2023 年 11 月

Journal of Terahertz Science and Electronic Information Technology

文章编号: 2095-4980(2023)11-1381-06

中图分类号: TP393

一种基于EDDL的非侵入式负荷检测模型

李 晨,夏立典,章 超,叶杨锋

(浙江华云信息科技有限公司,浙江 杭州 310030)

摘 要:针对目前非侵入式负荷检测时存在检测精确度低的问题,提出一种基于事件驱动-深 度学习(EDDL)的负荷检测模型。通过零交叉检测电流数据,基于事件驱动机制从大量数据中发现 关键事件;将包含关键事件的电流序列转换至图像空间,并代入基于深度学习的负荷检测模型, 从而实现端对端的非侵入式负荷检测。实验结果表明,与多分类支持向量机(MSVM)、前馈神经网 络(FNN)、卷积神经网络(CNN)和长短时记忆网络(LSTM)模型相比,所提EDDL模型综合性能更 优,检测准确率和精确度分别为94.67%和91.76%。仿真结果验证了所提模型可基于事件驱动机 制挖掘电流数据,并基于深度学习模型有效提取电流数据特征,从而实现高精确度的非侵入式电 力负荷检测。该模型对非侵入式电力负荷检测研究具有一定借鉴作用。

关键词: 电力系统; 非侵入式; 负荷检测; 深度学习; 事件驱动

doi: 10.11805/TKYDA2023184

A non-intrusive load detection model based on EDDL

文献标志码:A

LI Chen, XIA Lidian, ZHANG Chao, YE Yangfeng (Zhejiang Huayun Information Technology Co., LTD., Hangzhou Zhejiang 310030, China)

Abstract: A load detection model based on Event Driven and Deep Learning(EDDL) is proposed to address the issue of low detection accuracy in current non-invasive load detection. The current data is detected through zero crossing, and the key events are discovered from a large amount of data based on event driven mechanisms. The end-to-end non-invasive load detection is achieved by converting the current sequence containing key events into image space and incorporating it into a deep learning based load detection model. The experimental results show that compared with the Multi-class Support Vector Machine(MSVM), Feedforward Neural Network(FNN), Convolution Neural Network(CNN), and Long Short Term Memory (LSTM) models, the proposed EDDL model has better overall performance, with detection accuracy and accuracy of 94.67% and 91.76%, respectively. The simulation results verify that the proposed model can mine current data based on event driven mechanisms and effectively extract current data features based on deep learning models, thus achieving high-precision non-invasive power load detection.

Keywords: power system; non-intrusive; load detection; deep learning; event driven

由于智能电力需求响应^[1-2]的深入发展,以及日益增强的节能意识,电力系统的负荷监测已成为减少电网损 耗和减少谷峰差的有力途径。为此,可基于物联网、通信、计算机等技术^[3-5]对电力系统中电流、电压等数据进 行收集与分析,有助于电力公司了解电力用户用电行为模式,并根据消费者的需求调整电能的产生、传输和存 储,进而为电力消费者提供更高质量、更具成本效益和个性化的服务。

通常,负荷检测^[6]可分为侵入式和非侵入式两种方式。侵入式依赖于安装在每个电力设备上的多个专用传感器获取电力消耗信息。识别精确度取决于直接测量,但在实践中建立传感器分布式测量网络仍具有挑战性。与 侵入式负荷检测技术不同,非侵入式负荷检测技术(Non-Intrusive Load Monitoring, NILM)只需在主电力服务入口 进行测量,即可有效实现电力负荷检测。同时该方式安装和维护成本更低,在隐私和便利性方面更易为消费者 接受,且无需更换现有设备设施。

收稿日期: 2023-06-30; 修回日期: 2023-07-21

鉴于NILM的优势,近年来大量学者对其进行了研究。其中一种主流方法是使用机器学习模型,如文献[7]采 用数据挖掘对电力负荷历史数据进行聚类分析以及异常检测,但该方法对多负载环境缺乏普遍适用性。随着深 度学习技术的发展,有学者将其引入负荷检测或识别领域。文献[8]提出了基于极限学习机的非侵入式电力负荷 识别算法,可以有效地处理多个家用电器的同时开/关事件;文献[9]提出了一种基于长短时记忆网络(LSTM)的电 力负荷检测方法。但大部分检测方法的最高精确度结果不是从最优特征提取器和最优分类器中得出,且部分模 型特征提取过程中无法从大量数据中突出关键信息,导致大量信息丢失,检测精确度有限。

