引用格式:李辉,高嘉颉,席荣军,等.基于改进GAF-inception网络的非侵入式工业负荷识别算法[J].电力科学与技术学报,2025,40(4):103-112.
Citation: LI Hui, GAO Jiajie, XI Rongjun, et al. Non-intrusive load identification for industrial loads based on improved GAF-inception network[J]. Journal of Electric Power Science and Technology,2025,40(4):103-112.

基于改进GAF-inception网络的非侵入式工业负荷识别算法

李　辉,高嘉颉,席荣军,陈思颖,黄轶群,沈泽帆
(广东电网有限责任公司汕尾供电局,广东 汕尾 516600)

摘　要:针对现有非侵入式负荷识别(non-intrusive load monitoring, NILM)在低频工业数据中的辨识准确率低、泛化能力弱等问题,提出一种基于格拉夫角场格拉夫角场(Gramian angular field, GAF)与改进Inception网络结合的非侵入式工业负荷识别算法。先基于GAF,将功率的一维时序信息转换为带有时间特性的二维数据,提取不同工业场景下负荷特征信息;再建立改进Inception网络,利用其稀疏连接特性对多参数负荷特征进行多尺度提取,降低模型复杂度、提高计算效率,实现多场景工业负荷的高精度辨识;最后,采用工业负荷数据集(industrial appliance identification dataset,IAID)对所提算法进行验证。研究结果表明:所提算法能有效提高辨识准确率,其准确率可达94.48%,降低8%的计算成本。

关　键　词:非侵入式负荷识别;工业负荷;格拉夫角场;Inception网络;深度学习
DOI:10.19781/j.issn.1673-9140.2025.04.010　　**中图分类号**:TM93　　**文章编号**:1673-9140(2025)04-0103-10

Monitoring algorithm of non-intrusive industrial loads based on improved GAF-inception network

LI Hui, GAO Jiajie, XI Rongjun, CHEN Siying, HUANG Yiqun, SHEN Zefan
(Shanwei Power Supply Bureau, Guangdong Power Grid Co., Ltd., Shanwei 516600, China)

Abstract: In view of the existing problems of low recognition accuracy and weak generalization ability in non-intrusive load monitoring using low-frequency industrial data, a non-intrusive industrial load monitoring algorithm based on the combination of Gramian angular field (GAF) and an improved Inception network structure is proposed. The one-dimensional time series information of power is converted into two-dimensional data with temporal characteristics based on GAF. An improved Inception network is constructed, which leverages its sparse connection characteristics to perform multi-scale extraction of multi-parameter load characteristics, thereby reducing model complexity, improving computational efficiency, and achieving high-accuracy identification of industrial loads across multiple scenarios. Finally, the proposed algorithm is validated using the industrial appliance identification dataset (IAID). The research results show that the proposed algorithm can effectively improve monitoring accuracy up to 94.48% and enhance computational efficiency by more than 8% compared to the existing Inception network.

Key words: non-intrusive load monitoring; industrial load; Gramian angular field; Inception network; deep learning

“双碳”目标的提出,为推进全球气候治理注入了新动能,给电力行业带来了新一轮变革;同时,其对电网感知用户负荷使用也提出了更高要求[1-2]。通过负荷监控识别用户负荷的工作状态、分析用户用电行为,能提高用户用电能效,修正异常用电行为,挖掘用户侧节能潜力和需求响应潜力,增强电

收稿日期:2024-06-07;**修回日期**:2024-11-18
基金项目:南方电网科技项目(GDKJXM20212049);国家重点研发计划项目(2019YFE0118700)
通信作者:李　辉(1978—),男,硕士,中级工程师,主要从事电力营销技术等方面的研究;E-mail:31416280@qq.com

网服务精细化水平[3-4]。非侵入式负荷识别(non-intrusive load monitoring,NILM)具备实时性、可靠性与用户隐私信息保护性强等优点[5]。在新型电力系统下,面对多元用户侧群体与海量冗杂的工业低频数据,NILM的识别准确率较低。且该方法在不同工业场景下的负荷识别效果存在较大的差异,模型泛化能力弱。因此,提高NILM对工业负荷低频数据的识别准确率和模型泛化能力具有重要的研究价值和意义。

目前,国内外学者已对NILM的识别准确性和泛化性展开了系列研究。针对当前非侵入式负荷辨识中不同设备特征选择上主观性、盲目性的问题,文献[6-7]提出了基于Fisher支持向量机的(Fisher-support vector machine,Fisher-SVM)特征选择的非侵入式负荷辨识算法。文献[8-9]采用基于密度的噪声应用空间聚类算法(density-based spatial clustering of applications with noise,DBSCAN),降低了网压波动和噪声对聚类结果的扰动,且结合改进维特比算法与经典隐马尔可夫模型(hidden Markov model,HMM)来更新参数,增强了模型对负荷状态辨识与功率分解的泛化能力。文献[10-11]采用加权方式,改善了K邻近算法(K-nearest neighbors,KNN)可能误判少数类的问题,提出了基于V-I轨迹和幅值特征综合相似度的负荷识别方法,提高了对相同电路拓扑、不同功率等级用户负荷的识别准确率。文献[12]通过规定数据块,先利用滑动窗采集负荷状态改变时间信息,再使用均值漂移的方法,确定了状态质心与状态域,并结合时域信息,实现负荷状态检测。文献[13-14]通过将用电设备的相似特征转换为离散模糊数矩阵,实现了对负荷的辨识。文献[15]提出了2种不同映射学习方式分别处理序列到序列(sequence to sequence,S2S)和序列到点(sequence to point,S2P)的方法。基于S2P的NILM方法先通过单窗口的输入聚合功耗序列,预测位于该窗口中点位置的目标电器功耗,再结合卷积神经网络(convolutional neural network,CNN)模型,提高了负荷辨识的实时准确率。文献[16-17]在S2S基础上引入注意力机制,筛选与当前时刻相关度最高的数据信息,增强了算法对负荷信息的提取与分解能力。然而,当工业场景数较多且数据特征模糊时,这些方法对低精度负荷信息的提取与分解能力均明显下降。

