

基于非侵入式负荷分解的有色金属冶炼工序识别^{*}

方祖春 汪繁荣

(湖北工业大学电气与电子工程学院 武汉 430068)

摘要:为进一步简化数据处理过程和提高生产工序识别准确率,提出一种基于非侵入式负荷分解的工序识别方法。首先将每种工序定义为一种用电设备,然后根据非侵入式负荷分解相关理论,分别选取双向长短期记忆网络和时间卷积网络构建负荷分解模型,选择各用电设备对应功率、总功率数据构造数据集对模型进行训练和测试,最后对测试集负荷分解结果进行相关处理得到对应的工序数据。结果表明由基于时间卷积网络的负荷分解方法构成的工序识别模型具有较高的识别准确率,针对测试集的工序识别准确率达98.83%。

关键词:非侵入式负荷分解;双向长短期记忆网络;时间卷积网络;工序识别

中图分类号: TM714 **文献标识码:** A **国家标准学科分类代码:** 510.4010

Process identification of non-ferrous metal smelting based on non-invasive load decomposition

Fang Zuchun Wang Fanrong

(School of Electrical and Electronic Engineering, Hubei University of Technology, Wuhan 430068, China)

Abstract: In order to further simplify the data processing process and improve the accuracy of production process identification, a process identification method based on non-invasive load decomposition was proposed. Firstly, each process was defined as a kind of electrical equipment. Then, according to the relevant theories of non-invasive load decomposition, bidirectional long short-term memory network and temporal convolution network were selected to construct the load decomposition model, and the corresponding power and total power data of each electrical equipment were selected to construct the data set for training and testing the model. Finally, the corresponding process data was obtained by relevant processing of the load decomposition results of the test set. The results show that the process identification model constructed by the load decomposition method based on the temporal convolution network has high recognition accuracy, and the process identification accuracy for the test set is 98.83%.

Keywords: non-invasive load decomposition; bidirectional long short-term memory network; temporal convolution network; process identification

0 引言

近年来随着温室效应带来居住环境的逐渐恶化,低碳节能开始得到各国相关部门的重视,我国相关法律法规也表明了国家对于节约能源的支持与重视。钢铁、有色金属等冶炼行业由于其生产工艺特点,一直存在能耗高的问题,是我国减少碳排放重点关注行业之一。因此以节约能源、提高能源利用效率为目的能耗管理系统逐渐应用于钢铁、有色金属冶炼等高耗能企业,能耗管理系统不仅可以

为用户提供详细的用能分析,同时还可以结合生产特点及电能计费的峰—平—谷规则给出相关的节能降本建议。针对多工序、顺序进行的生产过程,根据相关生产数据确定生产工序,不仅有助于对生产线生产过程进行实时监测,计算出每道工序对应的生产时间、功率,给出详细的用能分析,同时有助于管理人员监测实际生产过程是否与生产计划保持一致,并及时做出相应的处理。目前用于工序识别及相关判断的方法较多,文献[1]使用基于机器视觉和决策树的方法对于面包发酵过程中所处阶段进行判定;