为改善上述问题,本文提出了一种基于事件驱动和深度学习的非侵入式负荷检测模型。该模型可基于事件 驱动机制,从大量电力数据中提取关键事件,并利用深度学习模型强大的拟合能力学习数据特征,从而有效实 现高精确度负荷检测。

1 事件驱动机制

考虑到有功和无功功率的计算复杂性,本文选择电流波形作为描述家用电器运行变化的特征参数。由于电力电子设备的存在,居民用电一般不是纯电阻负载,不同电器的相位滞后角也不同。因此,通过零交叉检测电流波形的单个周期,收集电流变化并估计设备的启动-停止时间和状态变化,从大量数据中发现关键事件。

获得单周期电流波形后,可通过使用动态时间扭曲(Dynamic Time Warping, DTW)^[10]算法区分每个周期之间 电流序列的变化。DTW算法是一种强大的相似性测量工具,可以找出2个电流序列之间的最短距离,并通过时 间轴进行匹配。与传统欧几里德距离相比,DTW距离减少了匹配时间,并克服了需要恒定长度电流序列的 限制。

假设在一个正弦周期中具有不同长度的2个电流序列 $I_p = \{i_{p_1}, i_{p_2}, \dots, i_{p_m}\}$ 和 $I_q = \{i_{q_1}, i_{q_2}, \dots, i_{q_n}\}$,其中 i_{p_m} 表示电流 波形的第p个周期中的第m个点; i_m 表示电流波形第q个周期中第n个点。DTW 距离可通过以下递归计算:

$$D(i_{pm}, i_{qn}) = d(i_{pm}, i_{qn}) + \min \begin{cases} D(I_p, \gamma(i_{qn})) \\ D(\gamma(i_{pm}), I_q) \\ D(\gamma(i_{pm}), \gamma(i_{qn})) \end{cases}$$
(1)
$$d(i_{pm}, i_{qn}) = \|i_{pm} - i_{qn}\|_{2}$$
(2)

式中: $d(i_{pm}, i_{qn})$ 为2个序列之间元素的距离;运算符 $\gamma(\cdot)$ 为除指定采样点之外的剩余采样点。以第一个采样点为例, $\gamma(\cdot)$ 可以描述如下:

$$\gamma(i_{p1}) = \{i_{p2}, i_{p3}, \dots, i_{pm}\}$$

$$\gamma(i_{q1}) = \{i_{q2}, i_{q3}, \dots, i_{qn}\}$$
(3)

一般来说,序列之间距离越短,2个当前序列之间的相似性就越大。因此,需要选取适当的DTW距离阈值 $\lambda_{\rm T}$ 来区分电流波形是否突变,然后判断负荷的启动-停止或状态变化,从而反映关键事件是否发生。

DTW距离比例为:

$$\lambda_{\rm D}(p) = \frac{D(I_p, I_{p-1})}{D(I_{p-1}, I_{p-2})} \tag{4}$$

一般情况下,将距离阈值 $\lambda_{T} = \lambda_{D}(p)$ 进行比较,当 $\lambda_{D}(p) > \lambda_{T}$ 时,表明2个电流波形突变,并可确定包含事件 信息的电流序列。

2 非侵入式电力负荷检测模型

考虑到高采样频率的家用电力数据随机性强,噪声干扰严重,提出了一种基于事件驱动和深度学习(EDDL) 的非侵入式电力负荷检测模型,可提高多个负载同时运行时的识别精确度。该模型首先将收集的高采样频率电 流数据形成事件序列,然后将序列转换为图像,并代入深度学习模型进行特征提取与分类,从而实现端对端的 非侵入式电力负荷检测。

2.1 数据预处理

在事件驱动过程之后,执行数据预处理操作。将长度为L²的包含事件信息的电流序列转换为L×L大小的灰度图像,以图像的形式作为深度学习模型的输入。由于随机窗口位置和不适当的窗口长度会导致特征丢失,严重时可能会生成无法显示特征的混沌灰度图像。因此结合滑动窗口算法和电流波形的预处理,设计了一种数据预处理方法。

假定从任一滑动窗口提取的目标电流序列记为 $i = \{i(1), i(2), \dots, i(m)\}, 1 \le m \le L \times L, 其中第 k 个电流 i(k) 过零点。$ 利用过零点检测确定该过零点满足 <math>i(k-1) < 0 和 i(k) > 0, 然后将目标电流转换为序列 i'(n), 具体定义如下:

$$i'(n) = \begin{cases} i(n+k-1) & 1 \le n \le L \times L - k + 1\\ 0 & L \times L - k + 1 < n \le L \times L \end{cases}$$
(5)