为提升对数据信息的提取与分解能力,研究者将一维时间序列的负荷功率值转换为带有时间特性的二维图像数据,提出格拉夫角场(Gramian angular field,GAF)算法。文献[18]基于GAF实现了用户用电数据图像化,其利用三元组孪生网络可改进聚类效果的特点,提高了小样本数据下的窃电检测准确性。文献[19-20]采用GAF算法,将一维故障样本转化为三维特征图像,使用改进深度压缩模型,在不降低识别准确率的前提下,有效降低所需存储空间和运行资源。文献[21-24]利用GAF算法,结合ResNet网络,提取历史数据中相关特征,解决了神经网络退化问题,提高了算法预测准确度。文献[25-26]使用GAF-CNN生成对抗网络,增强生成图像的关键信息密度,实现了对台区缺失数据较好的修复。GAF算法可提升数据信息的提取与分解能力。但这些算法并不适用于工业类负荷辨识,导致多场景工业负荷识别准确率较低。

同时,非侵入式工业负荷采集通常处于低频状态,这导致模型的辨识准确率偏低。一方面,低频信号所包含的信息量相对匮乏,从该信号中提取有效特征极为困难;另一方面,低频信号更易受到环境噪声、谐波干扰等因素的影响,其信号纯净度较低。此外,在工业环境中,当多个负荷同时运行时,常会出现信号重叠状况,这将进一步导致负荷辨识率下降。

为此,针对现有非侵入式工业负荷识别在低频工业数据中辨识准确率低、泛化能力弱等问题,本文提出基于改进GAF-Inception网络的非侵入式工业负荷识别算法。该方法将GAF的特征变换与改进Inception网络结合,利用GAF特征变换,将低频工业数据的一维时序信息变为二维图像信息,建立改进Inception网络的负荷辨识模型,并利用其自选卷积(或池化)优点,在不损失GAF算法输出信息精度的前提下,降低参数运算量,提升运算效率和辨识准确率。本文以工业低频数据为例,在金属厂、塑料厂、玻璃厂和化工厂的数据集中进行训练和测试,验证所提算法的准确性和有效性,其辨识准确率可达94.48%。

1 工业低频负荷数据处理与特征变换

在非侵入式工业负荷辨识中,负荷数据的处理至关重要。然而,受仪表故障、通信故障、电网故障等多种故障因素影响,工业用户功率的测量数据常存在缺失和异常情况。为此,本文对其进行数据处理和特征变换。

1.1　负荷数据处理

受仪表故障、通信故障、电网故障等因素影响，工业用户功率的测量数据常存在不同程度的缺失和异常。本文先对数据集进行预处理，包括数据缺失值的填充、异常值的替换和数据的归一化处理，以提升数据质量，降低其对识别准确率的影响。

1.1.1　缺失值处理

工业用户数据采集和传输过程中的通信中断或故障易导致部分数据丢失。如果这只是单数据点缺失的情况，可采用线性插值方法来填补该缺失值，其计算式为

$$P(t)=\begin{cases}\dfrac{P(t-1)+P(t+1)}{2}, & P(t)\in\varnothing\\ P(t), & \text{其他}\end{cases}\tag{1}$$

式中，t 为时间变量；$P(t)$ 为在时刻 t 采集到的工业用户数据；$P(t)\in\varnothing$ 为 $P(t)$ 的缺失值。

若该数据缺失是数据在采集、传输过程中通信中断或故障导致的，即 $P(t)$ 附近数值均出现空缺，则可采用拉格朗日插值法对其进行插值来填充相应的缺失项，即

$$\ell_i(t)=\prod_{\substack{0\leqslant j\leqslant i\\ j\neq i}}\frac{t-t_j}{t_i-t_j}\tag{2}$$

$$P(t)=\sum_{i=0}^{n}P(i)\ell_i(t)\tag{3}$$

式(2)～(3)中，t 为缺失值时刻；t_j、t_i 为 t 时刻附近非缺失值的时刻；$\ell_i(t)$ 为拉格朗日函数；n 为插值多项式的次数。

1.1.2　异常值替换

工业用户环境相对复杂，在数据采集过程中计量设备自身故障、电磁干扰、温度变化等因素均可能会影响测量仪器的测量精度，产生数据异常值。

本文采用 3σ 定律来进行异常值的替换，即

$$P(t)=\begin{cases}P(t), & P(t)\leqslant \operatorname{avg}(\tilde{\boldsymbol{P}})+2\operatorname{std}(\tilde{\boldsymbol{P}})\\ \operatorname{avg}(\tilde{\boldsymbol{P}})+2\operatorname{std}(\tilde{\boldsymbol{P}}), & \text{其他}\end{cases}\tag{4}$$

式中，$\operatorname{avg}(\tilde{\boldsymbol{P}})$ 和 $\operatorname{std}(\tilde{\boldsymbol{P}})$ 分别为计算一维功率时间序列 P 构成的向量 $\tilde{\boldsymbol{P}}$ 的均值和标准差。

1.1.3　归一化处理

为提高模型的收敛速度，并使各特征具有相同的尺度，对一维功率时间序列 $P(t)$ 进行最小-最大值缩放，将数据映射到[0,1]，其计算式为

$$\tilde{P}(t)=\frac{P(t)-P_{\min}}{P_{\max}-P_{\min}}\tag{5}$$

式中，$\tilde{P}(t)$ 为 t 时刻归一化后功率值；$P_{\max}$、$P_{\min}$ 分别为整个功率序列的最大、最小值。

1.2　工业低频数据 GAF 特征变换

为提高不同工业负荷识别场景下的识别准确率和泛化能力，本文采用 GAF 算法，将处理后的工业低频数据一维功率时间序列转换为包含时间信息的二维负荷功率图像，其功率时间序列的 GAF 变换如图 1 所示。

从图 1 中可以看出，经过预处理的功率序列先进行极坐标变换；再经过 GAF 变换，计算格拉夫矩阵；最后，形成功率序列 GAF 特征图。该特征图通过计算不同时间点之间角度的余弦值来构建反应功率序列数据内在结构的图像。该格拉夫矩阵 $\boldsymbol{G}$ 计算式为

$$\boldsymbol{G}=\tilde{\boldsymbol{P}}_i\tilde{\boldsymbol{P}}_j^{\mathrm{T}}-\sqrt{\boldsymbol{I}-\tilde{\boldsymbol{P}}_i\tilde{\boldsymbol{P}}_i^{\mathrm{T}}}\sqrt{\boldsymbol{I}-\tilde{\boldsymbol{P}}_j\tilde{\boldsymbol{P}}_j^{\mathrm{T}}}=\begin{pmatrix}\cos(\phi_1+\phi_1) & \cos(\phi_1+\phi_2) & \cdots & \cos(\phi_1+\phi_n)\\ \cos(\phi_2+\phi_1) & \cos(\phi_2+\phi_2) & \cdots & \cos(\phi_2+\phi_n)\\ \vdots & \vdots & \ddots & \vdots\\ \cos(\phi_n+\phi_1) & \cos(\phi_n+\phi_2) & \cdots & \cos(\phi_n+\phi_n)\end{pmatrix}\tag{6}$$