收稿日期:2022-11-01

^{*} 基金项目:国家自然科学基金(61903129)项目资助

文献[2]提出一种基于深度学习和多信息融合的判定方法,结合机器视觉实时检测金属镁在冶炼过程中的异常状态,此类方法需要外接摄像头等传感设备,应用成本较高,训练过程较复杂;文献[3]通过系统采集的瓦斯浓度变化规律判定掘进工作面生产工序,但是面对数据量大、逻辑关系较复杂的生产工序确定问题,人工分析存在过程复杂、识别结果准确率较低等问题。针对目前研究成果的应用成本高、训练复杂、部分场景人工分析较难实现等问题,本文提出一种基于非侵入式负荷分解的工序识别方法。非侵入式负荷分解主要应用于居民家庭负荷监测,通过在居民电源入户总线处增设采集装置或通过入户电表获取全屋总功率等数据并使用相关方法进行分析和处理,获取屋内各用电设备及其状态等数据,实现对全屋用电设备的监测与用能分析,相对于侵入式负荷分解,非侵入式负荷分解具有应用便捷、设备成本低、不侵犯用户隐私等特点^[4-5]。尤其近年来基于深度学习的负荷分解研究成果较多,如文献[6]在对电器按照工作状态进行分类后,分别采用基于双向长短期记忆神经网络(bi-directional long short term memory, BiLSTM)和基于事件监测的模型进行负荷分解并取得了较高的稳定性和负荷辨识率;文献[7]在BiLSTM的基础上考虑了某些内在或外在的因素对设备能耗的影响,以此来适应变化的设备运行状态及能耗,提高负荷分解模型的可移植性。目前影响非侵入式负荷辨识准确率的主要因素为一种电器存在多种工作状态、多种用电设备同时工作等^[8-9],本文将每道生产工序定义为一种用电设备,每道工序只有运行、停止两种状态,且不存在多道工序同时进行的状况,对应所有用电设备只有开、关两种状态,同一时刻只有一种用电设备处于开启状态,因此对其进行负荷分解在理论上可以取得较高的准确率,对负荷分解结果进行进一步处理后即可获得较高的工序识别准确率,且利用非侵入式负荷分解方法的安装使用方便、设备成本低、学习能力强等特点,进一步简化工序识别过程,有助于提高基于工序识别的能耗系统的使用性与推广价值。本文选择时间卷积网络(temporal convolutional network, TCN)、BiLSTM构建对应的负荷分解模型,对负荷分解结果进行相关处理得到对应的工序数据,最后结合青海某钛金属冶炼企业某生产线生产能耗数据及生产工序信息对模型进行训练和测试,选出工序识别率准确率较高的模型,用于企业生产线实际工序识别,并结合能耗管理系统、生产管理系统,助力企业实现节能、增效目的。

1 方法介绍

1.1 TCN 网络

TCN 是一种基于残差模块的卷积网络,其不仅具备卷积网络在数据特征提取、并行处理等方面的优势,而且通过卷积操作代替递归操作还可用于处理时序数据^[10]。TCN 的结构如图 1 所示,从图 1 可知,任意 t 时刻的输出,只和 t 时刻及之前的输入有关,且每一层链接到上一层时可以间

隔一定距离选择数据,依次类推,可以保证输出层具有较大范围的视野,从而该模型可以学习数据的长期依赖关系^[11]。




图 1 TCN 结构

TCN 主要结构的组成部分如表 1 所示^[11]。其中膨胀卷积使得模型拥有较大的视野同时减小了模型的复杂度,因此 TCN 可以处理长期的数据依赖关系。残差连接可以加速模型收敛,同时防止模型退化,避免出现梯度消失问题。

表 1 TCN 各组成部分

名称	数学表达式	说明
因果卷积	$F(x_t) = \sum_{i=1}^K f_i \times x_{t-K+i}$	按照时间先后进行卷积操作,保证没有泄露未来信息。
膨胀卷积	$F(x_t) = \sum_{i=0}^M f_i \times x_{t-d \times i}$	增大每层感受野,减小卷积层数量。
残差连接	$F(x_t, W_t) = H(x_t) - x_t$	防止模型退化,模型收敛更快。

其中, x_t 为 t 时刻的输入信息; f_i 为滤波器 i 对应的参数; K 为卷积核大小; M 为滤波器个数; d 为膨胀系数; W_t 为 t 层的权重参数矩阵; $H(x_t)$ 为实际目标映射值。

1.2 BiLSTM 网络

BiLSTM 作为长短期记忆网络(long short term memory, LSTM)的变体算法,主要由前向和反向传播两层 LSTM 构成^[12]。LSTM 是一种改进的循环神经网络,相对于传统的循环神经网络 RNN 只能处理一定短期依赖问题,LSTM 算法可用于处理长期非线性、非平稳的时间序列数据^[13]。LSTM 网络单元结构如图 2 所示。