根据式(5),可以将任意包含事件信息的电流序列转换为二维格式图像数据,有助于提高分类的准确性。

2.2 网络结构

图1为提出的EDDL 非侵入式电力负荷检测模型结构图。模型的输入为电流数据的二维格式图像数据,大小为128×128。归一化之后,有3个卷积块,每个卷积块进行2D卷积层、批量归一化、激活函数和最大池化操作,将提取的特征同时输入LSTM,充分结合上下文信息进行特征学习。为提高模型学习性能,在模型中添加注意力融合机制提高模型对分类特征的敏感性。因此,在LSTM 后进行注意力融合,之后经过 DropOut、全连接和Softmax 操作,完成非侵入式电力负荷检测过程。



Fig.1 Structure diagram of non-invasive power load detection model based on EDDL 图1 基于 EDDL 非侵入式电力负荷检测模型结构图

非侵入式电力负荷检测中卷积层主要利用一定大小的卷积滤波器提取电流数据特征,因此卷积层是深度神 经网络的基本算子。在前一层卷积核处理之后,可基于激活函数获得卷积层的新层特征图:

$$Y_{j}^{l} = f\left(\sum_{s \in M_{N^{-1}}(u,v) \in K^{(0)}} \sum_{w_{js(u,v)}} x_{s}^{(l-1)}(c+u,r+v) + b_{j}^{(l)}\right)$$
(6)

式中: $K^{(i)}$ 为卷积核; $u \approx v \rightarrow 0$ 别表示卷积核的宽度和高度; $l \rightarrow 1$ 当前层数; $b_j^{(i)}$ 为卷积层中第 $j \wedge 1$ 特征图的神经元 偏置; $s \in M_{j(l-1)}$ 为先前特征映射的集合; $w_{js(u,v)}^s$ 为特征图的权重; x_s^{l-1} 为输入特征; $c \rightarrow 1$ 前一层的通道数; $r \rightarrow 1$ 当前 层的卷积核个数。

卷积层之后的最大池化层主要进行下采样,使非侵入式电力负荷检测具备抗过拟合和保持特征不变能力。 最大池化层描述如下:

$$Y_j^l = d_w \left(Y_j^{l-1} \right) \tag{7}$$

式中 $d_{w}(\cdot)$ 为下采样函数。

与只有一个隐含层的递归神经网络(Recurrent Neural Network, RNN)相比, LSTM考虑了隐藏在长期状态中的时间相关性。非侵入式电力负荷检测模型中, LSTM定义为:

$$h_{t} = \tanh\left(W_{ih}x_{t} + b_{ih} + W_{hh}h_{t-1} + b_{hh}\right)$$
(8)

$$i_{t} = \sigma \left(W_{ii} x_{t} + b_{ii} + W_{hi} h_{t-1} + b_{hi} \right)$$
(9)

$$f_{t} = \sigma \left(W_{if} x_{t} + b_{if} + W_{hf} h_{t-1} + b_{hf} \right)$$
(10)

$$g_{t} = \tanh\left(W_{io}x_{t} + b_{io} + W_{ho}h_{t-1} + b_{ho}\right)$$
(11)

$$o_{t} = \sigma \left(W_{io} x_{t} + b_{io} + W_{ho} h_{t-1} + b_{ho} \right)$$
(12)

$$c_{t} = f_{t}^{*} c_{t-1} + i_{t}^{*} g_{t} \tag{13}$$

$$h_t = o_t^* \tanh(c_t) \tag{14}$$

式中: i_t 为输入门; f_t 为遗忘门; g_t 为单元门; o_t 为输出门; $h_t \in \mathbb{R}^h$ 为时间 t时的隐藏状态; $x_t \in \mathbb{R}^d$ 为输入; $c_t \in \mathbb{R}^h$ 为细胞态; $W_{ii} \in W_{ig} \in W_{io}$ 为各门输入向量上的可训练权重; $W_{hi} \in W_{hg} \in W_{ho}$ 为各门隐藏状态的可训练权重; b为可训练的相应偏差; *为哈达玛积; $\sigma(\cdot)$ 为 sigmoid 激活函数。

