

doi:10.3969/j.issn.1672-4348.2020.04.006

基于注意力机制与 ConvBiLSTM 的非侵入式负荷分解

张顺森, 陈铭龙

(福建工程学院 信息科学与工程学院, 福建 福州 350118)

摘要: 针对非侵入式负荷分解准确率低的问题, 提出一种新的非侵入式负荷分解方法。首先, 针对在训练时难以对含有大量数据的电器设备的工作状态做标签问题, 设计了引入轮廓系数和平方误差和共同作为评价指标的 k-means 聚类来确定负荷状态数, 构建了状态码表示所有电器的运行状态。其次, 利用卷积层和双向长短期记忆网络对特征进行提取, 并引入注意力机制选取对分解任务重要性程度高的电器状态码, 然后, 通过全连接层进行分类, 得到各时刻下的状态码, 进而得到各用电设备实际功率。最后利用公开 AMPds2 数据集进行验证, 结果表明所提方法, 具有较高的负荷分解准确率。

关键词: 非侵入式负荷分解; k-means 聚类; 状态码; 注意力机制

中图分类号: TM714

文献标志码: A

文章编号: 1672-4348(2020)04-0336-07

Non-intrusive load decomposition based on attention mechanism and ConvBiLSTM

ZHANG Shunmiao, CHEN Minglong

(School of Information Science and Engineering, Fujian University of Technology, Fuzhou 350118, China)

Abstract: Aiming at the problem that the accuracy of non-intrusive load decomposition still needs to be improved, a non-intrusive load decomposition method was proposed. First, aiming at the difficulty in labelling the operation status of electric equipment with a large amount of data during training, k-means clustering introducing the silhouette coefficient and the sum of squared error as evaluation indicators was designed to determine the number of load status. A status code was constructed to represent the operation state of all electrical appliances. Second, features were extracted by means of ConvBiLSTM (convolution layer and bidirectional long short-term memory network). Attention mechanism was introduced to select the electrical status codes with high importance to the decomposition task, and then these codes were classified through the full connection layer to obtain the status codes at each moment, and then the actual power of each electrical equipment was obtained. Finally, the public AMPds2 data set was used to verify the proposed method. Results show that the proposed method has higher load decomposition accuracy.

Keywords: non-intrusive load decomposition; k-means clustering; status code; attention mechanism

非侵入负荷监测 (non-intrusive load monitoring, NILM) 概念^[1]由 Hart 教授在 1982 年时提出, 即从智能电表采集到的用户总负荷数据中, 分解出各电器设备的能耗使用情况。目前, 国

内外学者在非侵入式负荷监测系统方面进行了大量研究。

在数据采集领域, 非侵入式负荷分解可分为基于高频和基于低频两种方法^[2]。在基于高频

收稿日期: 2020-07-09

基金项目: 福建省科技厅引导性项目 (2017H0001)

第一作者简介: 张顺森 (1974—), 男, 福建永泰人, 副教授, 博士研究生, 研究方向: 电力大数据, 智能计算。

采样方面,文献[3]提出一种对暂态事件检测和提取的算法,通过改进决策树进行分类,具有较高的准确率。文献[4]提出一种基于 V-I 特性的延时反馈非侵入负荷在线快速辨识算法,可高效的识别负荷。文献[5]提出一种 DAPSO 优化算法,将总谐波失真系数作为新的负荷特征进行负荷辨识,准确率得到了一定的提高。文献[6]针对暂态功率波形,提出了采用 DTW 算法计算距离,作为最邻近模板的相似度度量的负荷识别方法。

高频采样的数据所包含信息多、辨识率较高,但是对硬件设备的要求更高、价格更贵,在实际应用中不易推广。相对而言,低频数据的采样对设备要求低,易于推广,因此是学者研究的热点。

在基于低频采样方面,文献[7]提出一种基于超状态隐马尔可夫和 Viterbi 的新型 NILM 算法,但是需要较长历史训练数据进行训练。文献[8]以稳态功率作为负荷特征,按工/休日对负荷进行分析,结合遗传算法实现负荷辨识。文献[9]提出一种基于谱图理论的非侵入式负荷分解方法,具有较高的分解精度。但是若两个用电设备状态转化时的大小相近时,会造成一定误差。文献[10]提出了一种序列到点(sequence-to-point, seq2point)的深度学习方,用于非侵入式负荷监测负荷分解,取得了较高的准确率。文献[11]提出了一种基于边缘嵌入深度学习的非侵入式负荷监测方法,在大功率电器上具有较高的准确性。