图 2 LSTM 网络单元结构

相对于传统的循环神经网络 RNN 新增了门结构和单元状态,其中门结构包含类型及相关信息如表 2 所示^[13]。

表 2 门结构类型及相关信息

门类型	数学表达式	作用
遗忘门	$f_t = \sigma(W_f \cdot [y_{t-1}, x_t] + B_f)$ $i_t = \sigma(W_i \cdot [y_{t-1}, x_t] + B_i)$	决定单元状态 中丢弃的数据
输入门	$r_t = \tanh(W_r \cdot [y_{t-1}, x_t] + B_r)$ $c_t = f_t * c_{t-1} + i_t * r_t$	决定单元状态 中保存的数据
输出门	$o_t = \sigma(W_o \cdot [y_{t-1}, x_t] + B_o)$ $y_t = o_t * \tanh(c_t)$	决定单元状态 中输出的数据

其中, x_t 为 t 时刻的输入信息; y_t 为 t 时刻的输出信息; f_t 为 t 时刻的遗忘门信息; i_t 为 t 时刻的记忆门信息; r_t 表示当前时刻保存的信息; c_t 为当前单元状态; o_t 为 t 时刻的输出门信息; σ 为 sigmoid 激活函数; $\tanh$ 是双曲正切激活函数; $W_f, W_i, W_r, W_o, B_f, B_i, B_r, B_o$ 为相关矩阵。

基于 LSTM 的网络单元, BiLSTM 的网络结构如图 3 所示^[14]。




图 3 BiLSTM 结构

其对应表述公式^[14]如下:

$$h_t = f(W_1 x_t + W_2 h_{t-1}) \quad (1)$$

$$r_t = f(W_3 x_t + W_5 r_{t+1}) \quad (2)$$

$$y_t = g(W_4 h_t + W_6 r_t) \quad (3)$$

式中: x_t 为 t 时刻的输入信息; h_t 表示 x_t 经前向传播层后的输出信息; r_t 表示 x_t 经反向传播层后的输出信息; y_t 为 t 时刻的输出信息; f 和 g 分别表示前向传播层和反向传播层、输出层对应的激活函数; $W_1 \sim W_6$ 分别为对应的数据映射权重矩阵。

从图 3 可以看出 BiLSTM 算法不仅可以学习时间序列数据之间的顺序关系,还可以从反向检查并学习数据之间的关系^[15]。

2 模型搭建与数据介绍

2.1 模型搭建

本文提出的基于非侵入式负荷分解的工序识别模型搭建流程如图 4 所示。

使用 Python 语言基于 keras 框架分别搭建了基于




图 4 模型搭建流程

TCN 和 BiLSTM 的负荷分解模型,并使用 Adam 优化器,将均方误差(mean-square error, MSE)作为损失函数^[16],模型的关键参数采用经验法和试错法获得,通过不同的参数组合结合训练数据对模型进行训练,比较得出对应模型识别准确率最高的参数组合,硬件平台采用搭载 AMD 处理器 Ryzen 7 5800 H 和 NVIDIA GeForce GTX1650 显卡及 16 G 内存的 Windows 计算机。

2.2 数据介绍与处理

本文选取青海某钛金属冶炼企业某一生产线自 2021 年 8 月 6 日~2021 年 8 月 30 日共 25 d 连续生产能耗数据,结合生产工序记录数据,最后获得 3 556 组生产能耗与对应工序数据。数据获取方式为每 10 min 采集一次产线总功率数据,并记录对应工序状态,所有数据按照生产次数进行整理后如表 3 所示。

该时间段共包含 16 次完整的生产过程,单次生产从清炉到冷却成型耗时不定,最长为 42.5 h,最短为 18.5 h。从表 3 可以看出,所有生产工序中仅有补缩和冷却耗时间分别固定为 1.5 和 4 h,其他工序耗时均不确定,各工序切换时功率数据大部分都发生了变化,经过对数据特点进行分析后得出可以通过相同功率数据的持续时间来识别补缩和冷却过程工序,再通过前后功率变化确定其他工序。虽然该数据时间跨度不大、数据量有限,但是考虑到该生产过程步骤固定,且功率与工序间的关系较明显,各工序间没有重叠部分,因此选择合适的时间长度构造数据集对负荷分解模型进行训练可以取得较满意的分解结果,