非侵入式电力负荷检测模型利用全连接层增强非线性映射能力,并限制网络的大小。全连接层的操作可描述为:

$$O_{j}^{l} = f\left(\sum_{i=1}^{n} x_{i}^{(l-1)} w_{ji}^{(l)} + b_{j}^{(l)}\right)$$
(15)

式中: n为前一层的神经元数量; l为当前层数; w_{ji}^{0} 为当前层j和最后一层i中神经元之间的权重; b_{j}^{0} 为神经元偏置; f为激活函数。

3 仿真与分析

对所提出的基于EDDL的非侵入式电力负荷检测模型进行测试和验证。

3.1 数据集

使用开源数据集 UK-DALE 中洗衣机、电视、水壶、冰箱、微波炉、灯和计算机 7 种不同类型的常见住宅负 荷数据(电流值)作为数据集。UK-DALE 数据集中整个房间的采样率为 16 kHz,单个电器的采样率为 1/6 Hz。最终,将数据集按 8:2 分为训练集和测试集。

为稳定监督学习模型的学习过程,原始输入变量代入所提网络模型时需做归一化处理,所有家用电器数据 通过最小-最大标准化缩放到(0,1)的范围之间。

3.2 试验设置

仿真软件环境为Pycharm 建立的算法框架,并由Python 3.7和Pytorch 1.8 搭建深度学习网络。模型运行硬件环境为Intel Core i9-9280X CPU,内存 32 G,操作系统为Ubuntu 18.04 64位,显卡为2块NVIDIA RTX2080Ti 11G。

试验时使用的评估指标包括:归一化均方根误差(Normalized Root Mean Square Error, NRMSE)、平均绝对百分比误差(Mean Absolute Percentage Error, MAPE)、均方根误差的变异系数(Coefficient of Variation of the Root Mean Squared Rrror, CV-RMSE)、准确率(Accuracy, ACC)和精确度(Precision, PRE)。其中,NRMSE反映了实际值和预测值之间的差异,且对异常值非常敏感;MAPE为衡量预测值准确程度的评估指标;CV-RMSE根据平方误差和结果值的相对大小来描述模型拟合性能;准确率为分类正确的样本数与样本总数之比;精确度为正确检测的样本数与被检测到样本总数之比。

模型训练过程中参数设置如下:初始学习率设置为10⁻³,数据批量处理大小设置为50,学习率衰减倍数设置为0.2,正则化参数设置为10⁻⁵,最大迭代次数为15 000。

3.3 学习性能分析

对比 CNN、LSTM 和所提 EDDL 检测模型在训练集和测试集中的训练性能。各模型训练集和测试集损失对比如图 2 所示,可以看出,所提 EDDL 检测模型训练性能优于 CNN 和 LSTM 模型。CNN 和 LSTM 在训练集上的损失 约为 17.69% 和 15.83%。测试集中 CNN 的损失最大,约为 23.58%;其次为 LSTM 模型,约为 17.01%。EDDL 检测模型在训练集产生的损失约为 7%,在测试集上的损失约为 10%,训练集和测试集之间的误差仅为 3%。分析原因,CNN 学习了许多训练数据集的特征,但存在过拟合问题,导致在测试数据集中性能下降严重。LSTM 模型 较 CNN 模型有一定缓解,但性能提升有限。试验结果表明,所提 EDDL 检测模型在事件驱动机制下可更多关注 电流数据特征,获得更优的训练性能。

3.4 综合性能分析

对经典机器学习模型 MSVM^[11]和 FNN^[12],以及 CNN、LSTM等深度学习模型的综合性能进行分析。不 同模型的对比结果如表1所示。可以看出, MSVM和 FNN综合性能明显低于深度学习模型。分析原因,家庭 电器数据维度高,传统机器学习模型(MSVM和FNN)无 法更深层次理解特征与特征之间的关系。此外,根据 ACC 和 PRE 指标可看出, MSVM 和 FNN 存在过拟合问 题,导致模型虚警率较高,大量正样本未被检测出来。 尤其是MSVM模型, PRE指标仅为43.69%。

与MSVM、FNN、CNN和LSTM等模型相比,所提 EDDL 模型综合指标性能更优,其NRMSE为5.08%, MAPE 为 8.43%, CV-RMSE 为 7.85%, ACC 为 94.67%, PRE为91.76。分析原因,基于 EDDL 的非侵入式电力 负荷检测模型可更容易关注且有效学习包含关键事件的 电流信息。实验结果验证了所提模型的可行性和有效性。



