

DOI: 10.19783/j.cnki.pspc.211021

基于 2D-ResNet 的船舶电力系统电能质量扰动识别

宋铁维, 施伟锋, 毕宗, 谢嘉令

(上海海事大学电气自动化系, 上海 201306)

摘要: 为实现船舶电力系统电能质量扰动准确识别, 结合深度学习提出基于二维残差网络(2D-ResNet)的电能质量扰动识别方法。首先将电能质量一维时间序列通过距离矩阵转化为二维平面图, 随后将图像送入所提二维残差网络中提取特征。最终输出特征图通过线性层分类器得到识别结果, 实现船舶电力系统电能质量扰动的在线识别。与现有特征提取方法相比, 不同信噪比下该方法扰动识别准确率均最高。信噪比为 20 dB 时, 单标签分类平均准确率为 93.86%, 多标签分类平均 F_1 -score 为 96.52%, 证明了 2D-ResNet 能有效提取扰动特征且对噪声具备鲁棒性。对于未知复合扰动, 单标签分类器识别失败, 而多标签分类器准确识别出扰动中的未知成分, 且 F_1 -score 达到 93%, 证明了多标签分类适用于未知复合扰动识别。

关键词: 船舶电力系统; 电能质量; 二维残差网络; 扰动识别; 单标签分类; 多标签分类

Shipboard power quality disturbance recognition based on a two dimensional residual network

SONG Tiewei, SHI Weifeng, BI Zong, XIE Jialing

(Department of Electrical Automation, Shanghai Maritime University, Shanghai 201306, China)

Abstract: For accurate classification, a power quality disturbance recognition method of a shipboard power system based on a two dimensional residual network (2D-ResNet) is proposed. First, the one-dimensional power quality time series is transformed into a two-dimensional image by a distance matrix, and then the image is sent to the proposed 2D-ResNet to extract features. Then an output feature map is used to obtain the recognition results through the linear layer classifier to realize on-line recognition of power quality disturbances in a shipboard power system. Compared with existing feature extraction methods, this method has the highest accuracy of disturbance recognition under different signal-to-noise ratio (SNR). When the SNR is 20 dB, the average accuracy of single-label classification is 93.86%, and the average F_1 -score of multi-label classification is 96.52%. This proves that the 2D-ResNet can effectively extract features and is robust to noise. A single-label classifier fails to recognize unknown compound disturbance, while the multi-label classifier accurately recognizes the unknown components in the disturbance signal, and the F_1 -score reaches 93%, which proves that the multi-label classification is suitable for the recognition of unknown compound disturbance.

This work is supported by the Shanghai Science and Technology Committee Foundation (No. 20040501200).

Key words: shipboard power system; power quality; two dimensional residual network; disturbance identification; single-label classification; multi-label classification

0 引言

船舶电力系统属于海上孤岛电网, 运行工况复杂, 且装备有冲击性负载与非线性负载, 大功率推进电机、变频器以及其他用电设备的故障等都会造成电能质量扰动, 影响船舶的正常运行^[1]。船舶电力系统电能质量扰动可能会引起推进电机转速调节

不准确, 影响船舶推进, 进而影响船舶航速。若不及时处理, 可能导致推进电机发热, 降低电机使用寿命, 甚至启动热保护, 影响船舶运行安全。研究船舶电力系统电能质量扰动识别可为故障定位与诊断提供有价值的信息, 以便及时采取故障隔离措施, 降低负面影响^[2]。

目前, 基于时频分析与数据驱动的电能质量扰动识别方法应用广泛。文献[3]提出利用短时傅里叶变换和谱峭度对电能质量信号进行分析, 该方法在

基金项目: 上海市科技计划项目资助(20040501200)

傅里叶变换的基础上增加一个滑动时间窗, 可分析信号的局部特征, 但时间窗宽度固定, 捕捉信号瞬态特征的效果不好; 文献[4]使用离散小波变换(DWT)对电能质量信号进行分析, DWT 有较好的频率分辨率, 可以处理非平稳信号, 但小波基不易选取, 品质因子不易调谐; 文献[5]提出基于可调品质因子小波变换和随机森林的电能质量复合扰动方法, 相比 DWT 具有更高的灵活性, 但其选择子带时具有较大的主观性; 文献[6]提出基于广义 S 变换(ST)的电能质量信号处理方法, ST 抗噪能力较强, 不需要设置窗函数, 但运算量较大; 文献[7]提出基于经验模态分解(EMD)的电能质量检测方法, EMD 能自适应分解信号, 但是容易出现模态混叠; 文献[8]利用变分模态分解(VMD)对电能质量信号进行处理, VMD 有较好的分解效果, 但较难确定分解层数, 不适用于复合扰动的分类。以上方法均需手动提取特征, 需要先验知识, 否则容易丢失有效信息。

随着深度学习的发展, 数据驱动方法在电能质量扰动识别上的应用越来越多。文献[9]提出基于一维卷积神经网络的电能质量扰动识别方法, 具有较好的分类效果, 但未考虑复合扰动的分类。文献[10]提出基于循环神经网络(RNN)的电能质量扰动识别, RNN 具有短期记忆能力, 能实现电能质量信号时间特征的学习, 但训练困难。文献[11]提出基于特征融合的一维卷积神经网络(FCNN), 该模型通过融合多个子模型提取的特征达到提升识别准确率的效果, 但本质上仍为一维卷积神经网络, 未充分挖掘扰动信号特征, 且未说明各个子模型的选取标准。

本文运用距离矩阵挖掘船舶电力系统电能质量扰动时间序列的递归特性, 提出结合卷积神经网络与深度残差网络的二维残差网络来提取船舶电力系统电能质量扰动信号特征, 同时讨论了单标签分类与多标签分类各自的适用场景。算例表明, 所提方法特征提取能力强, 对噪声鲁棒性高。

1 电能质量序列图像化

递归图最初被用在复杂动力系统可视化研究上, 通过分析高维相空间轨迹对非线性系统时间序列进行分析^[12]。相较于其他信号处理方法, 递归图便于直观地分析信号, 距离矩阵作为递归图的一种特例, 可用来对时间序列进行分析。

