785–794.
- [21] CHEN T, HE T. Higgs boson discovery with boosted trees[C]//NIPS 2014 Workshop on High-Energy Physics and Machine Learning, 2015: 69–80.
- [22] TOSI D, LAVAZZA L, MORASCA S, et al. On the definition of dynamic software measures[C]//Proceedings of the ACM–IEEE International Symposium on Empirical Software Engineering and Measurement, 2012: 39–48.
- [23] LIU R L. Research and industrial application of soft sensor technology[D]. Hangzhou: Zhejiang University, 2004.
- 刘瑞兰. 软测量技术若干问题的研究及工业应用[D]. 杭州: 浙江大学, 2004.

(责任编辑:尹晨茹)