Fig.2 Comparison of losses between training and testing sets of each model

图2 各模型训练集和测试集损失对比

表1 不同模型各指标统计情况(%)

Table1 Statistical situation of various indicators in different models(%)								
model	NRMSE	MAPE	CV-RMSE	ACC	P			
MSVM	13.43	17.31	22.56	79.31	43			

model	NRMSE	MAPE	CV-RMSE	ACC	PRE
MSVM	13.43	17.31	22.56	79.31	43.69
FNN	11.77	25.49	14.82	83.46	69.35
CNN	9.83	19.62	12.47	86.17	89.85
LSTM	7.81	13.69	11.78	89.62	91.54
EDDL	5.08	8.43	7.85	94.67	91.76

结论 4

本文对智能电网中非侵入式电力负荷检测方法进行了研究与分析,建立了一种基于 EDDL 的非侵入式电力负 荷检测模型。该模型可基于事件驱动机制挖掘包含重要信息的电流数据,并基于深度学习模型有效提取电流数 据特征,实现高精确度的非侵入式电力负荷检测。提出的基于EDDL的非侵入式电力负荷检测模型可为电力数据 分析以及电力领域安全发展提供一定的借鉴作用。

参考文献:

- [1] 张晓华,刘道伟,李柏青,等.智能电力物联网功能架构体系设计及创新模式探讨[J].电网技术, 2022,46(5):1633-1640. (ZHANG Xiaohua, LIU Daowei, LI Baiqing, et al. Discussion on the functional architecture system design and innovation mode of intelligent power Internet of things[J]. Power System Technology, 2022,46(5):1633-1640.) doi:10.13335/j.1000-3673.pst.2021.1569.
- [2] 朱怡莹,周荣生,罗龙波.考虑需求响应与光伏不确定性的电力系统经济调度[J].太阳能学报, 2023,44(1):62-68. (ZHU Yiying, ZHOU Rongsheng, LUO Longbo. Economic dispatch of power system considering demand response and PV uncertainty[J]. Acta Energiae Solaris Sinica, 2023,44(1):62-68.) doi:10.19912/j.0254-0096.tynxb.2021-0844.
- [3] 毛龙灿,杨南.基于大数据背景的皮革人才培养优化研究[J].中国皮革, 2021,50(9):38-41. (MAO Longcan, YANG Nan. Optimization of leather talent training based on big data[J]. China Leather, 2021,50(9):38-41.) doi:10.13536/j.cnki.issn1001-6813.2021-009-009.
- [4] 杨涛. 互联网时代下皮革行业电商物流体系研究分析[J]. 中国皮革, 2021,50(8):82-85. (YANG Tao. E-commerce logistics system of leather industry in Internet era[J]. China Leather, 2021,50(8):82-85.) doi:10.13536/j.cnki.issn1001-6813.2021-008-019.
- [5] 钟建栩,余少锋,廖崇阳,等. 基于云计算的电力设备智能监测系统[J]. 云南师范大学学报(自然科学版), 2022,42(3):37-41. (ZHONG Jianxu, YU Shaofeng, LIAO Chongyang, et al. Research on power equipment condition monitoring system based on cloud computing[J]. Journal of Yunnan Normal University(Natural Sciences Edition), 2022, 42(3): 37-41.) doi: 10.7699/j. ynnu.ns-2022-034.
- [6] 张春辉,白翠芝,张蔓娴.基于小波的电力负荷异常检测[J].云南大学学报(自然科学版), 2020,42(Z2):49-54. (ZHANG Chunhui, BAI Cuizhi, ZHANG Manxian. Abnormal detection of power load based on wavelet[J]. Journal of Yunnan University (Natural Sciences Edition), 2020, 42(Z2): 49-54.)