1.1 船舶电力系统电能质量信号

相比于陆上电力系统, 船舶电力系统容量较小, 对电能质量扰动敏感, 且由于其运行工况复杂, 易出现复合电能质量扰动。本文参照文献[13]模拟

生成船舶电力系统电能质量扰动信号, 包含单一扰动以及由其相互组成的复合扰动, 表 1 中列出了 5 类电能质量扰动信号的数学模型。

表 1 电能质量扰动数学模型

扰动类别	数学模型	可调参数
正常	$v(t) = A \sin(\omega t - \varphi)$	φ
暂升	$v(t) = A(1 + \beta(u(t-t_1) - u(t-t_2))) \sin(\omega t - \varphi)$	φ, t_1, t_2, β
中断	$v(t) = A(1 - \rho(u(t-t_1) - u(t-t_2))) \sin(\omega t - \varphi)$	φ, t_1, t_2, ρ
闪变	$v(t) = A[1 + \lambda \sin(\omega_f t)] \cdot \sin(\omega t - \varphi)$	$\varphi, \omega_f, \lambda$
谐波+暂升	$v(t) = A(1 + \beta(u(t-t_1) - u(t-t_2))) \cdot [\sin(\omega t - \varphi) + \sum_{n=3}^{n=5} \alpha_n \sin(n\omega t - \theta_n)]$	φ, β, θ_n

表 1 中列出了正常、暂升、中断、谐波+暂升、闪变 5 类电能质量扰动信号的数学模型以及可调参数。其中: φ 为相角, $\varphi \in [-\pi, \pi]$; t_1 与 t_2 为扰动开始与结束时刻, $T \leq t_2 - t_1 \leq (N-1)T$, T 为基波周期, N 为扰动信号里的基频周波数; ρ 为中断信号下降幅值, $0.9 \leq \rho \leq 1$; λ 与 ω_f 为闪变幅值与角频率, 且 $\lambda \in [0.05, 0.1]$, $\omega_f \in [16\pi, 50\pi]$; β 与 θ_n 为暂升幅值与 n 次谐波相角, $0.1 \leq \beta \leq 0.8$, $\theta_n \in [-\pi, \pi]$ 。在使用数学模型模拟时, 调整可调参数能模拟生成随机扰动信号, 用于扩充的神经网络输入。表 1 中 A 表示扰动信号幅值, 本文考虑标么值, 故将 A 设置为 1。

1.2 电能距离矩阵

无阈值递归图的延迟时间置为 0, 嵌入维度置为 1 时, 得到的矩阵便与距离矩阵一致。

$$\mathbf{D}_{N \times N} = \begin{bmatrix} d_{1,1} & \cdots & \cdots & d_{1,N} \\ \vdots & & & \vdots \\ \vdots & & & \vdots \\ d_{N,1} & \cdots & \cdots & d_{N,N} \end{bmatrix} \quad (1)$$

式中: \mathbf{D} 为距离矩阵; N 为时间序列长度; $d_{k,j} = \|x_k - x_j\|^2$ 为距离矩阵 \mathbf{D} 中的元素, 代表两采样点之间的欧式距离, 其中 $d_{k,j} = d_{j,k}$, $\|\cdot\|$ 为二范数。

神经网络输入归一化处理, 能够防止梯度爆炸, 加速网络收敛。因此本文将电能质量矩阵归一化后再送入 2D-ResNet 提取特征。

$$\tilde{d}_{k,j} = \frac{d_{k,j} - \min D}{\max D - \min D} \quad (2)$$

$$\tilde{\mathbf{D}}_{N \times N} = [\tilde{d}_{k,j}] \quad (3)$$

式(2)为矩阵元素的归一化操作,式(3)为归一化后的电能质量矩阵,矩阵元素均在[0,1]中。

1.3 电能质量扰动二维图像

由于复合扰动的分类比较困难,本文采用距离矩阵处理电能质量扰动一维时间序列,将其转化为二维图像,突出特征,便于分类。图1给出了表1中5种电能质量扰动信号波形及其对应的距离矩阵,其中幅值为1,序列长度为512。

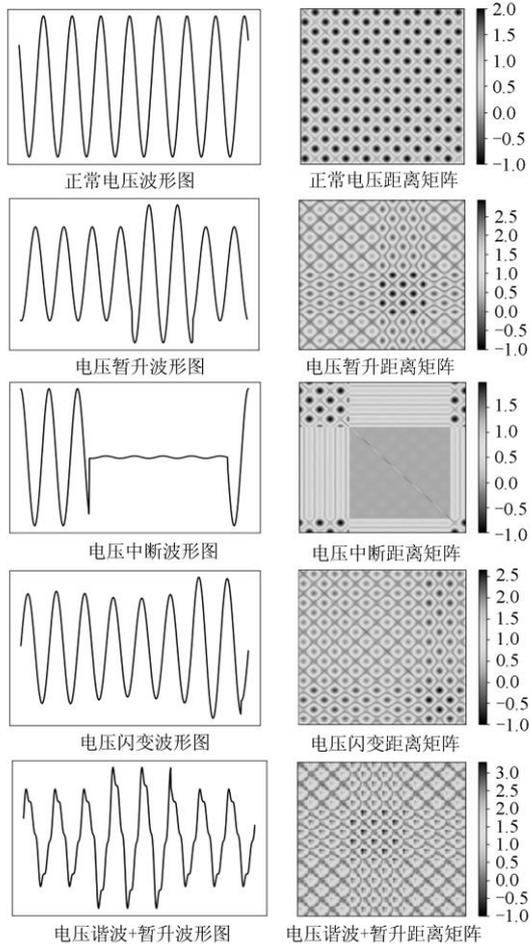


图1 电能质量扰动信号与对应的距离矩阵

Fig. 1 Power quality disturbance signal and distance matrix

图1中,正常电压距离矩阵具有很明显的递归特性,形状规则;电压暂升后的距离矩阵的元素增大,突变处在矩阵上有较为明显、呈现在图上为两条垂直的线条;电压中断在距离矩阵上体现为存在行与列上的突变,并且突变后的元素接近于0;电压闪变在幅值与周期上都存在变化,其距离矩阵在其闪变部分变得“圆润”;电压谐波+暂升包含了两种扰动的特征,主要体现在突变与元素幅值增大;谐波的距离矩阵也具有较好的递归性,但其与正常

电压矩阵元素值大小不一致,且对角线变得不规则,呈现“弯曲”特征。综上所述,采用距离矩阵能够较充分地挖掘船舶电力系统电能质量扰动信号时间序列中的信息,有利于扰动分类。