式中，ϕ_i、ϕ_j 分别为 i、j 时刻对应的极坐标变化角度；

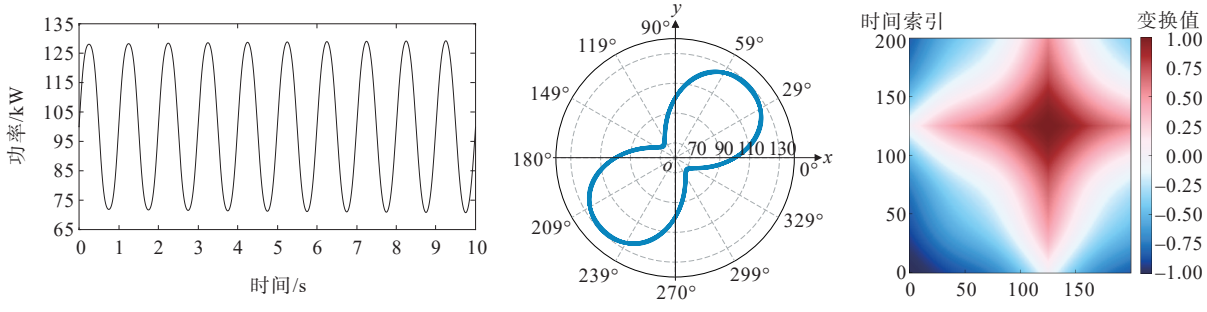

(a) 功率时间序列　　(b) 极坐标变换　　(c) GAF 变换

图 1　功率时间序列的 GAF 变换

Figure 1　GAF transform of power time series

$\boldsymbol{P}_i$、$\boldsymbol{P}_j$分别为i、j时刻归一化后的功率值向量；$\boldsymbol{I}$为单位矩阵。

经过GAF特征变换，工业用户t时刻的一维总功率$P(t)$先生成$n\times n$的矩阵，再转换为二维图像，对应功率序列的图像的纹理信息，颜色分布包含原始一维功率数据的特征。

2 基于GAF-Inception工业负荷识别

2.1 工业负荷辨识算法流程

基于改进GAF-Inception的非侵入式负荷辨识算法步骤共3步。

1）数据处理。采用线性插值填充缺失数据，并采用3σ定律替换异常值，提高数据质量；对处理后的数据，进行标准化处理，并进行GAF特征变换，实现一维数据特征图像化。

2）模型训练。将负荷特征数据和标签中的80%作为训练集。训练改进的Inception的非侵入式负荷辨识深度网络，使其学习工业负荷特征与设备运行状态间映射关系。

3）模型评估阶段。将负荷特征数据和标签中的剩余20%作为测试集。基于训练好负荷的识别模型，对负荷特征数据进行识别，得到负荷运行状态，根据测试集实际标签对改进GAF-Inception网络的识别结果进行评估。

2.2 改进Inception网络模型结构

对NILM系统而言，其模型应布置在嵌入式、边缘等资源受限设备上。过于庞大的参数模型难以在此类设备上实现高效运行。因此，减少模型参数量有助于在有限计算资源下实现高效的负荷识别。为降低Inception网络结构的参数量和计算负担，本文提出一种新型改进Inception网络结构，减少5×5的卷积通道，该改进的Inception网络结构如图2所示。

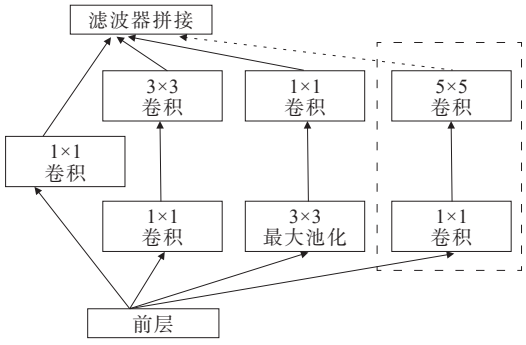

图2 改进Inception网络结构

Figure 2 Improved Inception network structure

在图2中，在原Inception网络结构消除右侧5×5卷积通道，减少不必要的特征提取。该改进后网络结构仍通过使用不同大小的卷积核提取多尺度的特征，但减少了一个通道的计算，大幅降低了模型的参数量。基于Inception网络结构不同通道的特征提取能力间的相关性，移除一个通道，减少冗余信息和计算负担，同时保留对目标特征的有效表达，使Inception网络结构能在保持较低计算成本，提高模型的表达能力和灵活，从而更好实现工业负荷监测和分析。本文建立基于改进Inception负荷识别网络结构，该基于改进Inception网络结构负荷识别模型如图3所示。

在图3中，c为卷积核个数，s为步幅。该改进Inception网络结构负荷识别模型总共包含4个Inception结构块，每2个Inception块组成一个block结构块，且第1个Inception块的步幅为2，第2个Inception块的步幅为1。第1个block结构块的卷积核个数设置为16，第2个block结构块的卷积核个数设置为32。输入矩阵经过3×3的卷积层升维成16通道输入到第1个block块，该结构块将输入数据加深到64通道，且输入数据的尺寸降低为原来的50%，再经过第2个block结构块将深度加倍，尺寸减半。由于过多模型参数会影响计算效率，本文先简化2个block结构块，输入数据经过卷积操作后，进行全局平均池化以减小参数数量；再进入全连接层；最后，通过softmax函数，输出负荷识别结果，减少计算时间，提高运算效率。

