

# 基于混合神经网络的交直流混联电网 交流线路故障定位

陈伟哲<sup>1,2</sup>, 宋弘<sup>3</sup>, 吴浩<sup>1,2</sup>, 宋匡玮<sup>1,2</sup>, 田海鹏<sup>1,2</sup>, 漆梓渊<sup>1,2</sup>

(1. 四川轻化工大学自动化与信息工程学院, 四川 自贡 643000; 2. 人工智能四川省重点实验室, 四川 自贡 643000; 3. 阿坝师范学院, 四川 汶川 624000)

**摘要:**随着电网交直流混联程度的不断加深,复杂的电网结构导致故障的精确定位愈加困难。针对目前定位方法所存在问题,提出一种基于同步挤压小波变换结合混合神经网络的交直流混联电网交流线路故障定位方法。首先,对交流线路单端电压数据通过同步挤压小波变换处理后,提取其时频矩阵中部分低频区域的能量,构建特征向量;然后,将特征向量构建数据集,并输入至混合神经网络中进行训练与测试,实现故障定位。实验结果表明,所提方法有较高的定位精度与一定的抗噪性能,受不同故障类型与过渡电阻的影响较小。

**关键词:**交直流混联电网; 交流线路; 同步挤压小波变换; 神经网络; 故障定位

**中图分类号:** TM 773 **文献标志码:** A **文章编号:** 1003-6954(2024)05-0066-10

**DOI:** 10.16527/j.issn.1003-6954.20240510

## AC Line Fault Location for AC/DC Hybrid Power Grids Based on Hybrid Neural Networks

CHEN Weizhe<sup>1,2</sup>, SONG Hong<sup>3</sup>, WU Hao<sup>1,2</sup>, SONG Kuangwei<sup>1,2</sup>, TIAN Haipeng<sup>1,2</sup>, QI Ziyuan<sup>1,2</sup>

(1. School of Automation and Information Engineering, Sichuan University of Science & Engineering, Zigong 643000, Sichuan, China; 2. Artificial Intelligence Key Laboratory of Sichuan Province, Zigong 643000, Sichuan, China; 3. Aba Teachers College, Wenchuan 624000, Sichuan, China)

**Abstract:** With the increasing degree of mixing of AC/DC power grids, the complex grid structure makes it increasingly difficult to accurately locate the faults. Aiming at the problems of the current location methods, a fault location method for AC line of AC/DC hybrid power grid based on synchrosqueezing wavelet transform (SWT) combined with hybrid neural network is proposed. Firstly, the single-ended voltage data of AC line is processed by SWT, and then the energy of some low-frequency regions in the time-frequency matrix is extracted to construct feature vectors. Finally, the feature vectors are constructed as a data set, which is input to the hybrid neural network for training and testing to realize fault location. The experimental results show that the proposed method has high positioning accuracy and certain anti-noise performance, and is less affected by different fault types and transition resistances.

**Key words:** AC/DC hybrid power grid; AC line; synchrosqueezing wavelet transform; neural network; fault location

## 0 引言

随着大规模分布式能源接入电力网络,针对交

直流混联的复杂电网的故障定位技术面临新的挑战,研究一种快速准确可靠的电网故障定位方法能够加快故障修复速度,快速实现电网自愈,对智能电网的安全稳定运行有非常重要的意义<sup>[1]</sup>。

目前,故障定位领域的研究中主要使用行波法及其变种实现对各类线路的故障定位<sup>[2-3]</sup>,行波法主要分为单端法与双端法。通过计算波头到达终端的时间与波速结合起来计算故障距离,但由于该方法

**基金项目:**四川省科技厅项目(2022YFS0518, 2022ZHCG0035);人工智能四川省重点实验室项目(2023RY06);企业信息化与物联网测控技术四川省高校重点实验室项目(2022WYY04);四川轻化工大学研究生创新基金项目(Y2022122)