2 基于2D-ResNet的特征提取

2.1 深度残差网络

深度残差网络由多个残差块构成,残差块内部恒等连接,能够减小深度网络梯度消失的概率,使得网络容易优化,提升了识别准确率,目前在计算机视觉域得到广泛应用[14]。

图2为深度残差网络的基本结构-残差块。残差块存在两条通路:中间通路由多个权值层组成,用于提取高维特征;右侧通路称为恒等连接,其输出与中间通路提取的高维特征相加,避免网络出现梯度消失现象。当恒等连接与中间通路输出特征尺寸不一致时,可通过池化等操作调整两者的尺寸,无需引入额外的参数。

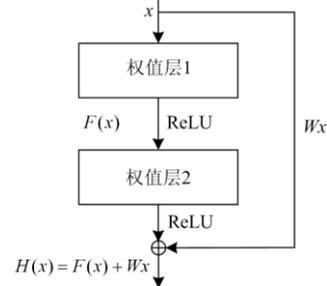


图2 原始残差块结构

Fig. 2 Structure of initial residual block

2.2 基于2D-ResNet的电能质量扰动特征提取

观察电能质量距离矩阵,发生扰动时距离矩阵行与列出现明显的变化,为提取这一特征,需要获取较大的邻域信息。卷积神经网络中,大卷积核具备大的感受野,可获取大邻域范围信息,但训练参数多。故在此使用多个小卷积核级联,获取大感受野的同时减少参数数量。具体地,残差块采用3组3×3卷积核获取等同于7×7卷积核的感受野,但每个通道减少了22个参数,且3组卷积核级联也加深了网络深度,加强了网络的表达能力。

电能质量距离矩阵规模较大,训练深层网络会消耗较多计算资源。权衡参数量与残差网络特征提取能力,设计图3所示的两个残差块进行特征提取。残差块1的输出与输入相比,特征图宽度与高度均减半,通道数不变。该残差块主要对特征图进行降采样,减少网络参数数量。输入特征图先通过批标准化层、ReLU激活函数以及步长为2的3×3的卷积

核, 减小特征图的尺寸, 随后经过相同的步骤进行特征提取。为了保证恒等连接与输出特征图尺寸一致, 残差块 1 中的恒等连接经过池化层再与卷积后的特征图相加。残差块 2 的输入与输出尺寸一致, 在文中作为最后一个残差块进行特征提取。经过残差块 1 后网络参数已经下降到一个可接受的范围, 故此时设置残差块 2 的卷积步长为 1, 从而保留两个像素点的相关信息。

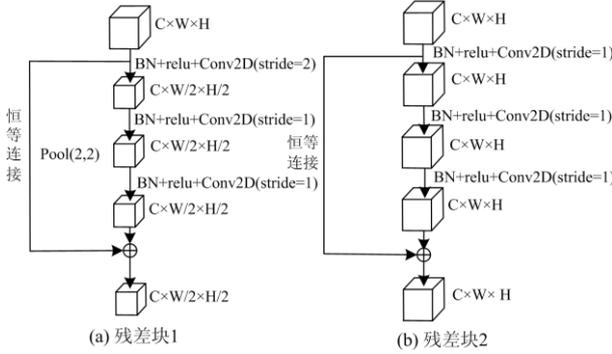


图 3 二维残差块结构

Fig. 3 Structure of two-dimensional residual block

卷积层(Convolution, Conv): 实现输入图像在三维空间的特征提取^[15]。卷积层的计算公式为

$$y_j = \sum_{i \in C_j} x_i * k_{ij} + b_j \quad (4)$$

式中: x_i 是输入特征图的第 i 个通道; y_j 是输出特征图的第 j 个通道; k_{ij} 是卷积核; b_j 是偏置项; C_j 是特征图的通道集合。

批标准化(Batch Normalization, BN): 解决网络训练过程中中间层数据分布发生改变的问题^[16]。

$$\mu = \frac{1}{m} \sum_{i=1}^m x_i \quad (5)$$

$$\sigma^2 = \frac{1}{m} \sum_{i=1}^m (x_i - \mu)^2 \quad (6)$$

$$\hat{x}_i = \frac{x_i - \mu}{\sqrt{\sigma^2 + \varepsilon}} \quad (7)$$

$$y_i = \gamma \hat{x}_i + \beta \quad (8)$$

式中: x_i 和 y_i 为一个批次上特征图的输入输出; γ 与 β 为可训练参数; ε 是一个非常小的接近 0 的数; m 为批尺寸。

式(5)和式(6)分别用来求每一个训练批次数据的均值与方差。式(7)使用求得的均值和方差对该批次的训练数据做归一化, 获得正态分布。归一化后的数据被限制在正态分布下, 使得网络表达能力下降, 故使用式(8)进行尺度变换与偏移。

激活函数: 负责将输入映射到输出端。ReLU

函数会使一部分神经元的输出为 0, 使得网络具有稀疏性, 减少了参数的相互依存, 缓解了过拟合问题, 因此本文选用 ReLU 激活函数^[17]:

$$y = \max(x, 0) \quad (9)$$

式中, x 与 y 分别是 ReLU 激活函数的输入与输出。

3 电能质量扰动分类器

本节讨论了单标签与多标签分类器^[18]的适用场景, 并说明了所提方法的电能质量扰动识别流程。

3.1 单标签分类

船舶电力系统电能质量扰动单标签分类, 将单一或复合扰动都视为一类标签。例如, 若电能质量扰动类型为单一扰动 C_1, C_2, C_3 及其组合而成的复合扰动 $C_1 + C_2, C_1 + C_3, C_2 + C_3, C_1 + C_2 + C_3$, 单标签分类器将输出这 7 种类型的概率, 取概率最大的类别作为分类结果。单标签分类的一般形式为: “softmax+交叉熵”, 以交叉熵作为损失函数, softmax 层放在网络的最后一层作为分类器, 输出各个类别的概率。单标签分类实现如下:

$$P(Y = k | X = x_i) = \frac{e^{s_k}}{\sum_j e^{s_j}} \quad (10)$$

$$\text{loss} = -\sum_k \log\left(\frac{e^{s_k}}{\sum_j e^{s_j}}\right) \quad (11)$$

$$s = f(x_i; W) \quad (12)$$

式(10)表示 softmax 函数, 把输出映射到概率空间, 表示样本被分为第 k 类的概率, 其中 e 为自然常数; 式(11)中 loss 为交叉熵损失函数, K 为总标签数目; 式(12)为神经网络第 i 层的输出。