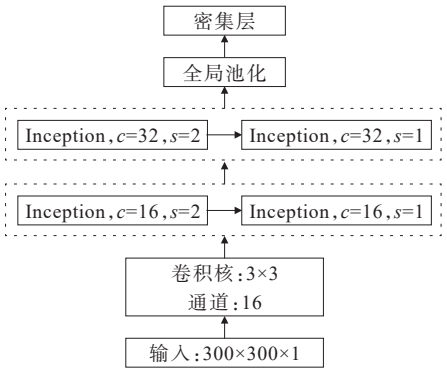

图3 基于改进Inception网络结构负荷识别模型

Figure 3 Load monitoring model based on improved inception network structure

2.3 模型的损失函数

本文选取分类交叉熵作为度量损失函数，该损失函数是是机器学习和深度学习中主要采用的损失函数，可用于多分类问题。对负荷辨识的问题，

假设有 N 个类别，真实设备标签用对应 one-hot 编码的向量来表示。

分类交叉熵损失函数 L 定义为

$$L=-\frac{1}{m}\sum_{i=1}^{m}\sum_{j=1}^{N}y_j^{(i)}\log_{10}(\hat{y}_j^{(i)}) \tag{7}$$

式中，$y_j^{(i)}$ 为真实设备状态的 one-hot 编码，i 为设备编号，j 为设备状态编号；$\hat{y}_j^{(i)}$ 为预测的设备状态的 one-hot 编码；m 为设备数；N 为设备状态类别。

2.4　基于 GAF-Inception 的 NILM 算法

为提取更丰富的特征并提高计算效率，本文提出基于改进 GAF-Inception 的 NILM 算法，该基于改进 GAF-Inception 的 NILM 整体框架如图 4 所示。

在图 4 中，用户低频总功率的一维时间序列作为输入，工业设备运行状态为输出。先将采集整理完备的一维功率时间序列通过 GAF 特征变换成带有时间特性的二维负荷功率图像，增加数据间的高维度特征；再将二维负荷功率图像经过一维卷积层增加数据特性表达能力；最后，基于改进 Inception 网络实现工业设备运行状态的识别。

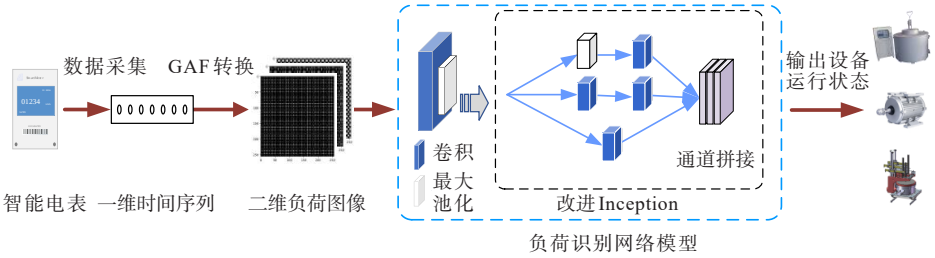

图 4　基于改进 GAF-Inception 的 NILM 整体框架

Figure 4　Overall framework of NILM based on improved GAF-Inception

本文提出的基于改进 GAF-Inception 的 NILM 负荷识别算法具体实现步骤共分 4 步。

1）数据获取。基于智能电表收集一维时间序列数据，记录工业用户的总功率消耗情况。

2）GAF 变换。对收集到的总功率时间序列数据进行预处理，并通过 GAF 变换，将其转换为 300×300×1 的格拉夫图像，增加负荷间高维度特征。

3）卷积增强。采用含有 3×3×16 卷积核的单层卷积网络处理 GAF 图像，将特征映射至 16 个通道，进一步增强数据的特征表现力。

4）负荷监测。应用改进的 Inception 网络模型，对经过增强的特征进行精细化处理，最终准确辨识出工业用户设备的运行状态。

3　试验验证与分析

为验证本文提出的基于改进 GAF-Inception 网络的工业负荷识别算法的准确性和有效性，采用国际公认工业设备识别数据集（industrial appliance identification dataset，IAID）作为数据集，基于多场景的工业负荷数据对非侵入式负荷辨识算法的性能进行验证。该数据集包括多个工业用户的 30 d 的 1 Hz 的低频总功率数据 P，并以 5 min 为时间尺度记录设备运行状态，共采集 8 640 个设备状态数据[27]。本文改进的 Inception 网络采用 Intel Core i5-12600K 进行训练与测试，模型语言为 Python，网络开发框架为 Tensorflow。

3.1　评价指标建立

本文采用混淆矩阵、准确率 I_{ACC} 与调和平均数 F_1 作为指标，评价负荷监测算法的性能。准确率 I_{ACC} 为预测正确的负荷分类个数与预测的负荷分类总数比，即

$$I_{ACC}=\frac{x_{TP}+x_{TN}}{x_{TP}+x_{FP}+x_{TN}+x_{FN}}\times 100\% \tag{8}$$

式中，x_{TP} 为样本的真实类别是正类，且模型预测的结果同是正类的数据个数；x_{TP} 为样本的真实类别是负类，但模型将其预测成为正类的数据个数；x_{FN} 为样本的真实类别是正类，而模型将其预测成为负类的数据个数。

根据混淆矩阵，可计算每个设备运行状态的准确度 I_{PRE}、召回率 I_{REC} 与这 2 者的调和平均数 F_1，具体的计算式分别为

$$I_{REC}=\frac{x_{TP}}{x_{TP}+x_{FN}}\times 100\% \tag{9}$$

$$I_{PRE}=\frac{x_{TP}}{x_{TP}+x_{FP}}\times 100\% \tag{10}$$

$$F_1=\frac{2I_{PRE}I_{REC}}{I_{PRE}+I_{REC}}\times 100\% \tag{11}$$

3.2　IAID 数据集介绍

IAID 数据集由多个工业用户 30 d 的对设备的 1 Hz 低频率低频总功率记录，涵盖 2019 年 6 月 1 日至

2019年6月30日之间8 640个设备状态信息[27]。针对不同行业工厂运行特点，本文选取IAID数据中的4家工厂（金属厂、化工厂、塑料厂、玻璃厂）的总负荷数据和设备状态进行分析，工业用户设备及其状态见表1。

表1 工业用户设备及其状态

Table 1 Industrial user equipment and its operational status

工业用户	工业设备	设备状态数
金属厂	电热处理炉	4
玻璃厂	电热炉、电动回火炉	12（3,4）
塑料厂	注塑机	3
化工厂	反应槽	4

由表1可知，玻璃厂有2种设备，电热炉和电动回火炉，其设备状态数分别为3和4。因此，玻璃厂的设备状态数组合为12种。

3.3 模型参数与训练过程

为验证基于改进GAF-Inception网络对低频工业负荷的辨识准确率，采用该方法对金属厂、化工厂、塑料厂和玻璃厂等4家工厂的工业设备进行负荷识别。

由于金属厂设备数量庞大、种类繁多、技术先进程度高，且其设备利用率、故障率等运行状态指标能更全面反映行业生产模式现状，更具有代表性和典型性，故本文以金属厂为例展开分析。