虽然上述文献提出的方法在特定的应用场景下都取得了一些研究成果,但其负荷监测的分解准确率上还有待提高。本研究引入平方误差和和轮廓系数对 k-means 算法的 K 值进行判定,确定负荷状态数,将每个用电器每个时刻下所处的工作状态组合成一个状态码,结合深度学习提出一种基于注意力机制与 ConvBiLSTM 的非侵入式负荷分解,该方法利用卷积层和 BiLSTM 提取有效特征,并引入注意力机制选取重要负荷特征信息,利用公开数据集进行训练和测试验证算法的准确率。

1 电器设备状态

1.1 提取设备状态

经典 k-means 算法需要预先指定 K 值,不同的聚类评价指标对于数据集的敏感性不同,且平

方误差和(sum of squared error, SSE)在实际应用中,可能会出现多个拐点。本研究对其进行改进,引入 SSE 和轮廓系数共同作为评价指标来确定 K 值,通过迭代实现负荷聚类数,其中 SSE 在其拐点处以及轮廓系数在峰值处所对应的 K 值为较佳聚类值,其具体步骤如下:

(1)对获取的各用电设备数据进行中值滤波处理。

(2)给定 SSE 初始迭代数为 K_0 为 1,给定轮廓系数初始迭代数 k_0 为 2,给定步骤(1)预处理过的电器设备的有功功率 $P = [P_1, P_2, P_3, \dots, P_n]$ 。

(3)对功率数据 P 进行聚类,计算平方误差和值,记为 SS_{K_0} 。

(4)对功率数据 P 进行聚类,计算轮廓系数值,记为 S_{k_0} 。

(5)令 K 为迭代数, $K_0 = K_0 + 1$,转(3) 计算平方误差和值,记 SS_{K_0+1} ,直至 $K < K_0$,迭代结束,完成聚类。

(6)令 K 为迭代数, $k_0 = k_0 + 1$,转(4) 计算轮廓系数,记 S_{k_0+1} ,直至 $K < k_0$,迭代结束,完成聚类。

(7)绘制 SSE 曲线和轮廓系数曲线图。

(8)判断出最佳聚类值。




图1 冰箱 SSE 和轮廓系数曲线图

Fig.1 Curves of refrigerator SSE and contour coefficient

从图1可见,冰箱在聚类数 $K=2$ 处有一个明显拐点,在 $K=3$ 处近似于直线,因此判断其是拐点。轮廓系数在聚类数 $K=2$ 处时,处于局部峰值, $K=3$ 时,虽然处于峰值,轮廓系数最大,但是综合两条曲线,判断 $K=2$ 时为冰箱最佳聚类数。各用电设备所得聚类数和每个簇下的有功功率均值如表1所示。

表 1 基于 k-means 有功功率索引表

Tab.1 Index table of active power based on k-means

设备	聚类数	有功功率/W			
		状态 0	状态 1	状态 2	状态 3
洗碗机	3	0	767	143	—
冰箱	2	1	135	—	—
热水器	2	35	1 746	—	—
洗衣机	4	0	504	172	105
照明灯	2	5	344	—	—
干衣机	3	0	4 680	255	—
暖通空调	2	110	372	—	—

1.2 负荷状态码的构建

通过聚类判断出各用电设备的工作状态数 K , 将得到的每个簇下的有功功率均值作为与之相关联负荷状态的实际值, 并对各个用电器的的工作状态做标签, 通过构建状态码, 将每个用电器每个时刻下所处的工作状态组合一个状态码, 假设共有 M 个设备, 则状态码 N 构建如式(1)所示:

$$N = n_t^M * 10^{M-1} + n_t^{M-1} * 10^{M-2} + \dots + n_t^1 * 10^0$$

(1)