3.2 多标签分类

船舶电力系统电能质量扰动多标签分类, 输出是每类单一扰动存在与否的布尔值。在 3.1 节中, 存在 7 种扰动类型, 单一扰动为 3 种, 因此多标签分类器输出含 3 个元素的向量, 分别是 C_1, C_2, C_3 是否存在的布尔值。例如, 扰动类型 $C_1 + C_2$ 与 $C_1 + C_3$ 可表示为 $[1, 1, 0]$ 与 $[1, 0, 1]$ 。电能质量扰动信号单个标签之间不存在强相关性, 因此本文对单个标签二分类, 网络最后一层设置为 “sigmoid” 层, 将输出映射到 $[0, 1]$ 的概率空间, 并确定一个合理的阈值, 大于阈值的输出为 0, 否则为 1。具体为

$$y = \frac{1}{1 + e^{-x}} \quad (13)$$

$$y = \begin{cases} 0 & x \geq \eta \\ 1 & x < \eta \end{cases} \quad (14)$$

式(13)为 sigmoid 函数, 式(14)为用于输出结果

的硬阈值函数， η 为阈值，本文取 0.5。

多标签分类会出现单个标签正负类别不均衡的情况，影响扰动识别的准确率。扰动的正类别定义为样本存在该扰动，负类别定义为样本不存在该扰动。例如，若存在 8 类数量相等的电能质量单一扰动(C1—C8)，则各扰动正负类别数目之比为 1:7，此时易发生漏判，将扰动样本划分为无扰动样本。

本文根据单个标签的正负类别数量比赋予二值交叉熵函数合适权重，作为损失函数，如式(15)。

$$loss = \sum_{i=1}^N (w_i^+ y_{true} \log(y_{pred}) + w_i^- (1 - y_{true}) \log(1 - y_{pred})) \quad (15)$$

式中： $loss$ 为带权二值交叉熵函数； y_{true} 为真实标签； y_{pred} 为预测标签； w_i^+ 为标签 i 正类别对应的权值； w_i^- 为标签 i 负类别对应的权值； N 为单个标签的数目。 w_i^+ 与 w_i^- 根据单个标签正负类别的数量选取，即式(16)。

$$\begin{cases} w_i^+ = \frac{N_{i,train}}{2N_{i,train}^+} \\ w_i^- = \frac{N_{i,train}}{2N_{i,train}^-} \end{cases} \quad (16)$$

式中： $N_{i,train}$ 为标签 i 的训练样本数； $N_{i,train}^-$ 与 $N_{i,train}^+$ 分别为训练样本中标签 i 的正负样本数。

3.3 评价指标

本文中各类电能质量扰动信号样本数量一致，故单标签分类的评价指标使用准确率(accuracy)；多标签分类正负样本数目不一致，因此评价指标使用精确率(precision)与召回率(recall)以及 F_1 -score^[19]。

$$accuracy = \frac{NC}{NC + NI} \quad (17)$$

$$precision = \frac{TP}{TP + FP} \quad (18)$$

$$recall = \frac{TP}{TP + FN} \quad (19)$$

$$F_1\text{-score} = \frac{2}{1/precision + 1/recall} \quad (20)$$

式中： NC 与 NI 分别为单标签分类中分类正确与分类错误的样本数； TP 表示预测为正例，实际为正例的样本数目； FP 表示预测为正例，实际为负例的样本数目； FN 表示预测为负例，实际为正例的样本数目； F_1 -score 为 precision 与 recall 的几何平均数。

3.4 电能质量扰动识别流程

整个网络模型中耗时的训练过程离线完成，在线识别速度较快，因此可应用于电能质量扰动实时识别。图 4 为电能质量识别流程图，描述了所提船舶电力系统电能质量扰动识别模型的离线训练以及在线识别过程。

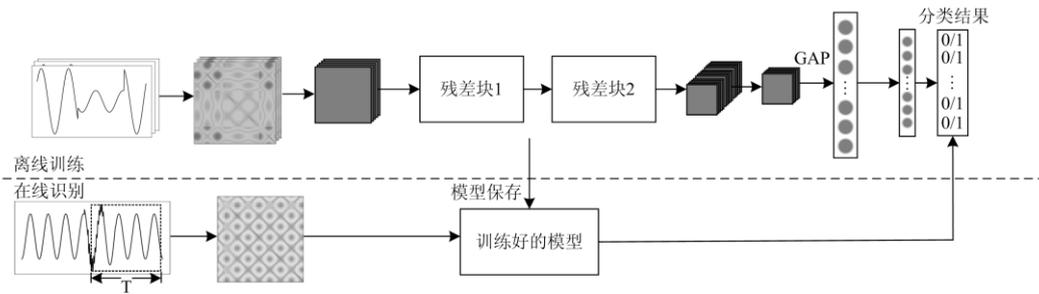


图 4 电能质量识别流程图

Fig. 4 Flow chart of power quality identification

离线训练：截取合适长度 T 的历史电能质量时间序列并给出标签，并将其转化为距离矩阵 D ； D 标准化后经过一个卷积层得到多个特征图；随后将特征图送入二维残差网络在高维特征空间上进行特征提取；对于单标签分类器，将网络最后一层设置为“softmax”层，用于输出分类结果，误差反向传播目标为最小化损失函数式(11)；对于多标签分类器，在网络最后加入“sigmoid”层，输出单个标签的正负类别概率，并设置合理阈值，得到二分类结果，反向传播目标为最小化损失函数式(15)。

在线识别：若当前时刻为 t ，则将 $[t - T - 1, t]$ 时段的电能质量序列转化为距离矩阵送入网络识别，输出分类结果。即选择一个大小为 T 的窗口在时间轴上滑动，实现电能质量扰动的在线识别，其中， T 的大小与采样频率相关。