需计算行波波速,而行波波速易受到输电线路参数的影响,因此文献[2]提出了一种无须计算波速且不受输电线路垂弧影响的高压交流线路故障定位方法,通过计算连续两次行波波头到达两端的时间差实现故障定位;但该方法未能脱离利用小波分解提取故障波头的思路,且未就方法的抗噪性能进行研究。文献[3]针对 T 型输电线路提出一种能同时得到故障区域与故障位置的方法,通过建立故障支路判断矩阵确定故障支路后通过小波分解提取行波到达 3 个测量点的时间差实现故障定位,该方法不受行波波速与过渡电阻的影响,但仍需要通过小波分解提取故障波头。文献[4]针对超高压输电线路单相接地故障定位提出了通过故障点电压电流变化量推导回路方程,将其通过 R-L 模型转换至时域中;通过连续积分得到故障距离,该方法无须提取故障波头,且能解决相位不一致带来的误差,但仅能实现单相接地故障的故障定位,具有一定的局限性。虽然研究人员们对行波法或传统定位方法进行了多方面的改进,但目前的故障定位方法仍然存在行波波头难以确定,在实际工程中其定位精度易受到噪声干扰的影响等问题。另外,由于交直流混联电网故障线路波形特征是通过多个行波源波形叠加而成,故障特征混叠严重,导致特征提取出现困难,因此需要研究新的故障定位方法。

随着电网自动化程度的提高,各类自动化终端设备与先进的测量装置在交直流混联电网中得到了应用,为深度学习技术应用于复杂电网故障定位中提供了数据基础。而神经网络的回归机制又为利用神经网络实现输电线路的故障定位提供了思路。例如文献[5]通过长短时记忆神经网络(long short-term memory, LSTM)实现大型多机电力系统中的输电线路故障检测、诊断和定位;该方法利用 LSTM 实现故障诊断后,利用 LSTM 回归机制实现故障线路的各类故障的定位,但在面对三相接地故障时,其定位误差较大。文献[6]利用小波包能量熵提取故障特征,先通过深度置信网络(deep belief network, DBN)分类模型对各类特征波形划分为 4 类,再对每一类特征波形单独训练一个 DBN 回归模型,实现故障定位。文献[7]将卷积神经网络(convolutional neural network, CNN)与 LSTM 结合,首先通过最大平均差异(maximum mean discrepancy, MMD)对不同输电线路进行划分,然后利用双端 CNN-LSTM 结合

Q 学习实现不同类型输电线路的故障定位。上述文献都是先通过神经网络对特征进行划分后利用神经网络回归机制实现故障定位,而文献[8]利用 S 变换提取特征后,直接利用改进 1D-CNN-GRU 实现故障定位;该方法能够实现高压直流输电线路的各类故障的定位,无须提前进行划分故障类型。文献[9]直接将故障时间序列信号作为输入,利用双向门控递归单元(bi-directional gated recurrent unit, Bi-GRU)结合注意力机制实现故障定位,且受噪声影响较小。但目前还未有研究人员针对交直流混联电网交流线路故障定位进行研究,仅有文献[10]针对交直流混联电网直流系统故障提出了基于麻雀优化 CNN-LSTM 的故障定位方法,但该方法定位误差较大。

由于目前直流系统并没有充分参与进电力系统潮流和稳定控制中,而电力电子器件过载能力低,导致当单个交流线路发生简单故障时,直流线路容易出现换向失败、直流闭锁或重启等现象<sup>[11]</sup>,进一步影响交流线路故障波形特征,使得故障特征提取更加困难。因此,下面提出一种基于同步挤压小波变换结合改进 CNN-LSTM 的交直流混联电网交流线路故障定位方法。首先,利用克拉克变换对故障线路单端电压量解耦后,利用同步挤压小波变换对解耦后的 3 个分量进行处理后,提取部分能量作为特征,构成特征向量;然后,通过改进 CNN-LSTM 实现故障定位,并针对网络的改进设计了一种多尺度时间卷积模块替换原始网络单一的输入层,加入一种多重密集连接模块提取更深层次的特征;最后,通过引入 Ghost1D 模块实现网络轻量化。