在进行数据处理和特征转换之后，所得到的带有时间特性的图像数据被用于构建网络模型。其中，80%的数据被送入所改进的Inception网络中，该网络负责输出不同工业用户的状态标签数量。模型的网络结构和参数设置详细信息见表2。

表2 改进的Inception网络结构

Table 2 Structure of improved Inception network

网络（类型）	层类型	输出形状	激活函数
数据输入层	输入层	（None,300,300,1）	
	卷积层	（None,298,298,16）	Relu
	批标准化层	（None,298,298,16）	
Inception_1	卷积层		
	最大池化	（None,149,149,48）	Relu
	卷积层		
	卷积层		
Inception_2	最大池化	（None,149,149,48）	Relu
	卷积层		
Inception_3	卷积层	（None,75,75,96）	Relu
	最大池化		
	卷积层		
	卷积层		
Inception_4	最大池化	（None,75,75,96）	Relu
	卷积层		
结果输出层	全局平均池化层	（None,1,1,96）	Softmax
	全连接层	（None,1,1,4）	

采用本文建立的改进Inception网络模型，对金属厂的识别准确率和损失值进行训练，其训练结果如图5所示。

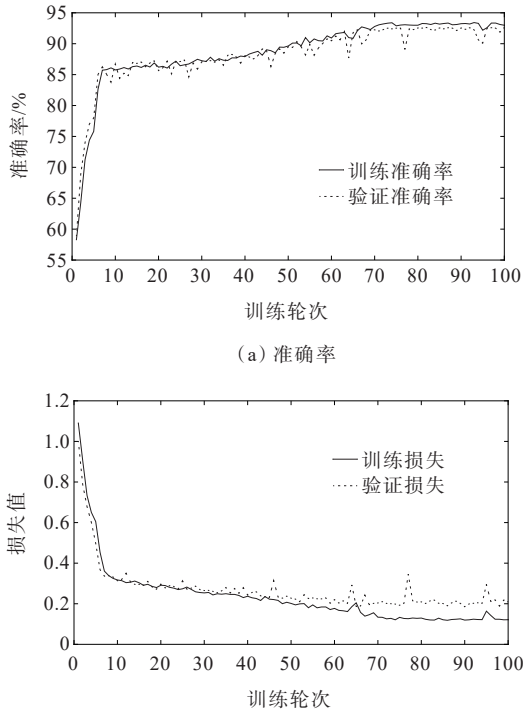

（a）准确率

（b）损失值

图5 金属厂准确率与损失值训练曲线

Figure 5 Accuracy and lost value training curves for metal plants

从图5中可以看出，在训练开始后的前10轮迭代中，测试准确率超过85%，损失值大幅下降；直到第75次迭代后，损失值趋于稳定；在经过100次迭代后，负荷识别的最高准确率为93%，满足当前工业环境实际负荷识别精度的要求。

3.4 不同工业场景泛化性分析

为验证本文建立的GAF-Inception负荷识别模型在不同生产场景下的泛化能力，分别在金属厂、玻璃厂、化工厂、塑料厂验证所提算法，金属厂、玻璃厂、化工厂、塑料厂的负荷识别混淆矩阵分别如图6(a)～(d)所示。

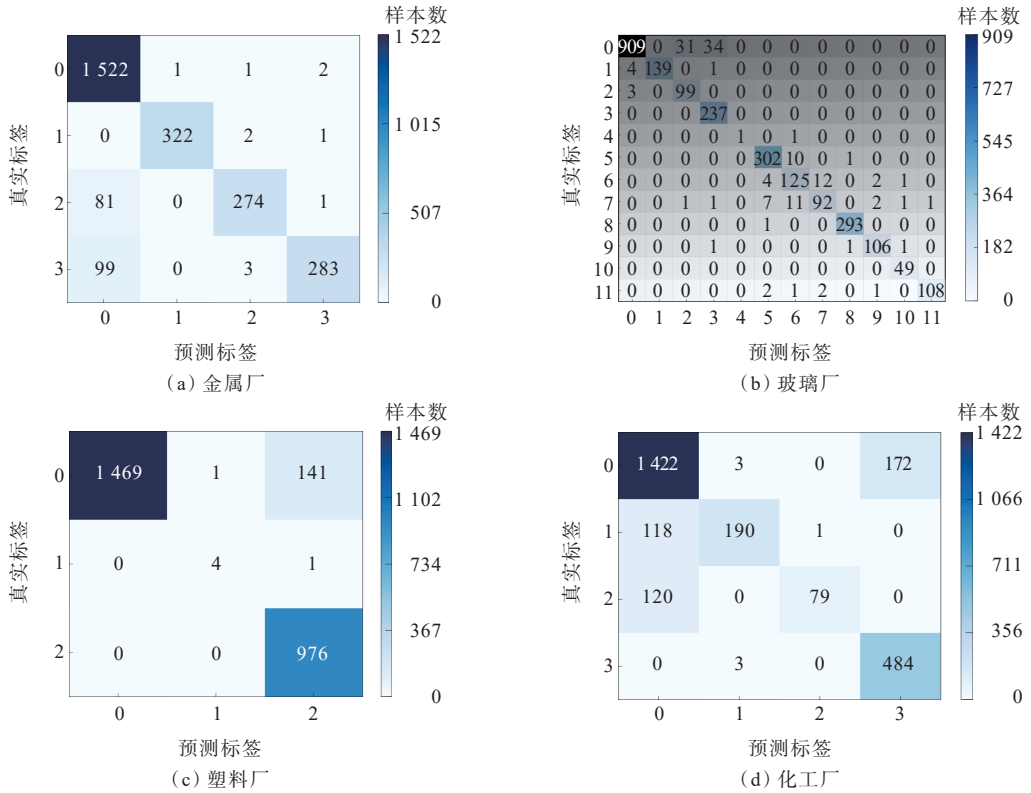

图 6　负荷识别的混淆矩阵

Figure 6　Confusion matrix for load monitoring

从图 6(a)中可以看出，本文改进的 Inception 网络模型对金属厂设备的停止状态与运行状态 1 的识别预测准确率较高，可达到 99%；设备处于运行状态 2 与运行状态 3 时工况复杂，协调该设备运作的其他辅助设备较多，从而产生较多噪声，影响对核心碳排放设备状态识别的准确性，导致识别准确率较低。从图 6(b)、(c)中可以看出，该方法对玻璃厂和塑料厂的整体识别准确率均超过 94%，除数据样本缺失情况外，各设备状态下识别准确率均超过 87%。从图 6(d)中可以看出，化工厂主要设备少且辅助设备多，设备间相互影响，在设备状态 0 的特征与设备状态 1 和 2 的特征存在相似之处，故设备状态 1 和 2 易被误判为设备状态 0，但方法整体准确率仍高于 83%，满足工业环境实际负荷识别的准确性要求。