4 算例分析

本文参照文献[13]使用 Matlab 仿真形成 18 种船舶电力系统电能质量扰动信号，包括单一扰动：暂降、暂升、中断、脉冲、谐波、振荡、闪变与缺口；

复合扰动: 谐波+暂降、谐波+暂升、闪变+暂降、闪变+暂升、暂降+振荡、暂升+振荡、谐波+暂降+闪变、谐波+暂升+闪变、谐波+暂降+振荡、谐波+暂升+振荡, 分别用 C1, C2, ..., C18 表示。设电能质量扰动信号基频为 50 Hz, 为分析采样频率对识别结果的影响, 分别在 3.2 kHz、2.4 kHz、1.6 kHz、0.8 kHz 频率下进行试验, 采样时间设置为 0.16 s, 对应 50 Hz 基频信号的 8 个周波。通过随机改变表 1 中数学模型的可调参数, 为每类扰动随机生成 800 个样本, 共 14 400 个样本, 训练样本 10 080 个, 测试样本 4 320 个。深度学习框架为 tensorflow2.0, 编程平台 Python3.7, 使用 64 GB 的 Tesla T4 显卡计算。

4.1 网络参数设置

迭代次数设为 150, batchsize 设为 256, 学习率采用随迭代次数增加而逐渐减小的策略, 具体见式 (21), 采用 Adam 优化器^[20]优化求解。

$$lr(epoch) = lr_{init} * M^{\frac{1+epoch}{drop}} \quad (21)$$

式中: lr_{init} 为初始学习率, 本文取 0.01; M 为下降因子, 本文取 0.5; $drop$ 取 15。式(21)表示每经过 15 个 $epoch$, 学习率减半, 这样有利于训练后阶段的参数寻优, floor 为向下取整函数。

表 2 列出了所提 2D-ResNet 里卷积层与线性层的参数设置, 同时为了防止网络出现过拟合现象, 添加了 dropout 层^[21]。

表 2 二维残差网络参数表
Table 2 Parameters of 2D Resnet

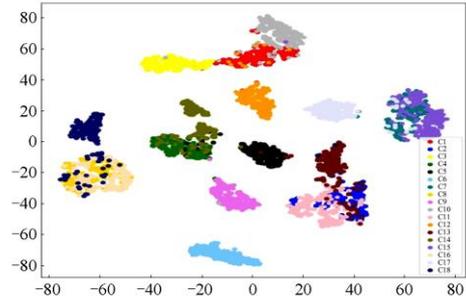
模块	卷积核	数量/尺寸	步长
卷积层	Conv2D	32(3×3)	1
残差块 1	Conv2D	32(3×3)	2
	Conv2D	32(3×3)	1
残差块 2	Conv2D	32(3×3)	1
	Conv2D	32(3×3)	1
卷积层	Conv2D	32(1×1)	1
线性层	softmax/sigmoid	18/8	—

4.2 单标签分类结果分析

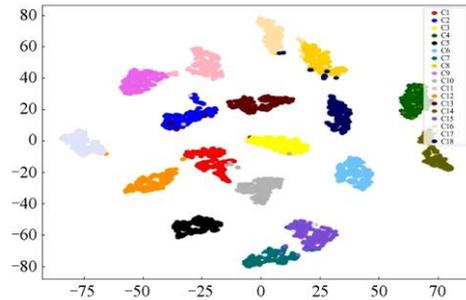
为增加模型可解释性, 使用 t-SNE^[22]对不含噪声、信噪比分别为 20 dB、30 dB、40 dB 情况下 2D-ResNet 的最后一层进行可视化, 结果见图 5。

如图 5 所示: 2D-ResNet 在信噪比为 40 dB 与无噪声的情况下, 提取到的各类电能质量扰动高维特征边界分明, 分类效果良好; 信噪比为 30 dB 时, 特征聚类边界基本明显, 未出现特征簇重叠现象; 信噪比为 20 dB 时, 特征簇出现重叠现象, 但大部

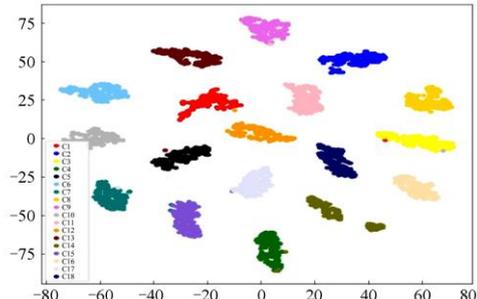
分扰动类别仍能够准确识别出来, 观察可视化图发现造成特征簇重叠的主要因素为噪声的引入导致电能质量扰动信号递归特性发生变化。



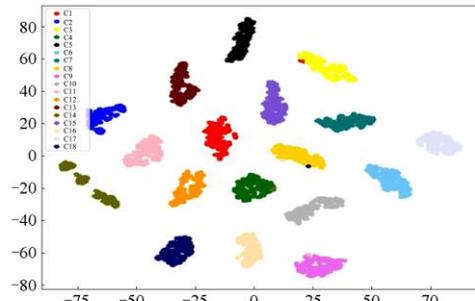
(a) 20 dB 信噪比下特征可视化图



(b) 30 dB 信噪比下特征可视化图



(c) 40 dB 信噪比下特征可视化图



(d) 无噪声时特征可视化图

图 5 高维特征 t-SNE 可视化

Fig. 5 The t-SNE of high dimensional features

表 3 列出了所提电能质量扰动识别方法在 4 种不同信噪比下每个扰动类型的分类准确率。

表 3 不同信噪比下本文方法分类准确率

Table 3 Classification accuracy with different SNR

扰动类型	分类准确率%			
	无噪声	40 dB	30 dB	20 dB
C1	100.00	100.00	99.00	97.00
C2	100.00	100.00	99.00	98.00
C3	100.00	100.00	100.00	95.00
C4	100.00	98.00	96.00	91.00
C5	100.00	100.00	99.00	95.00
C6	100.00	100.00	100.00	95.00
C7	100.00	99.00	100.00	94.00
C8	100.00	99.00	99.00	95.00
C9	100.00	100.00	100.00	94.00
C10	100.00	99.00	99.00	95.00
C11	100.00	99.00	100.00	93.00
C12	100.00	100.00	100.00	94.00
C13	100.00	100.00	99.00	93.00
C14	100.00	99.00	97.00	93.00
C15	99.00	100.00	99.00	93.00
C16	100.00	100.00	98.00	92.00
C17	99.00	99.00	98.00	91.00
C18	100.00	98.00	99.00	92.00
平均分类准确率	99.89	99.47	99.09	93.86