表3 按生产次数整理后数据

生产 序号	清炉 功率 /W	清炉 时间 /h	抽真空 功率 /W	抽真 空时间 /h	加热 功率 /W	加热 时间 /h	拉锭 功率 /W	拉锭 时间 /h	补缩 功率 /W	补缩 时间 /h	冷却 功率 /W	冷却 时间 /h	总耗 时/h
1	0	6	2 100	5	3 310	11	4 200	15	4 300	1.5	3 600	4	42.5
2	0	5	3 400	1	3 069	2.5	4 600	11.5	3 970	1.5	3 700	4	25.5
3	0	4	3 600	2.5	3 800	8.5	4 300	11.5	3 650	1.5	3 299	4	32
4	0	5	3 400	3	4 100	3.5	4 100	12.5	3 200	1.5	2 100	4	29.5
5	0	9	3 311	1.5	1 800	4.5	4 300	15.5	1 100	1.5	1 000	4	36
6	0	3.5	660	2.5	639	4	1 300	9.5	1 300	1.5	711	4	25
7	0	3.5	700	2	830	2.5	2 400	11.5	2 000	1.5	1 030	4	25
8	0	4	1 230	2	960	4.5	2 000	12.5	2 700	1.5	2 200	4	28.5
9	0	4.5	3 500	2.5	3 500	3	4 500	13	4 100	1.5	4 500	4	28.5
10	0	3	3 300	4	3 100	3	4 700	12.5	3 727	1.5	3 000	4	28
11	0	3.5	3 188	2.5	3 442	3	4 677	12.5	2 800	1.5	3 300	4	27
12	0	3.5	1 500	2	2 900	3	4 100	4.5	3 800	1.5	3 300	4	18.5
13	0	7	2 900	4	2 350	3.5	1 715	12	4 200	1.5	2 100	4	32
14	0	4	3 645	8	2 100	4	4 000	12	2 627	1.5	2 200	4	33.5
15	0	11.5	3 600	3	2 200	4	3 600	12.5	3 300	1.5	3 600	4	36.5
16	0	5.5	3 400	2.5	3 700	3	4 354	14	1 100	1.5	790	4	30.5
17	0	4	790	2.5	920	2.5	2 700	15.5	1 700	1.5	—	4	30

并最终取得较高准确率的工序判定结果。

针对原始数据个别值差异太大可能会影响模型收敛效果的问题,对数据进行归一化处理,按照统一比例将样本数据大小映射到 $[0,1]$ 范围内^[17],计算公式如下:

$$p' = \frac{p - P_{\min}}{P_{\max} - P_{\min}} \quad (4)$$

式中: p 为该实验样本数据的原始值; p' 是处理后的值; $P_{\max}$ 、 $P_{\min}$ 分别为实验样本数据原始值中的最大值与最小值。

该有色金属生产线运行方式为按照固定流程进行24 h不间断运作,主要生产流程包括容器清理、容器抽真空、加热、拉锭、补缩、冷却,部分工序间存在中断等待时间,本文根据不消耗电能将容器清理和中断等待过程归为一类,其余工序过程各为一类,最终的工序定义如表4所示,经整理后的工序信息有6种类型,分别为清炉或等待、容器抽真空、加热、拉锭、补缩、冷却,对应工序序号为0~5。

表4 生产工序分类

序号	对应工序
0	清炉或等待
1	炉内抽真空
2	炉内加热
3	拉锭
4	补缩
5	冷却

由于工序0对应的功率为0,因此在进行负荷分解数

据集构造时仅考虑工序1~5。首先定义工序1~5分别对应用电设备1~5,每道工序对应的功率数据则为对应5种用电设备的各自单独使用时的功率数据,取总功率数据和各用电设备功率组成模型训练和测试用数据集,其中特征数据集为某一时间窗口的总功率数据,标签数据集为总功率数据中某一时刻各用电设备的对应功率。如按照窗口大小为145对原始数据进行处理后得到3 411组数据集,选择前3 069组用于模型训练,后342组用于模型测试,对应的测试集总功率及工序如图5所示。