## 1 交直流混联电网故障仿真模型

参考实际工程,在 PSCAD/EMTDC 中搭建了如图 1 所示的交直流混联电网故障仿真模型。其中各线路参数如表 1 所示。为了模拟实际运行中存在多种新能源并网运行的情况,将 G1 设置为双馈风电机组,以便对风力发电与传统火电并网运行情况进行模拟,直流线路换流器为 12 脉动晶闸管换流器。

为了验证所提故障定位模型的性能,选择在线路长度为 100 km 的线路 6 中设置包括单相接地故障、两相接地故障、两相相间短路故障、三相短路故障在内共 10 种故障情况,进行故障定位实验。

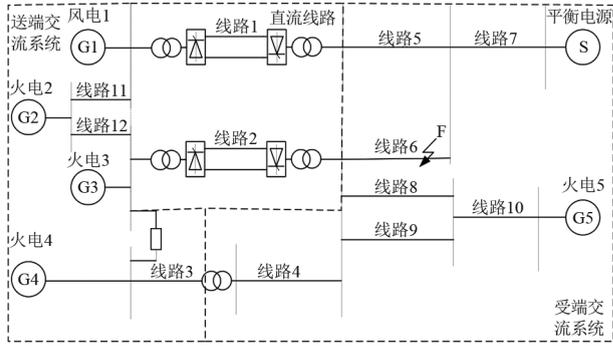


图 1 交直流混联电网拓扑

表 1 交直流混联电网参数

参数名称	参数值
送端交流系统额定电压/kV	345
受端交流系统额定电压/kV	230
交流线路正序负序阻抗/ $(\Omega \cdot \text{m}^{-1})$	$7.05 \times 10^{-5}$
交流线路正序负序电抗/ $(\Omega \cdot \text{m}^{-1})$	$4.0023 \times 10^{-4}$
交流线路正序负序容抗/ $(\text{M}\Omega \cdot \text{m})$	$3.7012 \times 10^2$
交流线路零序电阻/ $(\Omega \cdot \text{m}^{-1})$	$32.3 \times 10^{-5}$
交流线路零序电抗/ $(\Omega \cdot \text{m}^{-1})$	$1.2007 \times 10^{-3}$
交流线路零序容抗/ $(\text{M}\Omega \cdot \text{m})$	$5.2613 \times 10^2$
G2, G3 发电机容量/MVA	2000
G4, G5 发电机容量/MVA	500
额定直流电压/kV	500
额定直流电流/kA	2

## 2 基于 SWT 的特征提取方法

### 2.1 同步挤压小波变换原理

同步挤压小波变换 (synchrosqueezing wavelet transform, SWT) 能够实现信号的无损可逆变换, 具有计算速度快、抗噪抗频谱混叠能量较强的优点<sup>[12]</sup>。通过 SWT 从复合信号  $f(t)$  中提取特定频率分量  $f_k(t)$  的基本流程如下:

1) 选择 Morlet 小波作为母小波函数对  $f(t)$  进行连续小波变换。

$$W_f(a, b) = \int f(t) a^{-1/2} \psi\left(\frac{t-b}{a}\right) dt \quad (1)$$

式中:  $W_f(a, b)$  为连续小波系数;  $a$  为尺度因子, 对应频率信息;  $b$  为平移因子, 对应时间信息;  $\psi(t)$  为母小波函数。

2) 将  $f(t)$  划分为不同频率区间。

$$W_l = \left( \frac{\omega_{l-1} + \omega_l}{2}, \frac{\omega_l + \omega_{l+1}}{2} \right) \quad (2)$$

式中:  $W_l$  为连续小波变换计算得到的连续小波系数;  $\omega_l$  为第  $l$  个频率分量的中心频率。

对小波系数进行挤压, 得到同步挤压小波系数  $T_f(a, b)$  为

$$T_f(a, b) = \sum_{a_i \in [\omega_l - \omega_l < 0.5\Delta\omega]} R_{\psi}^{-1} a_i^{-1.5} W_f(a, b) \Delta a_i \quad (3)$$