综上所述，本文提出改进 GAF-Inception 网络的负荷识别算法先将负荷用电功率信息解构，将功率特征转换为如图 5 所示的二维灰度图像，其纹理信息丰富了特征参数；再对改进的 Inception 结构模型进行负荷识别，这 4 个工厂中的整体负荷识别准确率均超过 83%，实现了高精度的工业负荷辨识。这表明该算法具有良好的泛化性能，适用于不同类型工厂的设备状态识别。

3.5　与现有算法对比分析

为验证本文提出的基于改进 GAF-Inception 网络的非侵入式工业负荷识别算法的优越性，与现有采用主流算法进行比较分析，包括 K 近邻算法(k-nearest neighbor，kNN)、决策树(decision tree，DT)、随机森林(random forest，RF)、岭回归分类、卷积神经网络-双向长短期记忆网络(convolutional neural network bi-directional long short-term memory，CNN-BiLSTM[28-29])、挤压激励残差网络(squeeze-and-excitation resnet，SE-Resnet[30])、挤压激励长短期记忆网络(squeeze-and-excitation long short-term memory SE-LSTM[31])、多层门控循环单元(multi-layer gated recurrent unit，Multi-GRU[27])算法。其中 KNN、DT、RF、Ridge 等算法超参数遵循的 Python 中 sklearn 库的默认参数配置，CNN-BiLSTM[28]、SE-Resnet[30]、SE-LSTM[31]和 Multi-GRU[27]等算法参数则根据相应文献进行了详细设定，不同算法的对比结果见表 3。

由表 3 可知，本文所提算法的 F_1 和 I_{ACC} 在 4 个不同工业用户中均表现优越，实现了最佳辨识效果。对于金属厂、玻璃厂和塑料厂的辨识准确率均达到 92% 以上。其中，该算法对塑料厂辨识准确率最高，达

表 3 不同算法的对比结果

Table 3 Comparison results of different algorithms %

算法	金属厂		玻璃厂		塑料厂		化工厂	
	I_{ACC}	F_1	I_{ACC}	F_1	I_{ACC}	F_1	I_{ACC}	F_1
KNN	91.14	89.52	85.18	75.41	92.91	71.37	80.34	76.46
DT	88.03	87.71	78.24	78.32	93.86	68.75	82.13	77.69
RF	90.54	89.82	87.85	79.53	94.19	72.24	83.00	78.49
Ridge	49.56	48.25	38.64	46.59	50.66	32.18	51.69	58.45
CNN-BiLSTM[28]	83.61	83.40	49.52	76.96	84.76	81.52	74.94	66.77
SE-Resnet[30]	91.03	87.73	87.15	54.48	93.69	62.34	82.70	78.70
SE-LSTM[31]	91.55	88.62	89.41	54.68	93.69	62.34	82.52	78.31
Multi-GRU[27]	91.26	88.15	94.10	63.38	93.81	89.07	83.04	79.17
GAF-Inception	92.66	92.18	94.24	84.85	94.48	89.53	83.99	79.89

到94%。化工厂的辨识准确率最低，仅有84%，但本文所提算法辨识准确率依旧最高。塑料厂、玻璃厂和化工厂中的F_1值略次，这些厂中设备状态复杂，二维图像的特征不佳，造成总体F_1偏小。虽然SE-Resnet、SE-LSTM和Multi-GRU在玻璃厂和塑料厂上I_{ACC}均较高，但是没有进行GAF提取的灰度图像特征，其F_1明显低于本文所提算法的，表明本文算法在不同类别识别性能更加平衡，具有更佳的泛化性。Multi-GRU对金属厂和玻璃厂均有较高辨识准确率，但对于其他厂的辨识结果欠佳，泛化性差。综上所述，本文提出算法在工业负荷辨识准确率与泛化性上均优于现有算法，且在不同类别工业负荷识别平衡性能更强。

3.6 消融试验

为减少冗余信息和计算负担，本文提出了改进Inception网络。为验证网络的有效性，基于模型参数与训练过程，以金属厂为例，其改进前、后模型结构见表4。

由表4可知，改进后网络结构的所需训练的参数量大幅减少，减少51%的参数量。其中，Sequential层的参数量参数最多。因为该部分中5×5卷积通道计算量较大，去除5×5卷积通道，减少模型计算的冗余信息和计算负担，同时可保留网络的复杂性和计算效率，使得改进的Inception网络结构能够在保持较低计算成本的同时，提高模型的表达能力和灵活性。

表 4 改进前、后模型结构

Table 4 Structure of models before and after improvement

层名(类型)	输出形状	改进前参数量	改进后参数量
输入层	(None,300,300,1)	0	0
卷积层	(None,300,300,16)	224	224
Inception层	(None,150,150,512)	119 616	58 176
最大池化层	(None,512)	0	0
全连接层	(None,4)	516	516

为验证改进模型的有效性，选用金属厂、塑料厂、玻璃厂和化工厂的数据构建试验，将5×5卷积核替换为2个3×3卷积核，与改进前、后的Inception网络进行对比试验，并采用准确率、F_1分数和计算时间等进行指标分析。算法改进前、后结果对比见表5。

由表5可知，改进后模型相较于改进前模型在金属厂中准确率下降0.84%，计算时间减少174.75 s；在塑料厂中准确率下降0.04%，计算时间减少140.95 s；在玻璃厂中准确率下降0.28%，计算时间减少131.35 s；在化工厂中准确率下降0.85%，计算时间减少137.40 s。相较于替换后模型，在金属厂中改进后模型计算时间减少了520.13 s；在塑料厂中改进后模型的计算时间减少了595.42 s；在玻璃厂中改进后模型计算时间减少了595.46 s；在化工厂中改进后模型计算时间减少了521.6 s。综上所述，这4个工厂的整体计算成本降低8%，验证了本文改进后模型在保持合理准确率的同时，能显著降低计算资源的消耗。