3 实验过程及结果

3.1 实验过程

结合训练数据集和测试数据集,分别建立基于TCN、BiLSTM负荷分解方法的工序识别模型,模型评价指标为工序识别准确率,计算表达式如下:

$$acc = \frac{N_{acc}}{N} \times 100\% \quad (5)$$

式中: N_{acc} 为工序识别结果与实际值保持一致的数量; N 为测试集数据总数。为使模型获取足够长的观察视野,同时减少模型的复杂度和训练时间,本文分别选择大小为145、217、289的时间窗口对应的总功率数据构造特征数据集,标签集为当前窗口中间时刻各用电设备的对应功率并保持不变,以模型针对测试集进行工序识别的准确率作为目标函数,然后采取遍历的方式寻找最高识别率对应的模型参数。

在计算目标函数时,考虑原始数据中任意时刻只存在一种工序状态,根据定义即该时刻只有工序对应的用电设




图5 测试集总功率及对应工序

备处于开启状态,其他工序对应的用电设备均处于关闭状态,且该时刻打开的用电设备(除设备0以外)功率值最大为总功率值,其他处关闭状态的用电设备功率值为0。因此任意时刻的工序状态与该时刻用电设备功率值最大者是一一对应的,则可以通过总功率数据经负荷分解后的各用电设备功率数据中最大值来确定当前对应的工序数据。处理流程如下。

1)使用经训练后的负荷分解模型对测试集某一时刻总功率数据进行分解,获取各用电设备的功率数据。

2)取该时刻负荷分解结果中单个用电设备功率最大值对应的设备序号即为当前对应的工序编号。

3)测试集所有数据经上述方法处理后,采用式(5)计算工序识别准确率。

数据处理流程如图6所示,在指定模型的参数范围及目标函数后,分别代入不同的特征数据集与标签数据集进行训练与测试。

经过数据集构造与模型参数寻优后,得到基于TCN负荷分解方法的工序识别模型针对测试数据集取得最高识别率对应的相关参数,其对应基于TCN的负荷分解结果如图7所示。

从图7可以看出,负荷分解结果与实际值有一定的差距,如分解后总功率与实际总功率有一定出入,尤其在采样序号60~100和175~325的功率数值对比,二者不仅




图6 基于TCN的工序识别模型




图7 基于TCN的负荷分解结果

数值存在差距,且负荷分解后总功率曲线变化情况也未与实际功率变化情况保持一致,但考虑到同一时刻只进行一种工序操作,所以在根据总功率信息判定某一时刻对应工序时,取该时刻负荷分解结果中单个用电设备功率最大值对应的设备序号即为当前对应的工序编号,因此在对负荷分解结果做进一步处理后,即根据各时刻对应的负荷分解功率值最大的用电设备确定对应时刻的生产工序,对于总功率值为0的时刻其对应的工序为0,得到最终的工序识别准确率为98.83%,其对应工序信息对比如图8所示。






图8 基于TCN负荷分解方法的工序识别结果

从图8可以看出,基于TCN负荷分解方法的工序识别模型的工序识别结果与实际结果几乎保持一致,尤其针对其中短暂的工序状态如采样序号为0~25和175~200的工序状态等都能正确识别,仅在采样序号对应75~100和300~325的工序转换存在个别工序状态识别时未能准确识别,造成实际识别准确率未达到100%。

按照基于TCN的工序识别模型(图6)搭建流程,将TCN算法更换为BiLSTM算法后修改相关参数类型及上下限,进行模型相关参数的寻优,最后获得最优模型参数对应的负荷分解结果如图9所示。