表 2 用电设备工作情况

Tab.2 Working conditions of electrical equipment

组合	洗碗机	冰箱	状态码
1	0	0	0
2	0	1	1
3	1	0	10
4	1	1	11
5	2	0	20
6	2	1	21

表 2 表示洗碗机和冰箱的编码过程, 假设洗碗机有 3 个工作模式, 冰箱有 2 个工作模式, 根据洗碗机和冰箱在 t 时刻的工作模式, 通过式(1)计算出该时刻状态码, 状态码表示 M 个用电器所处时刻的总功率对应的运行状态, 非侵入式负荷监测通过总功率预测出对应的状态码, 进而得到各电器设备当前时刻的运行状态, 从而预测到各电器设备的实际功率值, 最后实现了非侵入式的负荷分解。

2 基于注意力机制与 ConvBiLSTM 算法模型

2.1 卷积层

卷积神经网络(convolutional neural networks, CNN)^[12]是经典的深度学习算法之一, 其中卷积层的作用是对输入的信息进行特征提取, 即通过卷积核在非侵入式负荷监测的时间序列上进行滑动并进行卷积运算得到输出特征, 同时也减少了参数量, 如式(2)所示:

$$x_j^1 = \sigma_1 \left(\sum_{i \in M_j} x_i^{l-1} w_{ij}^l + b \right)$$

(2)

式中, σ_1 表示激活函数, 选用 ReLU 函数, M_j 表示上一层的输入集合, x_i^{l-1} 表示上层输入, w_{ij}^l 表示权重, b 表示偏置向量。

2.2 长短期记忆网络

长短期记忆网络(long short term memory network, LSTM)^[13]是针对 RNN 不能够很好的处理长期依赖问题提出的一种改进。LSTM 引入了 3 个门控制器, 即遗忘门、输入门和输出门, 如图 2 所示。




图 2 LSTM 单元拓扑图

Fig.2 Topology of LSTM unit

遗忘门 f_t 根据上一时刻的短期记忆 h_{t-1} 和当前时刻 x_t 做为输入, 通过 Sigmoid 激活函数决定保留多少上一时刻的信息, 如式(3)所示:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)$$

(3)

输入门 i_t 的工作原理是通过 Sigmoid 激活函数决定是否将当前的信息更新到 LSTM 当时时刻的细胞状态, 如式(4)所示:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$$

(4)

当前候选时刻单元记忆值 \tilde{c}_t 是由 x_t 和 h_{t-1} 作为输入, 经 tanh 激活函数使值缩放到 -1 和 1 之间, 如式(5)所示:

$$\tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (5)$$

当前时刻记忆单元状态值 C_t 需要通过遗忘门和输出门分别调节上一时刻细胞状态和候选细胞,如式(6)所示:

$$c_t = f_t * c_{t-1} + i_t * \tilde{c}_t \quad (6)$$

输出门 O_t 通过 Sigmoid 激活函数,来控制当前时刻的单元状态的输出,如式(7)所示:

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (7)$$

LSTM 最终输出如式(8)所示:

$$h_t = o_t * \tanh(c_t) \quad (8)$$

在公式(3)-(8)中, W_f 、 W_i 、 W_c 、 W_o 分别为遗忘门、输入门、tanh 层、输出门的权重向量, b_f 、 b_i 、 b_c 、 b_o 分别为其对应的偏移量, σ 为 Sigmoid 激活函数, h_t 可以看作是学习到的电器状态特征。

2.3 BiLSTM 网络

SCHUSTER、PALIWAL 等^[14]在 1997 年时提出了双向循环神经网络, BiLSTM 可以看作是前向的 LSTM 与后向的 LSTM 结合而成, 两个单向的 LSTM 同时处理数据, 可以得到更全面的特征信息, 如公式(9)。

$$\vec{h}_t = \text{LSTM}(x_t, \vec{h}_{t-1}) \quad (9)$$

$$\overleftarrow{h}_t = \text{LSTM}(x_t, \overleftarrow{h}_{t-1}) \quad (10)$$

$$h_t = w_t \vec{h}_t + v_t \overleftarrow{h}_t + b_t \quad (11)$$

其中, \vec{h}_t 、 \overleftarrow{h}_t 分别为前向 LSTM 和后向 LSTM 的隐藏层状态, w_t 和 v_t 分别为 \vec{h}_t 和 \overleftarrow{h}_t 的权重向量, b_t 为该时刻隐藏状态的偏移值。