表 5 算法改进前、后结果对比

Table 5 Result comparison before and after algorithm improvement

工厂类型	I_{ACC}/%			F_1/%			计算时间/s		
	改进前	替换后	改进后	改进前	替换后	改进后	改进前	替换后	改进后
金属厂	93.50	91.51	92.66	92.68	92.20	92.18	1 748.57	2 093.95	1 573.82
塑料厂	94.52	94.33	94.48	93.18	94.50	89.53	1 713.56	2 168.03	1 572.61
玻璃厂	94.52	93.79	94.24	85.33	93.78	84.85	1 697.08	2 161.19	1 565.73
化工厂	84.84	83.50	83.99	77.50	83.95	79.89	1 722.27	2 106.53	1 584.87

4　结语

针对当前非侵入式工业负荷识别准确率不高、泛化能力弱的问题，本文提出了基于改进 GAF-Inception 网络的工业负荷非侵入式负荷辨识算法，得到了如下的结论：

1）本文提出的基于 GAF 的特征变换方法，将一维时间序列数据转为带有时间特性的二维图像信息，更有效地获取不同工业场景下负荷特征信息，解决了负载监测中数据高维度和复杂特征提取的问题，将低频工业数据上的识别准确率最高提高至 94.48%。

2）本文建立了改进的 Inception 网络模型，对 Inception 网络结构进行改进，减少冗余信息和计算负担。在保证工业负荷识别效果的同时，提高了模型的计算效率和表达能力，减少了 51% 的参数量，降低了 8% 以上的计算成本。

3）本文提出的基于改进 GAF-Inception 网络的负荷监测算法，使用多尺度特征提取和稀疏连接网络，解决了非侵入式负载监测中特征提取复杂、参数过多的问题，其在这 4 个工厂中的识别准确率均大于 83%，且与现有算法对比具有最佳泛化性。

综上所述，本文提出的基于改进 GAF-Inception 网络的工业负荷非侵入式辨识算法能对低频数据下工业负荷实现精准、高效识别，且具有良好的场景泛化能力，满足新型电力系统建设下多种工业场景负荷辨识的实现要求。

参考文献：

[1] 习近平在第七十五届联合国大会一般性辩论上发表重要讲话[EB/OL].(2020-09-22) [2024-03-22].http://www.gov.cn/xinwen/ 2020-09/22/content_5546168.htm

[2] 谭显东,刘俊,徐志成,等."双碳" 目标下"十四五" 电力供需形势[J].中国电力,2021,54(5): 1-6.
TAN Xiandong, LIU Jun, XU Zhicheng, et al. Power supply and demand balance during the 14th Five-Year Plan period under the goal of carbon emission peak and carbon neutrality[J].Electric Power,2021,54(5): 1-6

[3] 刘鹏,崔雪.双碳背景下考虑市场份额偏好的发电侧市场均衡分析[J].电力科学与技术学报,2023,38(2): 9-17+39.
LIU Peng, CUI Xue. Equilibrium analysis of power generation market considering market share preference un-der carbon-neutral goal[J]. Journal of Electric Power Science and Technology,2023,38(2): 9-17+39.

[4] FROEHLICH J, LARSON E, GUPTA S, et al. Disaggregated end-use energy sensing for the smart grid [J].IEEE Pervasive Computing,2010,10(1): 28-39.

[5] HART G W. Nonintrusive appliance load monitoring[J]. Proceedings of the IEEE,1992,80(12): 1870-1891.

[6] 栾开宁,杨世海,黄艺璇,等.基于 Fisher-SVM 特征选择的负荷辨识研究[J].电力科学与技术学报,2023,38(4): 230-239+264.
LUAN Kaining, YANG Shihai, HUANG Yixuan, et al. Research on Fisher-SVM feature selection based load identification[J]. Journal of Electric Power Science and Technology,2023,38(4): 230-239+264.

[7] 王丙楠,陆玲霞,包哲静,等.一种基于度量学习的自适应非侵入式负荷识别方法[J].电测与仪表,2024,61(11): 54-60.
WANG Bingnan, LU Lingxia, BAO Zhejing, et al. An adaptive non-intrusive load identification method based on metric learning[J]. Electrical Measurement & Instrumentation,2024,61(11): 54-60.

[8] 苏晓,余涛,徐伟枫,等.基于隐马尔可夫模型的非侵入式负荷监测泛化性能改进[J].控制理论与应用,2022,39(4): 691-700.
SU Xiao, YU Tao, XU Weifeng, et al. Generalization performance improvement of non-intrusive load monitoring based on hidden Markov model[J]. Control Theory & Applications,2022,39(4): 691-700.

[9] 严萌,于雅雯,王玲静,等.基于多特征联合稀疏表达的 SOM-K-means 非侵入负荷辨识[J].电力建设,2023,44(5): 61-71.
YAN Meng, YU Yawen, WANG Lingjing, et al. SOM-K-means non-intrusive load identification based on multi feature joint sparse expression[J]. Electric Power Construction,2023,44(5): 61-71.

[10] 延菲,张瑞祥,孙耀杰,等.基于改进 kNN 算法的非侵入式负荷识别方法[J].复旦学报(自然科学版),2021,60(2): 182-188.
YAN Fei, ZHANG Ruixiang, SUN Yaojie, et al. Non-intrusive load identification method based on improved kNN algorithm[J]. Journal of Fudan University (Natural Science),2021,60(2): 182-188.

[11] 李乐,刘智源,王学军,等.基于 SDP 信息融合的用电特征分析及负荷识别方法研究[J].电网与清洁能源,2024,40(8): 56-63+73.
LI Le, LIU Zhiyuan, WANG Xuejun, et al. Research on the electricity consumption characteristic analysis and load identification method based on SDP information fusion[J]. Power System and Clean Energy,2024,40(8): 56-63+73.

[12] 周东国,张恒,周洪,等.基于状态特征聚类的非侵入式负荷事件检测方法[J].电工技术学报,2020,35(21): 4565-4575.
ZHOU Dongguo,ZHANG Heng,ZHOU Hong,et al.Non-intrusive load event detection method based on state feature clustering[J]. Transactions of China Electrotechnical Society,2020,35(21): 4565-4575.