(a) 负荷分解后各用电设备功率值



(b) 负荷分解前后总功率对比

图9 基于BiLSTM的负荷分解结果

从图9可以看出,负荷分解后总功率与实际功率也存在明显差距,负荷分解后总功率曲线与基于TCN算法的负荷分解结果相似,但是在采样序号125~175数据波动较大,且存在两台用电设备即用电设备3和4功率曲线重

叠现象,则在进行相关处理获取该采样序号对应的工序时容易发生误判。

3.2 实验结果与分析

经过负荷分解与结果处理后分别得到基于BiLSTM和TCN负荷分解模型的工序识别结果对比,如图10所示。




图10 各工序识别模型结果对比

对应的工序识别准确率计算结果如表5所示。

表5 识别模型针对测试集识别准确率

算法	准确率/%
TCN	98.83
BiLSTM	97.95

从图10可以看出,两种工序识别模型的识别结果与实际工序值重合率较高,因此两种模型都能取得较高的识别准确率。但是基于BiLSTM负荷分解的识别模型在中间连续工序出现了跳变,在采样序号150~175,识别工序由工序3跳变到工序4,结合基于BiLSTM的负荷分解结果(图9),该模型在对测试集数据进行负荷分解时在采样序号15~175的用电设备3和4功率存在部分重叠,且个别采样序号对应的用电设备4的功率值大于用电设备3的功率值,经过相关处理后该序号对应的工序状态为4,最终造成识别错误结果,虽然在基于TCN负荷分解方法的工序识别模型(图7)的负荷分解结果也存在部分尖峰,但尖峰存在的工序与实际工序值保持一致,因此未对识别结果造成影响,最终识别结果基本和目标工序保持一致,仅有个别的识别错误,针对测试集的识别准确率最高,研究结果表明,基于TCN负荷分解的工序识别模型较能学习各工序功率与总功率之间的关系,并能根据当前及历史总功率数据识别出当前的生产工序。

虽然基于TCN负荷分解方法的工序识别模型能取得较高的工序识别正确率,但是在处理工序转换时仍然存在个别识别错误的状态,如针对采样序号75~100对应的工序2转换为工序3时,结合负荷分解结果发现对应时刻的设备2分解功率值下降缓慢,同时设备3分解功率值上升缓慢,造成在对该点进行工序处理时产生了误判,若能在

负荷分解过程中消除此问题可进一步提高工序识别模型的准确率。

4 结 论

本文通过分别建立基于 TCN、BiLSTM 算法的负荷分解模型,针对负荷分解结果进行相应处理后得出对应的生产工序,并结合青海某钛金属冶炼企业某生产线实际生产能耗及工序信息对模型进行训练和测试,研究结果表明,本文提出的基于非侵入式负荷分解的工序识别模型具有较高的识别准确率,该方案除可以获得较高的工序识别准确率,其他优势如下:1)对输入数据类型要求低,对当前状态的工序识别无需历史工序等信息,仅提供相关功率数据即可,在一定程度上减少了对采集设备的依赖,降低了系统的安装成本与复杂度,有助于能耗管理系统的推广与应用;2)数据预处理过程简单、方便,减少了人工分析数据的处理过程与时间,提高建模效率。

同时该研究结果可结合生产管理系统及能耗管理系统,有助于企业实现如下节能、增效目的:1)结合生产计划及时调整生产安排,避开电费计量高峰期,达到降低企业生产成本、提高生产效益的目的;2)结合能耗管理系统,对生产过程涉及的每道工序能耗进行精准分析,及时发现存在耗能异常的工序并提醒管理人员做出相应处理。

虽然研究结果表明该方法具有较高的识别准确率,但是依然存在优化的空间,针对模型在负荷分解处理时单个用电设备的功率变化较慢,造成发生工序切换时未能及时正确识别工序状态的现象,经分析可能与训练数据有限造成特征不明显或模型关键参数选取不合适有关,同时本文所提模型的关键参数目前采用经验法和遍历法,参数寻优过程花费时间较长,因此在后续的研究工作中计划从以下两个方面进行进一步的探究与完善:1)扩充、完善相关数据集,尽可能多的包含用电设备的功率特征信息,从而使模型可以学习到更多的数据间关系;2)针对模型关键参数采用相关优化算法进行寻优,减少模型训练时间,进一步提高负荷分解模型的性能。