2.4 注意力机制

对于非侵入式负荷分解任务来讲, 每个时间维度, 各电器状态贡献不同。本研究引入注意力保护机制层, 选取分解任务中重要性程度高的电器状态。注意力保护机制的思想是对输入的向量计算其对应的权重, 突出重要性程度高的输入向量, 实现注意力权重分配。如式(12)-(15)为其计算公式。具体步骤如下:

第一步, 将上一层 BiLSTM 的输出量作为输入, 并进行维度变换。

$$L = \text{Permute}((2, 1))(h_t) \quad (12)$$

其中, h_t 表示 BiLSTM 的输出量, L 表示 h_t 维度置换后的结果。

第二步, 经全连接层并进行维度变换, 计算出对应权重系数。

$$a = \text{softmax}(WL + b) \quad (13)$$

$$a_probs = \text{Permute}((2, 1))(a) \quad (14)$$

其中, W 表示全连接层的权值矩阵, b 表示偏置向量, a_probs 为各个功率所对应的权重。

第三步, 将权重系数乘以上一层输入, 对原有模型进行改进。

$$\text{output} = h_t * a_probs \quad (15)$$

其中, output 为注意力计算后的输出向量。

2.5 训练模型

基于注意力机制与 ConvBiLSTM 的训练模型如图 3 所示, 训练采用 Adam 优化器, 学习率设置为 0.01, 损失函数为交叉熵损失函数, 引入 Dropout 技术来减小过拟合, 比率设置为 0.4。其中 X_1, X_2, \dots, X_n 为经数据预处理后, 各用电设备功率的叠加和, 具体步骤如下:

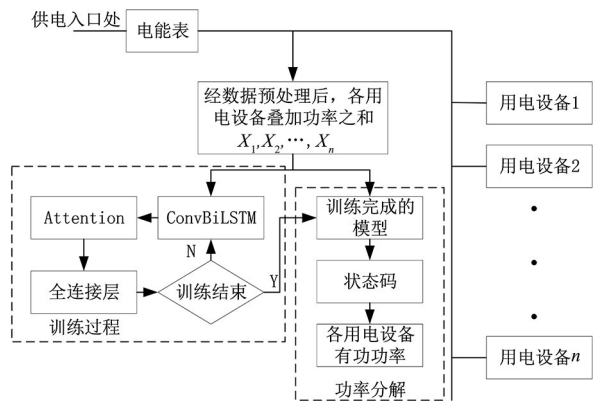


图3 基于注意力机制与 ConvBiLSTM 的非侵入式负荷分解

Fig.3 Non-intrusive load decomposition based on attention mechanism and ConvBiLSTM

首先, 对获取的各电器设备电力数据进行预处理, 采用中值滤波, 滤除异常数据, 采用 k-means 对预处理后的数据进行聚类划分, 并构建状态码, 其中总功率为选取单个用电设备的功率叠加和。

其次, 将样本数据进行归一化处理, 选取半年用电数据作为训练样本, 对公式(1)组成的状态码转化成独热码输入到构建的模型进行训练, 首先输入到 ConvBiLSTM 层, 其中卷积层主要用于挖掘总功率的有效负荷特征, BiLSTM 可以通过前向 LSTM 和后向 LSTM 同时处理上层卷积层提取的有效特征。

接着, 将上一层 ConvBiLSTM 的输出向量, 经

Attention 机制层对权重进行优化,突出重要负荷特征信息,从而更好的训练模型。

然后,输入为上一层 Attention 层的输出向量,经过双层全连接层进行计算,最终得到分类的预测状态码,通过预测出的状态码,通过表 1 索引出各用电设备的有功功率。其中最后一层的全连层激活函数采用 softmax 函数。