式中:  $R_{\psi}^{-1} = \int_0^{+\infty} \varphi^*(\xi) \cdot d\xi/\xi$ , 即小波函数共轭傅里叶变换的积分形式,  $\varphi^*$  为小波函数共轭的傅氏变换;  $a_i^{-1.5}$  为尺度归一化因子;  $W_f(a, b)$  为连续小波变换计算得到的连续小波系数;  $\Delta a_i$  为离散化处理后的尺度步长。

3) 通过对第  $k$  个频率分量所对应的同步挤压小波变换  $T_f(a, b)$  进行反变换, 提取特定频率分量  $f_k(t)$ 。

$$f_k(t) = \frac{2}{R_{\psi}} \text{Re} \left[ \sum_{t \in X_k(t)} T_f(\omega_l, t) \Delta\omega \right] \quad (4)$$

式中:  $f_k(t)$  为第  $k$  个频率分量在时间  $t$  上的重构结果;  $\text{Re}(\cdot)$  为取实部;  $T_f(\omega_l, t)$  为同步挤压后的小波系数;  $\Delta\omega$  为频率步长。

SWT 将时间信号转换到时间频率面上, 通过挤压的方式将小波系数限制在中心频率附近, 使得时频能量更加集中, 各频率曲线不存在交叉项, 这使得其能有效避免频率混叠的现象。

### 2.2 故障信号特征提取方法

故障信号经过同步挤压小波变换后得到时间-频率相关矩阵。该矩阵中每行数据代表同一频率下的信号特征, 每列代表同一时间下的信号特征。但由于同步挤压小波变换后得到的时频矩阵中每个量都为复数, 需先对每个量求其绝对值后进行后续特征提取; 而其时频矩阵中信号的能量在一定程度上能够反映故障距离的特征<sup>[18]</sup>, 因此定义 SWT 时频矩阵中每个值的绝对值的平方来表征该值包含的能量, 选择提取 SWT 时频矩阵中各点数据的能量, 再对某特定频率分量  $f_k(t)$  求能量和, 如式(5)所示。

$$E_k = \sum_{at} \left| f_k(k, at) \right|^2 \quad (5)$$

式中:  $E_k$  为时频矩阵中第  $k$  行的能量和;  $\left| f_k(k, at) \right|^2$  为时频矩阵中第  $k$  行、时间为  $at$  处对应的能量。

因此, 信号经同步挤压小波变换后得到的能量序列为  $E = [E_1, E_2, \dots, E_n]$ 。

以图 1 所示交直流混联电网线路 6 出现故障为例,线路 6 总长 100 km,设置故障距离为 40 km,发生过渡电阻为 50 Ω 的 A 相接地故障,仿真时长为 1 s,故障发生时刻为 0.8 s,以 100 kHz 为采样频率,对故障前 1 ms 和故障后 3 ms(400 个采样点)的三相电压信号进行特征提取。考虑三相电压信号在发生故障时,各相电压信号会相互耦合,因此首先使用克拉克变换实现三相信号的解耦,通过式(6)求得三相信号的  $\alpha$ 、 $\beta$ 、0 模分量。

$$\begin{bmatrix} V_0 \\ V_\alpha \\ V_\beta \end{bmatrix} = \frac{1}{3} \begin{bmatrix} 1 & 1 & 1 \\ 2 & -1 & -1 \\ 0 & \sqrt{3} & \sqrt{3} \end{bmatrix} \begin{bmatrix} V_a \\ V_b \\ V_c \end{bmatrix} \quad (6)$$

式中: $V_0$ 、 $V_\alpha$ 、 $V_\beta$  分别为解耦后的  $\alpha$ 、 $\beta$ 、0 模分量; $V_a$ 、 $V_b$ 、 $V_c$  分别为 a、b、c 三相电压信号。

对解耦后三相信号的  $\alpha$ 、 $\beta$ 、0 模分量分别进行同步挤压小波变换,其中  $\alpha$  模分量经同步挤压小波变换得到的时频图如图 2 所示。