参 考 文 献

- [1] 孙美艳,刘峻,练毅.基于机器视觉和决策树算法的智能面包机面团发酵过程识别研究[J].包装与食品机械,2019,37(5):17-21.
- [2] ZHOU P, GAO B, WANG S, et al. Identification of abnormal conditions for fused magnesium melting process based on deep learning and multisource information fusion [J]. IEEE Transactions on Industrial Electronics, 2022, 69(3): 3017-3026.
- [3] 屈世甲.矿井掘进巷道生产工序自动识别方法的探索[J].煤矿安全,2015,46(4):206-209.
- [4] ESA N F, ABDULLAH M P, HASSAN M Y. RETRACTED: A review disaggregation method in non-intrusive appliance load monitoring [J]. Renewable and Sustainable Energy Reviews, 2016, 66: 163-173.
- [5] ABUBAKAR I, KHALID S N, MUSTAFA M W, et al. Application of load monitoring in appliances' energy management: A review [J]. Renewable & Sustainable Energy Reviews, 2017, 67: 235-245.
- [6] 罗平,樊星驰,章坚民,等.基于电器运行状态和深度学习的非侵入式负荷分解[J].电力系统自动化,2021,45(12):49-56.
- [7] KASELIMI M, DOULAMIS N, VOULODIMOS A, et al. Context aware energy disaggregation using adaptive bidirectional LSTM models [J]. IEEE Transactions on Smart Grid, 2020, 11(4): 3054-3067.
- [8] 汪繁荣,向堃,吴铁洲.基于聚类特征及 seq2seq 深度 CNN 的家电负荷识别方法研究[J/OL].电测与仪表: 1-10[2023-01-06].<http://kns.cnki.net/kcms/detail/23.1202.TH.20201016.1636.014.html>.
- [9] BUDDHAHAI B, WONGSEREE W, RAKKWAM-SUK P. A non-intrusive load monitoring system using multi-label classification approach [J]. Sustainable Cities and Society, 2018, 39: 621-630.
- [10] YAN J, MU L, WANG L, et al. Temporal convolutional networks for the advance prediction of ENSO[J]. Scientific Reports, 2020, 10(1): 8055.
- [11] 韩天翔,史元浩,李孟威,等.融合 CEEMD 和 TCN 的受热面积灰预测研究[J].电子测量与仪器学报,2022,44(10):108-114.
- [12] BIN Y, YANG Y, SHEN F, et al. Describing video with attention-based bidirectional LSTM [J]. IEEE Transactions on Cybernetics, 2019, 49(7): 2631-2641.
- [13] KONG W, DONG Z Y, JIA Y, et al. Short-term residential load forecasting based on lstm recurrent neural network [J]. IEEE Transactions on Smart Grid, 2019, 10(1): 841-851.
- [14] 刘辉,李永康,高放,等.基于小波散射协同 BiLSTM 的输电线路故障诊断[J].国外电子测量技术,2021,40(12):165-172.
- [15] ASLAN M F, UNLERSEN M F, SABANCI K, et al. CNN-based transfer learning-BiLSTM network: A novel approach for COVID-19 infection detection[J]. Appl Soft Comput, 2021, 98: 106912.
- [16] 杨珂,方诚,段黎明.基于深度学习模型融合的铸件缺陷自动检测[J].仪器仪表学报,2021,42(11):150-159.
- [17] 陈岚,文斌,贺南,等.基于融合模型动态权值的气温预测[J].电子测量技术,2022,45(15):68-74.

作者简介

方祖春(通信作者),硕士研究生,主要研究方向为电网控制与智能制造、能耗管理。

E-mail:1639264984@qq.com

汪繁荣,博士,副教授,主要研究方向为电网控制与智能制造、能耗管理、非侵入式负荷分解。

E-mail:77129580@qq.com