最后,选取一周的数据做为测试集输入至训练好的模型,得到各电器设备所处的工作模式,分解出各用电设备的有功功率,通过评价指标,对负荷的分解性能进行评估。

3 实验

3.1 数据集介绍

研究采用 AMPds2^[15] 公开数据集对本文的方法进行训练和验证, AMPds 公开数据集由 Makonin 团队记录创建, AMPds2 对版本 1 存在的数据完整性问题进行完善,记录了加拿大一居民用户家中的 21 个用电器 2 a 的能耗,其中电力数据包含了各个电器的有功功率,无功功率,电流等 11 个用电参数,采样频率为每间隔 1 min 采样一次,选择功率作为负荷特征。实验采用的是 Windows 7 64 位操作系统的笔记本计算机,主频为 2.60 GHZ, 8 G 内存,开发环境为 Keras,后端为 tensorflow,结合 python3 试验平台。

3.2 评价指标

为了评估所提方法的分解性能,将分解准确率(pacc)和平均绝对误差(MAE)作为本研究的评价指标^[10,16]。当分解准确率(pacc)越高,平均绝对误差(MAE)越低,则说明分解性能越好。其中 pacc 的数学表达式如式(16)所示,表示各个电器设备有功功率的实际值与分解值之间的差异。

$$pacc = 1 - \frac{\sum_{t \in T} |P(t) - p(t)|}{2 \sum_{t \in T} P(t)} \quad (16)$$

MAE 指的是所选测试集在总时间 T 内每个时刻的有功功率的绝对误差,其表达式如式(17):

$$MAE = \frac{1}{T} \sum_{t=1}^T |(P(t) - p(t))| \quad (17)$$

其中, P(t) 表示某一电器在 t 时刻消耗的实际功率, p(t) 表示该电器的预估值。

3.3 实验分析与结论

从 AMPds2 公开数据集中选择洗碗机

(DWE)、干衣机(CDE)、冰箱(FGE)、热水器(HPE)、洗衣机(CWE)、灯(BME)等 6 种电器进行 20 次实验取均值,选取半年的数据做为训练集,选取一周的数据作为测试集。总功率为 6 个用电器各个时刻功率之和,将本方法与 NILMTK^[17] 工具包中的 DAE^[18]、seq2seq^[10]、seq2point^[10] 算法做比较。功率分解准确率、MAE 具体见表 3-6。

表 3 场景一的功率分解准确率
Tab.3 Power decomposition accuracy of Scenario 1

电器	不同算法的功率分解准确率/%				
	DAE	seq2seq	seq2point	本文方法	本文方法 (加无功功率)
洗碗机	46.9	93.5	96.5	97.6	98.6
干衣机	88.8	94.2	98.1	98.8	99.0
冰箱	82.4	89.7	94.0	94.1	94.5
热水器	93.3	97.3	98.5	96.4	96.5
洗衣机	40.5	61.7	77.2	78.3	85.7
灯	88.1	92.5	91.7	97.4	97.8

表 4 场景一的平均绝对误差
Tab.4 Mean absolute error of Scenario 1

电器	不同算法的误差平均绝对误差				
	DAE	seq2seq	seq2point	本文方法	本文方法 (加无功功率)
洗碗机	4.86	0.58	0.30	0.21	0.11
干衣机	11.00	5.67	1.81	1.13	0.92
冰箱	17.80	10.30	5.98	5.83	5.39
热水器	8.92	3.50	1.87	4.64	4.59
洗衣机	4.31	2.77	1.64	1.41	0.92
灯	7.32	4.59	5.09	1.58	1.32

场景一:使用 6 个用电设备。
从表 3 可以出,以上算法对干衣机、热水器、照明灯的分解准确率较高,因为干衣机、热水器功率高,易于区分;照明灯工作状态简单且功率较为稳定;洗碗机也属于高功率用电设备,除 DAE 算法外,剩余算法对洗碗机的分解准确率均较高;冰箱属于低功率设备,容易与其他用电设备发生特征重叠现象,因而分解准确率较低;洗衣机功率分

解准确率最低,主要是因为洗衣机的工作状态较多,且洗衣机存在与洗碗机和冰箱两个用电设备相近的低功率,因此对洗衣机的分解功率造成一定影响。热水器的功率分解准确率较 seq2seq 和 seq2point 低的原因是,热水器的功率代表值对功率分解准确率造成一定影响,在剩余用电设备上,本研究的功率分解性能较其他算法高。