- [7] 曾德斌,许江淳,杨杰超,等. 基于数据挖掘的 PSO-BP 短期电力负荷预测[J]. 自动化仪表, 2020,41(5):93-97. (ZENG Debin, XU Jiangchun, YANG Jiechao, et al. Short-term power load forecasting based on PSO-BP with data mining[J]. Process Automation Instrumentation, 2020,41(5):93-97.) doi:10.16086/j.cnki.issn1000-0380.2019050012.
- [8] 周晓,李永清,张有兵. 基于 ELM 的非侵入式电力负荷识别算法[J]. 高技术通讯, 2020,30(10):1018-1024. (ZHOU Xiao,LI Yongqing,ZHANG Youbing. Identification algorithm for non-intrusive power load based on ELM[J]. Chinese High Technology Letters, 2020,30(10):1018-1024.) doi:10.3772/j.issn.1002-0470.2020.10.004.
- [9] 马一杰,陈君,刘松. 基于长短时记忆网络的电力负荷异常检测[J]. 云南大学学报(自然科学版), 2020,42(Z2):55-59. (MA Yijie, CHEN Jun, LIU Song. Power load abnormal detection based on long short-term memory[J]. Journal of Yunnan University (Natural Sciences Edition), 2020,42(Z2):55-59.)
- [10] 许伟红,周金宇.加权动态时间扭曲的不平衡结构转子故障诊断[J]. 机械设计与制造, 2023(2):90-100. (XU Weihong,ZHOU Jinyu. Fault diagnosis of unbalanced rotor structure based on weighted dynamic time warping[J]. Machinery Design & Manufacture, 2023(2):90-100.) doi:10.3969/j.issn.1001-3997.2023.02.019.
- [11] KATARYA R, DAHIYA D, CHECKER S. Fake News detection system using Featured-Based optimized MSVM classification[J]. IEEE Access, 2022(10):113184-113199.) doi:10.1109/ACCESS.2022.3216892.
- [12] LEE U, LEE I. Efficient sampling-based inverse reliability analysis combining Monte Carlo Simulation(MCS) and feedforward neural network(FNN)[J]. Structural and Multidisciplinary Optimization, 2021,65(1):8. doi:10.1007/s00158-021-03144-2.

作者简介:

技术.

李 晨(1990-),女,学士,工程师,主要研究方 向为信息技术.email:lichen_199003@163.com.

夏立典(1992-),男,学士,主要研究方向为信息 叶林

章 超(1990-),男,学士,主要研究方向为信息 技术.

叶杨锋(1991-),男,学士,主要研究方向为信息 技术.

(上接第1356页)

- [5] 何宏,杜明星,张志宏.电磁兼容原理与技术[M].北京:清华大学出版社, 2017. (HE Hong, DU Mingxing, ZHANG Zhihong. Principle and technology of electromagnetic compatibility[M]. Beijing:Tsinghua University Press, 2017.)
- [6] 柳光福,刘启明,葛光楣. 介质谐振腔滤波器的设计[J]. 航空电子技术, 2004,35(1):32-36,41. (LIU Guangfu,LIU Qiming,GE Guangmei. Design of a bandpass filter using dielectric ring resonators[J]. Avionics Technology, 2004,35(1):32-36,41.) doi:10. 3969/j.issn.1006-141X.2004.01.007.
- [7] 周俊,刘大刚,曾亚文,等. 微波谐振腔本征模求解的算法及应用[J]. 材料导报, 2007(Z2):244-246. (ZHOU Jun,LIU Dagang, ZENG Yawen, et al. Algorithms and applications of eigen-mode solution in microwave resonant cavities[J]. Materials Review, 2007(Z2):244-246.)
- [8] 陈珂,杜平安,任丹. 一种基于隙缝天线阻抗的带缝腔体谐振频率计算方法[J]. 电子学报, 2017,45(1):232-237. (CHEN Ke, DU Pingan,REN Dan. A method for resonant frequencies calculation based on the impedance of cavity-backed slot antenna[J]. Acta Electronica Sinica, 2017,45(1):232-237.) doi:10.3969/j.issn.0372-2112.2017.01.032.
- [9] 刘海涛,张学军,李冬霞,等.L频段数字航空通信系统干扰抑制方法与性能[M].北京:科学出版社, 2018. (LIU Haitao,ZHANG Xuejun,LI Dongxia, et al. Interference mitigation methods and performance for L-DACS1 system[M]. Beijing:Science Press, 2018.)
- [10] 赵辉. 系统电磁兼容[M]. 北京:国防工业出版社, 2019. (ZHAO Hui. System electromagnetic compatibility[M]. Beijing: National Defense Industry Press, 2019.)

作者简介:

徐健(1974-),男,学士,高级工程师,主要研究 方向为大功率合成、电子通信、系统总体工程等.emai: 13967384464@sina.cn. **陈永其**(1969-),男,硕士,研究员,主要研究方向为信号处理、系统总体工程等.

肖秋枫(1964-),男,学士,研究员,主要研究方 向为系统总体设计、高新技术引领等.