[13] 孙毅,崔灿,张璐,等.智能用电非侵入式负荷监测系统研究[J].电力科学与技术学报,2019,34(2): 155-160.
SUN Yi, CUI Can, ZHANG Lu, et al. Research on nonintrusive load monitoring system for global energy Internet[J]. Journal of Electric Power Science and

Technology,2019,34(2): 155-160.

[14] 张帅,程志友,田甜,等.基于马尔可夫转移场和轻量级网络的非侵入式负荷识别[J].电力系统保护与控制,2024,52(17): 51-61.
ZHANG Shuai, CHENG Zhiyou, TIAN Tian, et al. Non-intrusive load identification based on the Markov transition field and a lightweight network[J]. Power System Protection and Control,2024,52(17): 51-61.

[15] FONTANA C, SANSEVERINO E R. On the non-intrusive load monitoring in dwellings: a feasibility perspective[C]//2021 IEEE International Conference on Environment and Electrical Engineering and 2021 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I&CPS Europe).Bari,Italy.IEEE,2021: 1-5.

[16] 汪颖,杨维,肖先勇,等.基于U-I轨迹曲线精细化识别的非侵入式居民负荷监测方法[J].电网技术,2021,45(10): 4104-4113.
WANG Ying, YANG Wei, XIAO Xianyong, et al. Non-intrusive residential load monitoring method based on refined identification of U-I trajectory curve[J]. Power System Technology,2021,45(10): 4104-4113.

[17] 赵成,宋彦辛,周赣,等.基于先验统计模型的非侵入负荷辨识算法[J].电力工程技术,2024,43(1): 165-173+211.
ZHAO Cheng, SONG Yanxin, ZHOU Gan, et al. Resident non-invasive load identification algorithm based on prior statistical model[J]. Electric Power Engineering Technology,2024,43(1): 165-173+211.

[18] DA SILVA NOLASCO L, LAZZARETTI A E, MULINARI B M. DeepDFML-NILM: a new CNN-based architecture for detection, feature extraction and multi-label classification in NILM signals[J]. IEEE Sensors Journal,2022,22(1): 501-509.

[19] ZHANG C Y,ZHONG M J,WANG Z Z,et al. Sequence-to-point learning with neural networks for nonintrusive load monitoring[EB/OL]. (2016-12-29) [2024-03-03]. https://arxiv.org/abs/1612.09106

[20] 封钰,宋佑斌,金晟,等.基于随机森林算法和粗糙集理论的改进型深度学习短期负荷预测模型[J].发电技术,2023,44(6): 889-895.
FENG Yu,SONG Youbin,JIN Sheng,et al.Improved deep learning model for forecasting short-term load based on random forest algorithm and rough set theory[J]. Power Generation Technology,2023,44(6): 889-895.

[21] 王轲,钟海旺,余南鹏,等.基于seq2seq和Attention机制的居民用户非侵入式负荷分解[J].中国电机工程学报,2019,39(1): 75-83+322.
WANG Ke, ZHONG Haiwang, YU Nanpeng, et al. Nonintrusive load monitoring based on sequence-to-sequence model with attention mechanism[J]. Proceedings of the CSEE,2019,39(1): 75-83+322.

[22] 孙睿晨,董坤,赵剑锋,等.基于递进式模型结构和时间信息嵌入的非侵入式负荷分解[J].智慧电力,2024,52(2): 55-62+70.
SUN Ruichen, DONG Kun, ZHAO Jianfeng, et al. Non-intrusive load decomposition based on progressive model structure and temporal information embedding[J]. Smart Power,2024,52(2): 55-62+70.

[23] 高昂,郑建勇,梅飞,等.基于三元组孪生网络的窃电检测算法[J].中国电机工程学报,2022,42(11): 3975-3986.
GAO Ang, ZHENG Jianyong, MEI Fei, et al. Electricity theft detection algorithm based on triplet network[J]. Proceedings of the CSEE,2022,42(11): 3975-3986.

[24] 邹念,魏梅芳,苏盛,等.基于水电关联信息的零电量低压用户窃电检测[J].中国电力,2023,56(12): 206-216.
ZOU Nian, WEI Meifang, SU Sheng, et al. Detection of electricity theft by low voltage users with zero power consumption based on water-electricity correlation information[J].Electric Power,2023,56(12): 206-216.

[25] 刘志坚,何蔚,刘航,等.基于格拉姆角场变换和深度压缩模型的变压器故障识别方法[J].电网技术,2023,47(4): 1478-1490.
LIU Zhijian,HE Wei,LIU Hang,et al.Fault identification method for power transformer based on gramian angular field transformation and deep compression model[J]. Power System Technology,2023,47(4): 1478-1490.

[26] 周家玉,侯慧娟,盛戈皞,等.状态参量关联规则挖掘及深度学习融合的变压器故障诊断算法[J].高压电器,2023,59(3): 108-115.
ZHOU Jiayu, HOU Huijuan, SHENG Gehao, et al. Transformer fault diagnosis algorithm based on association rules mining of state parameters and deep learning[J].High Voltage Apparatus,2023,59(3): 108-115.

[27] LIU G L,LIU J J,ZHAO J H,et al. Real-time corporate carbon footprint estimation methodology based on appliance identification[J]. IEEE Transactions on Industrial Informatics,2022,19(2): 1401-1412.

[28] 贺才郡,李开成,杨王旺,等.基于双通道GAF和深度残差网络的电能质量复合扰动识别[J].电网技术,2023,47(1): 369-379.
HE Caijun, LI Kaicheng, YANG Wangwang, et al. Power quality compound disturbance identification based on dual channel GAF and depth residual network[J]. Power System Technology,2023,47(1): 369-379.

[29] 王昭卿,常延朝,陈建磊,等.基于多融合MVMD-ISVM的复杂电能质量扰动识别方法[J].供用电,2024,41(9): 70-77.
WANG Zhaoqing,CHANG Yanzhao,CHEN Jianlei,et al. Identification method for complex power quality disturbances based on multi-fusion MVMD-ISVM[J]. Distribution & Utilization,2024,41(9): 70-77.

[30] CHEN T, QIN H Y, LI X S, et al. A non-intrusive load monitoring method based on feature fusion and SE-ResNet[J].Electronics,2023,12(8): 1909.

[31] HWANG H, KANG S. Nonintrusive load monitoring using an LSTM with feedback structure[J]. IEEE Transactions on Instrumentation and Measurement,2022,71: 2509111.