从表 4 可以看出,除热水器外,每种设备的平均绝对误差均为最低,所提的方法具有一定的优势,此外,本研究在有功功率的基础上,增加无功功率,其分解性能得到了一定的提高。

场景二:本文在场景一的基础上,继续增加暖通空调设备(FRE),构建更为复杂的用电环境。

表 5 场景二的功率分解准确率

Tab.5 Power decomposition accuracy of Scenario 2

电器	不同算法的功率分解准确率/%				
	DAE	seq2seq	seq2point	本文方法	本文方法 (加无功功率)
洗碗机	29.7	93.6	96.6	97.8	98.4
干衣机	89.8	93.8	97.9	98.9	99.0
冰箱	82.9	88.6	95.3	93.9	94.5
热水器	92.5	97.5	98.2	96.5	96.5
洗衣机	39.4	58.9	78.4	78.8	85.5
灯	88.0	92.5	91.1	97.0	97.5
暖通空调	98.2	99.1	97.4	98.0	98.0

从表 5、表 6 可以看出,在增加暖通空调之后,对于冰箱和热水器,本方法的分解准确率略低于 seq2point 算法,在剩余设备的分解准确率上,

本方法优于 seq2point 算法,且本方法的分解性能仍然优于剩余算法。从 2 个场景可以发现,本研究采取无功功率和有功功率特征的方法相对于只使用有功功率的方法,分解效果较好,说明利用有功功率和无功功率特征,提出的基于注意力机制与 ConvBiLSTM 的非侵入式负荷分解可以实现提高非侵入式负荷分解准确率。

表 6 场景二的平均绝对误差

Tab.6 Mean absolute error of Scenario 2

电器	不同算法的误差平均绝对误差				
	DAE	seq2seq	seq2point	本文方法	本文方法 (加无功功率)
洗碗机	6.44	0.57	0.29	0.19	0.13
干衣机	10.00	6.02	2.02	1.03	0.91
冰箱	17.20	11.40	4.69	6.03	5.38
热水器	9.90	3.29	2.30	4.59	4.59
洗衣机	4.39	2.97	1.55	1.38	0.94
灯	7.43	4.59	5.46	1.83	1.51
暖通空调	3.53	1.88	5.42	4.22	4.22

4 结语

针对非侵入式负荷分解任务,提出一种基于注意力机制与 ConvBiLSTM 的非侵入式负荷分解方法,该方法在利用功率特征时,随着负荷的增加仍能保证对非侵入式负荷分解具有较高准确率。在模型训练过程中,充分挖掘负荷特征,可以提高非侵入式负荷分解准确率,因此在下一步研究中,将考虑归纳各负荷特征的特点,提高分解准确率。

参考文献:

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

[2] 阿蓉. 场景自适应的非侵入式负荷识别算法研究[D]. 武汉: 华中科技大学, 2018.

[3] 曹敏, 魏龄, 邹京希, 等. 基于暂态过程的非侵入式负荷监测研究[J]. 水电能源科学, 2018, 36(8): 177–180.

[4] 韩笑, 邓春宇, 张玉天, 等. 基于高频数据 V-I 特性的延时反馈负荷在线快速辨识算法[J]. 电力系统自动化, 2019, 43(9): 108–116.

[5] 孙毅, 张璐, 赵洪磊, 等. 基于动态自适应粒子群算法的非侵入式家居负荷分解方法[J]. 电网技术, 2018, 42(6): 1819–1826.

[6] LIU B, LUAN W, YU Y. Dynamic time warping based non-intrusive load transient identification[J]. Applied Energy, 2017, 195: 634–645.

[7] MAKONIN S, POPOWICH F, BAJIC I, et al. Exploiting HMM sparsity to perform online real-time nonintrusive load monitoring[J]. IEEE Transactions on Smart Grid, 2016, 7(6): 2575–2585.

[8] 徐青山, 姜藕蝶, 郑爱霞, 等. 基于近邻传播聚类和遗传优化的非侵入式负荷分解方法[J]. 电工技术学报, 2018,

33(16): 3868–3878.

[9] 彭显刚, 郑凯, 林哲昊, 等. 基于谱图理论的居民用户非侵入式负荷分解[J]. 电网技术, 2018, 42(8): 2674–2680.