由表 3 可以看出，4 种不同信噪比情况下，所提方法的平均分类准确率均高于 93%，证明了所提方法能有效提取信号特征。“脉冲”信号在含噪声的情况下难以识别，但所提方法在 20 dB 信噪比的情况下对“脉冲”信号识别仍可达到 91% 的准确率，证明其对噪声有较强鲁棒性。将所提方法与残差网络+格拉姆角场(ResNet+GAF)、残差网络+时间序列堆叠矩阵(ResNet+STM)、1D-CNN 模型^[9]、CNN+LSTM 模型^[23]进行对比，结果见表 4。

表 4 不同方法扰动识别结果

Table 4 Disturbance identification result of different methods

实验方法	平均分类准确率/%				参数量
	无噪声	40 dB	30 dB	20 dB	
本文方法	99.89	99.47	99.09	93.86	56 850
ResNet+STM	99.32	99.21	98.37	90.07	101 522
ResNet+GAF	98.50	98.03	96.83	87.88	101 522
1D-CNN	98.59	98.24	97.30	88.75	121 234
CNN+LSTM	98.97	98.08	96.31	86.65	321 411

由表 4 可以看出，4 种不同信噪比下，本文所提方法分类准确率均要高于其余 4 种方法，特别是在信噪比为 20 dB 的情况下，提升效果最明显，说明 2D-ResNet 能够提取鲁棒性强的电能质量特征。

前 3 种方法对比说明将电能质量时间序列转化为距离矩阵能更好地挖掘信号中的隐含信息。1D-CNN 与 CNN+LSTM 相较前 3 种方法分类准确率低，说明二维图像输入更适合卷积神经网络进行特征提取。表 4 中，参数量表示网络各层待训练权重与偏置项总和，参数量小的网络结构简单且易于训练。本文方法由于结构简单且采用多个小卷积核级联，故待训练参数比其余 4 种方法计算量均少。综上，所提方法能有效提取电能质量扰动信号的特征，对噪声鲁棒性强，运算量较小。

考虑到采样频率对电能质量扰动识别的影响，分别在 3.2 kHz、2.4 kHz、1.6 kHz、0.8 kHz 频率下进行试验，对应的平均分类准确率如图 6 所示。

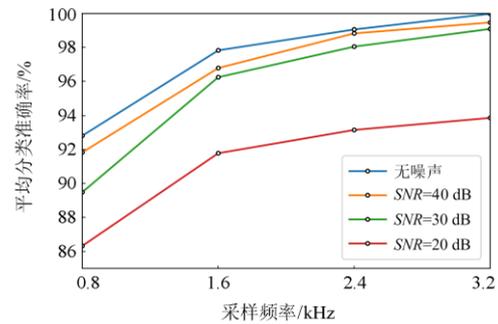


图 6 平均分类准确率与采样频率的关系

Fig. 6 Relationship between average classification accuracy and sampling frequency

图 6 中：3.2 kHz 采样频率下的分类准确率最高；采样频率下降到 2.4 kHz 时，准确率略微下降，但仍维持在 92% 以上；采样频率下降到 1.6 kHz 时，折线走势变陡峭，准确率下降幅度增大；采样频率降为 0.8 kHz 时，信噪比为 20 dB 与 30 dB 时的扰动平均分类准确率降低至 90% 以下。因此，采样频率越高，电能质量扰动识别效果越好。目前，实际应用中的电能质量采样频率能达到 3.2 kHz 及以上，因此所提方法能运用于实际电能质量扰动识别中。

4.3 多标签分类结果分析

多标签分类方法分别在无噪声、20 dB、30 dB、40 dB 信噪比的船舶电力系统电能质量扰动信号下进行测试对比。

混淆矩阵能够体现分类的误判与漏判情况。其纵坐标为实际类别，横坐标为预测类别。对角线元素为判断正确的元素。左下角为漏判元素，右上角为错判元素。信噪比为 20 dB 时，2D-ResNet 多标签分类的混淆矩阵如图 7 所示。图 7 中，各类电能质量扰动信号误判、漏判事件较少，特别在“闪变”与“振荡”扰动信号上的分类效果明显。其余信噪

比情况下的分类效果见表 5—表 7。

观察表 5—表 7, 多标签分类方法在不同信噪比下, 3 个评价指标均较高, 说明所提方法对噪声鲁棒性强。随着噪声含量的增加, 分类指标下降最快

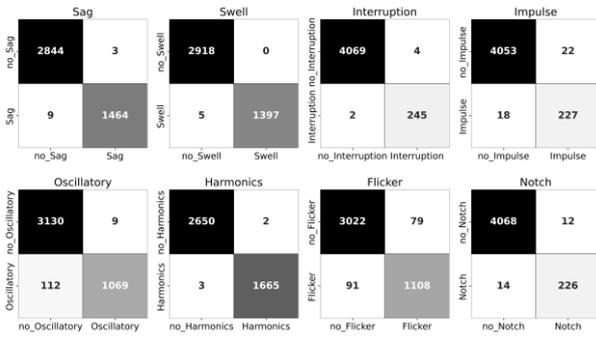


图 7 20 dB 信噪比混淆矩阵

Fig. 7 Confusion matrix with 20 dB SNR

表 5 信噪比为 30 dB 时的评价指标

Table 5 Evaluation index with 30 dB SNR

类型	准确率/%	召回率/%	F_1 -score/%
暂降	100	99.66	99.83
暂升	100	99.86	99.93
中断	99.80	100	99.40
脉冲	96.27	100	98.09
振荡	99.64	98.98	99.36
谐波	99.01	99.76	99.39
闪变	99.64	98.25	98.95
缺口	100	97.08	98.52
指标平均值	99.24	99.14	99.18

表 6 信噪比为 40 dB 时的评价指标

Table 6 Evaluation index with 40 dB SNR

类型	准确率/%	召回率/%	F_1 -score/%
暂降	100	99.72	99.86
暂升	100	99.85	99.92
中断	99.20	100	99.20
脉冲	97.05	100	98.50
振荡	100	99.74	99.87
谐波	99.88	100	99.94
闪变	99.91	99.33	99.62
缺口	100	97.91	98.94
指标平均值	99.50	99.44	99.48

表 7 无噪声时的评价指标

Table 7 Evaluation index without noise

类型	准确率/%	召回率/%	F_1 -score/%
暂降	100	99.79	99.89
暂升	100	100	100
中断	99.60	100	99.80
脉冲	97.07	100	98.51
振荡	100	99.75	99.87
谐波	99.94	100	99.97
闪变	99.92	99.92	99.92
缺口	100	97.92	98.94
指标平均值	99.56	99.67	99.61