[10] ZHANG C, ZHONG M, WANG Z, et al. Sequence-to-point learning with neural networks for non-intrusive load monitoring. [C]//2018 Thirty-Second AAAI Conference on Artificial Intelligence, 2018.

[11] 刘耀先, 孙毅, 李彬, 等. 基于边缘嵌入深度学习的非侵入式负荷分解方法[J]. 电网技术, 2019, 43(12): 4329–4337.

[12] 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.

[13] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735–1780.

[14] SCHUSTER M, PALIWAL K. Bidirectional recurrent neural networks[J]. IEEE Transactions on Signal Processing, 1997, 45(11): 2673–2681.

[15] MAKONIN S, POPOWICH F, BARTRAM L, et al. AMPds: a public dataset for load disaggregation and eco-feedback research[C]//2013 IEEE Electrical Power & Energy Conference. Halifax, NS, Canada: IEEE, 2013: 1–6.

[16] 任文龙, 许刚. 基于深度序列翻译模型的非侵入式负荷分解方法[J]. 电网技术, 2020, 44(1): 27–37.

[17] BATRA N, KELLY J, PARSON O, et al. NILMTK: an open source toolkit for non-intrusive load monitoring[EB/OL]. 2014: arXiv:1404.3878[stat.AP]. <https://arxiv.org/abs/1404.3878>.

[18] KELLY J, KNOTTENBELT W. Neural NILM: deep neural networks applied to energy disaggregation[C]//Proceedings of the 2nd ACM International Conference on Embedded Systems for Energy-Efficient Built Environments-BuildSys 15. New York: ACM Press, 2015: 55–64.

(责任编辑: 方素华)

(上接第 318 页)

和 NSC 3 组浆体的总孔隙率均较低,有害孔和多
害孔数量很少,影响镍渣聚合物砂浆强度的主要
因素是水化聚合物数量的多少; H_2O/Na_2O 摩尔
比值为 27 时,浆体内总孔隙率上升,特别是有害
孔和多害孔的数量明显增多,这是导致其抗压强
度迅速下降的主要原因。

参考文献:

[1] SINGH J, SINGH S. Geopolymerization of solid waste of non-ferrous metallurgy-A review[J]. Journal of Environmental Management, 2019, 251: 109571.

[2] 李小明, 沈苗, 王翀, 等. 镍渣资源化利用现状及发展趋势分析[J]. 材料导报, 2017, 31(5): 100–105.

[3] ELSHKAKI A, RECK B, GRAEDEL T. Anthropogenic nickel supply, demand, and associated energy and water use[J]. Resources Conservation and Recycling, 2017, 125: 300–307.

[4] 王强, 杨峻, 王登权. 碱激发电炉镍渣的反应产物性能[J]. 清华大学学报(自然科学版), 2018, 58(6): 593–597, 602.

[5] ZHANG Z, ZHU Y, YANG T, et al. Conversion of local industrial wastes into greener cement through geopolymer technology: A case study of high-magnesium nickel slag[J]. Cleaner Production, 2017, 141: 463–471.

[6] 张云升. 高性能地质聚合物混凝土结构形成机理及其性能研究[D]. 南京: 东南大学, 2003.

[7] HEAN C, KAMARUDIN H, MUSTAFA AL BAKRI A, et al. Study on solids-to-liquid and alkaline activator ratios on kaolin-based geopolymers[J]. Constr Build Mater, 2012, 35: 912–922.

[8] GAO K, LIN K, WANG D, et al. Effects of SiO_2/Na_2O molar ratio on mechanical properties and the microstructure of nano- SiO_2 metakaolin-based geopolymers[J]. Construction and Building Materials, 2014, 53: 503–510.

[9] 吴中伟. 绿色高性能混凝土: 混凝土的发展方向[J]. 混凝土与水泥制品, 1998(1): 3–5.

[10] RODRIGUEZ E, BERMAL S, PROVIS J, et al. Effect of nanosilica-based activators on the performance of an alkali-activated fly ash binder[J]. Cem Concr Comp, 2013, 35(1): 1–11.

(责任编辑: 陈 雯)