的是“脉冲”, 这是因为噪声的加入会导致电能质量信号出现和脉冲类似的突变, 影响分类效果, 但所提方法仍保持较好的分类效果。

不同特征提取方法在多标签分类的准确率、召回率以及 F_1 -score 见图 8。

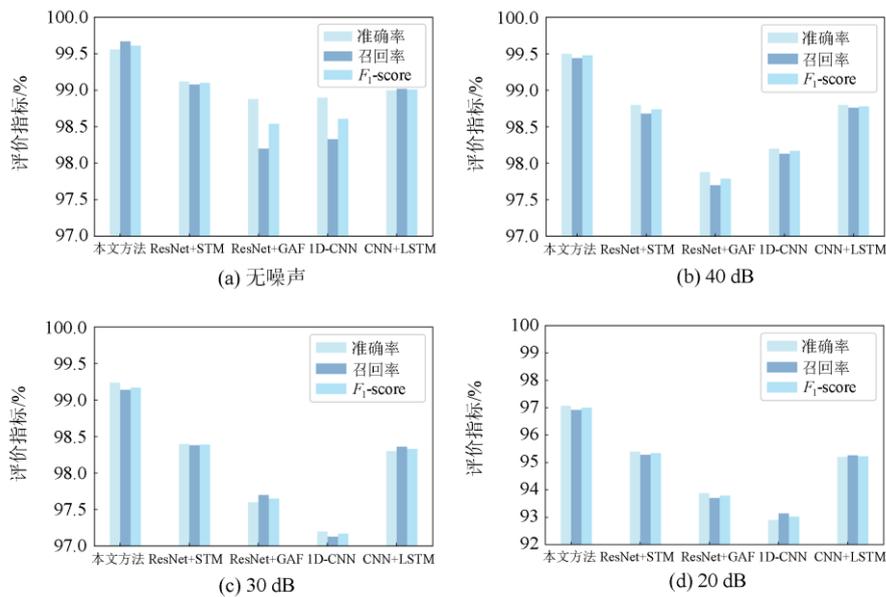


图 8 多标签分类结果对比

Fig. 8 Comparison of multi label classification results

图 8 中：4 种信噪比下所提方法平均分类准确率均高于其余方法，验证了 2D-ResNet 提取电能质量扰动信号的有效性以及其对噪声的鲁棒性；精确率与召回率相差较小，说明带权值二值交叉熵函数缓解了正负样本数量不平衡的影响。

4.4 单标签与多标签分类适应场景分析

多标签分类方法仅有 8 个标签，而单标签分类有 18 个标签，复合扰动的数量增加，标签数量随之增加，影响分类效果；实际中，单标签分类无法识别未知复合扰动，而多标签分类可以对单个标签一一识别。本节使用多标签分类对 100 条无噪声情况下的“谐波+暂升+脉冲+振荡”这一未知扰动进行识别，结果见表 8。

表 8 未知复合扰动多标签分类结果

Table 8 Multi-label classification results of unknown compound disturbance

标签	F_1 -score/%
谐波	97
暂升	100
脉冲	93
振荡	96

当出现“谐波+暂升+脉冲+振荡”扰动时，由于学习样本中不含此类扰动，单标签分类会将其分为“谐波+暂升+振荡”，而忽略“脉冲”成分，但多标签分类会逐个判断该信号中是否存在“谐波”、“暂升”、“脉冲”、“振荡”成分，如表 8 所示，多标签分类识别出该未知复合扰动中的未知成分“脉冲”，且 F_1 -score 达到 93%。因此，说明了单标签分类适用于单一扰动分类任务，多标签分类适用于未知复合扰动识别任务。

5 结论

为充分挖掘船舶电力系统电能质量扰动信号的时序特性，且避免手动进行特征提取，本文提出结合距离矩阵与二维残差网络的扰动识别方法。

仿真结果表明：无噪声时，单标签分类的平均准确率能达到 99.89%，比文献[9]与文献[23]方法的准确率分别高 1.3%、0.92%，多标签分类的平均 F_1 -score 能达到 99.56%；信噪比为 20 dB 时，单标签分类的平均准确率能达到 93.86%，比文献[9]与文献[23]方法的准确率分别高 5.11%、7.21%，多标签分类的平均 F_1 -score 能达到 96.52%；不同信噪比下，所提方法均具备较高的识别准确率，说明其能有效提取扰动特征，对噪声鲁棒性强；算例中，单标签分类未能识别出未知复合扰动，而多标签分类成功识别出扰动中的未知成分，且 F_1 -score 达到 93%。

故得出单标签分类适用于单一扰动分类任务，多标签分类适用于未知复合扰动识别的结论。

未来的研究主要围绕对船舶电力系统电能质量扰动分类的同时评估扰动程度，并考虑将所提方法与实际船舶电力系统电能质量扰动分析结合。

参考文献

- [1] 邱爱超, 袁成清, 孙玉伟, 等. 光伏渗透率对船舶光伏系统电能质量的影响[J]. 哈尔滨工程大学学报, 2018, 39(9): 1532-1538.
QIU Aichao, YUAN Chengqing, SUN Yuwei, et al. Impact of photovoltaic penetration factor on the power quality of the photovoltaic system of ships[J]. Journal of Harbin Engineering University, 2018, 39(9): 1532-1538.
- [2] 汪飞, 全晓庆, 任林涛. 电能质量扰动检测与识别方法研究综述[J]. 中国电机工程学报, 2021, 41(12): 4104-4121.
WANG Fei, QUAN Xiaoqing, REN Lintao. Review of power quality disturbance detection and identification methods[J]. Proceedings of the CSEE, 2021, 41(12): 4104-4121.
- [3] 黄建明, 瞿合祚, 李晓明. 基于短时傅里叶变换及其谱峭度的电能质量混合扰动分类[J]. 电网技术, 2016, 40(10): 3184-3191.
HUANG Jianming, QU Hezuo, LI Xiaoming. Classification for hybrid power quality disturbance based on STFT and its spectral kurtosis[J]. Power System Technology, 2016, 40(10): 3184-3191.
- [4] 郑成华, 张宁宁, 王向周. 基于提升小波和 Hilbert 变换的暂态电能质量检测[J]. 北京理工大学学报, 2019, 39(2): 162-168.
ZHENG Shuhua, ZHANG Ningning, WANG Xiangzhou. A lifting wavelet and Hilbert transform fusion method for transient power quality detection[J]. Transactions of Beijing Institute of Technology, 2019, 39(2): 162-168.
- [5] 杨晓梅, 郭林明, 肖先勇, 等. 基于可调品质因子小波变换和随机森林特征选择算法的电能质量复合扰动分类[J]. 电网技术, 2020, 44(8): 3014-3020.
YANG Xiaomei, GUO Linming, XIAO Xianyong, et al. Classification of multiple power quality disturbances based on TQWT and random forest feature selection algorithm[J]. Power System Technology, 2020, 44(8): 3014-3020.
- [6] 刘军, 黄纯, 江亚群, 等. 电能质量扰动分析中广义 S 变换算法的改进与实现[J]. 电力系统及其自动化学报, 2017, 29(3): 35-41.
LIU Jun, HUANG Chun, JIANG Yaqun, et al. Improved generalized S-transform algorithm for power quality disturbances analysis and its implementation[J]. Proceedings of the CSU-EPSA, 2017, 29(3): 35-41.

- [7] 田振果, 傅成华, 吴浩, 等. 基于 HHT 的电能质量扰动定位与分类[J]. 电力系统保护与控制, 2015, 43(16): 36-42.
TIAN Zhenguang, FU Chenghua, WU Hao, et al. Power quality disturbance for location and classification based on HHT[J]. Power System Protection and Control, 2015, 43(16): 36-42.
- [8] 徐长宝, 古庭赞, 高云鹏, 等. 基于改进小波阈值函数和变分模态分解的电能质量扰动检测[J]. 湖南大学学报(自然科学版), 2020, 47(6): 77-86.
XU Changbao, GU Tingyun, GAO Yunpeng, et al. Power quality disturbance detection based on improved wavelet threshold function and variational mode decomposition [J]. Journal of Hunan University (Natural Science Edition), 2020, 47(6): 77-86.
- [9] WANG Shouxiang, CHEN Haiwen. A novel deep learning method for the classification of power quality disturbances using deep convolutional neural network[J]. Applied Energy, 2019, 235.
- [10] 武昭旭, 杨岸, 祝龙记. 基于循环神经网络的电能质量扰动识别[J]. 电力系统保护与控制, 2020, 48(18): 88-94.
WU Zhaoxu, YANG An, ZHU Longji. Power quality disturbance recognition based on recurrent neural network[J]. Power System Protection and Control, 2020, 48(18): 88-94.
- [11] 王维博, 张斌, 曾文入, 等. 基于特征融合一维卷积神经网络的电能质量扰动分类[J]. 电力系统保护与控制, 2020, 48(6): 53-60.
WANG Weibo, ZHANG Bin, ZENG Wenru, et al. Power quality disturbance classification of one-dimensional convolutional neural networks based on feature fusion[J]. Power System Protection and Control, 2020, 48(6): 53-60.
- [12] LU J, TONG K Y. Robust single accelerometer-based activity recognition using modified recurrence plot[J]. IEEE Sensors Journal, 2019, 19(15): 6317-6324.
- [13] IGUAL R, MEDRANO C, ARCEGA F J, et al. Integral mathematical model of power quality disturbances[C] // 2018 18th International Conference on Harmonics and Quality of Power (ICHQP), May 13-16, 2018, Ljubljana, Slovenia: 1-6.
- [14] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA.
- [15] ZHAO M, KANG M, TANG B, et al. Deep residual networks with dynamically weighted wavelet coefficients for fault diagnosis of planetary gearboxes[J]. IEEE Transactions on Industrial Electronics, 2018, 65(5): 4290-4300.
- [16] GIRI E P, FANANY M I, ARYMURTHY A M, et al. Ischemic stroke identification based on EEG and EOG using ID convolutional neural network and batch normalization[C] // 2016 International Conference on Advanced Computer Science and Information Systems (ICACSIS), October 15-16, 2016, Malang, Indonesia: 484-491.
- [17] SCHMIDHUBER J. Deep learning in neural networks: an overview[J]. Neural Networks, 2015, 61: 85-117.
- [18] 靳果, 朱清智, 孟阳, 等. 基于多层极限学习机的电能质量扰动多标签分类算法[J]. 电力系统保护与控制, 2020, 48(8): 96-105.
JIN Guo, ZHU Qingzhi, MENG Yang, et al. Power quality disturbances multi-label classification algorithm based on a multi-layer extreme learning machine[J]. Power System Protection and Control, 2020, 48(8): 96-105.
- [19] WANG S, BI S, ZHANG Y. Locational detection of false data injection attack in smart grid: a multi-label classification approach[J]. IEEE Internet of Things Journal, 2020, 7(9): 8218-8227.
- [20] 赵小强, 宋昭漾. Adam 优化的 CNN 超分辨率重建[J]. 计算机科学与探索, 2019, 13(5): 858-865.
ZHAO Xiaoqiang, SONG Zhaoyang. Adam optimized CNN super-resolution reconstruction[J]. Journal of Frontiers of Computer Science and Technology, 2019, 13(5): 858-865.
- [21] GAL Y, GHAHRAMANI Z. A theoretically grounded application of dropout in recurrent neural networks[J]. Statistics, 2015, 1: 285-290.
- [22] 史东宇, 胡文强, 李刚, 等. 基于 t-SNE 的电力系统电气距离可视化方法研究[J]. 电力工程技术, 2018, 37(2): 78-82.
SHI Dongyu, HU Wenqiang, LI Gang, et al. Study on visualization method of electrical distance in power system using t-SNE[J]. Electric Power Engineering Technology, 2018, 37(2): 78-82.
- [23] 曹梦舟, 张艳. 基于卷积-长短期记忆网络的电能质量扰动分类[J]. 电力系统保护与控制, 2020, 48(2): 86-92.
CAO Mengzhou, ZHANG Yan. Classification for power quality disturbances based on CNN-LSTM network[J]. Power System Protection and Control, 2020, 48(2): 86-92.

收稿日期: 2021-08-03; 修回日期: 2021-10-15

作者简介:

宋铁维(1998—), 男, 通信作者, 硕士研究生, 研究方向为电力系统优化控制与故障检测; E-mail: 1262464910@qq.com

施伟锋(1963—), 男, 博士生导师, 研究方向为电力系统及其自动化。E-mail: wfshi@shmtu.edu.cn

(编辑 周金梅)