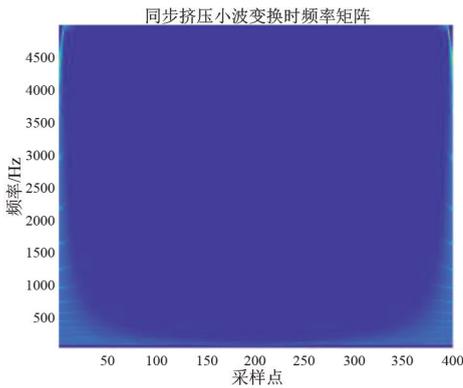
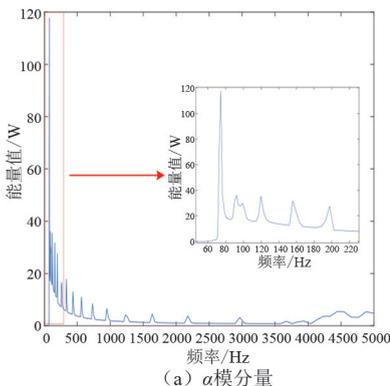


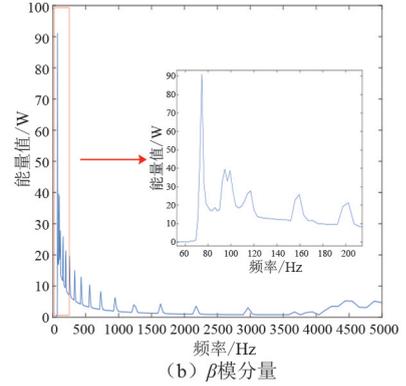
图 2  $\alpha$  模分量同步挤压小波变换时频矩阵

图 2 所示时频矩阵中包含大量与故障位置相关的信息,通过式(5)对  $\alpha$ 、 $\beta$ 、0 模分量对应的时频矩阵的各个频率下每行分量求取能量和作为能量特征,特征能量和随频率的分布情况如图 3 所示。

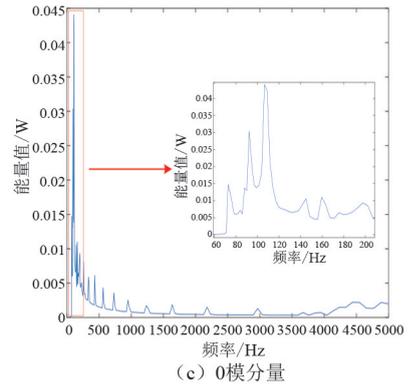
由图 3 可知,各模态分量经同步挤压小波变换后时频图的能量集中于低频区域,对应时频矩阵的



(a)  $\alpha$  模分量



(b)  $\beta$  模分量



(c) 0 模分量

图 3 各模态分量特征能量和频率曲线

41~90 行,矩阵行对应频率曲线如图 4 所示,所选取的低频区域的频率区间为 64.67~207.20 Hz。

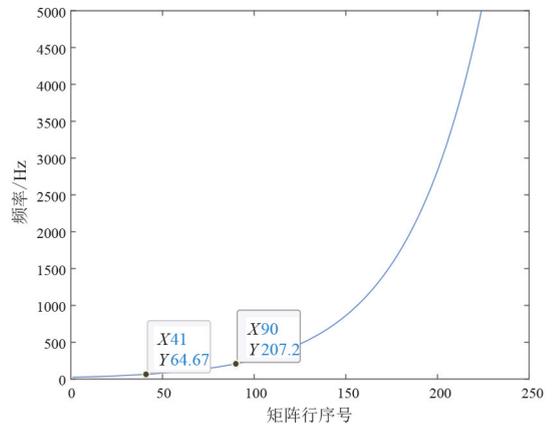


图 4 SWT 时频矩阵行对应频率曲线

因此选择该部分能量和来构建特征向量。特征向量构建方式如下:

1) 对采集到的单端电压信号通过克拉克变换解耦,得到  $\alpha$ 、 $\beta$ 、0 模分量。

2) 取 3 个分量故障前 1 ms 和故障后 3 ms 时间窗的数据,通过同步挤压小波变换后,由式(5)求取其时频矩阵 41~90 行对应的能量和  $E_\alpha$ 、 $E_\beta$ 、 $E_0$ ,其中  $E_\alpha = [E_{\alpha 41}, E_{\alpha 42}, E_{\alpha 43} \dots E_{\alpha 90}]$ ,  $E_\beta$ 、 $E_0$  同理。

3) 将  $\alpha$ 、 $\beta$ 、0 模分量对应  $E_\alpha$ 、 $E_\beta$ 、 $E_0$  组合,并经过 0~1 归一化后得到特征向量  $T = [E_0, E_\alpha, E_\beta]$ ,该特

征向量维度为  $150 \times 1$ 。

以故障位置距离送端 40 km、发生过渡电阻为  $50 \Omega$  的 A 相接地故障为例,将单端故障电压信号通过上述步骤求得故障特征向量,其故障特征向量如图 5 所示。

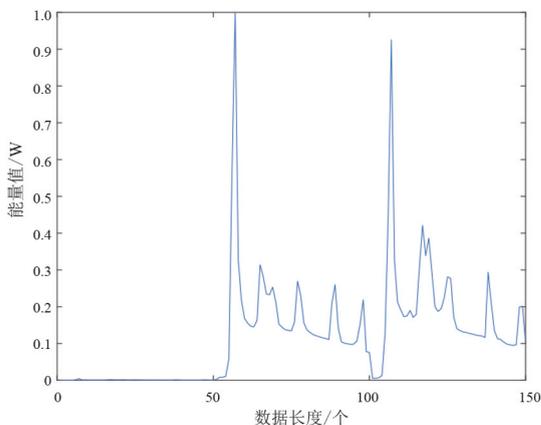


图 5 故障特征向量波形

从图 5 所示故障特征向量波形能够看出故障信号的能量分布特征较为明显。为了验证所提特征向量构建方法能够反映故障距离的变化,以故障距离为 20 km、40 km、60 km、80 km 4 种故障距离发生过渡电阻为  $1 \Omega$  的 A 相接地故障为例,展示不同故障距离下的特征向量波形,如图 6 所示。

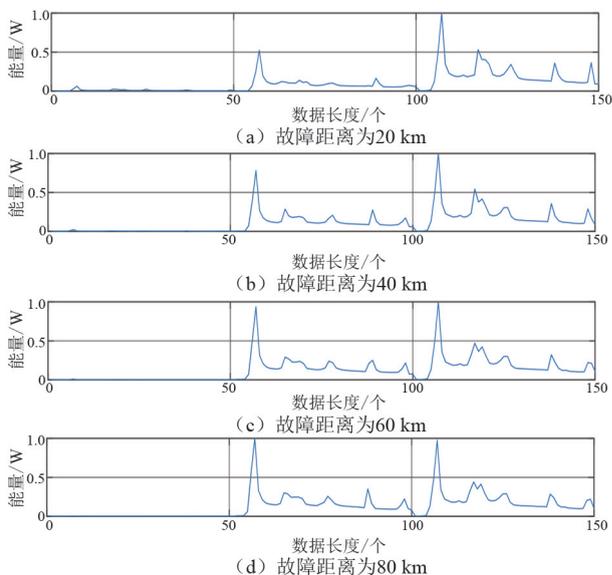


图 6 不同故障距离下特征向量波形

以故障距离为 40 km,发生过渡电阻为  $1 \Omega$ 、 $10 \Omega$ 、 $50 \Omega$ 、 $100 \Omega$ 、 $200 \Omega$  的 A 相接地故障为例,展示不同过渡电阻情况下的特征向量波形,如图 7 所示。

由图 6 可知,随之故障距离的变化,所构建的故障特征向量也随之变化,因此所提特征提取方式能够提取有关故障位置的信息。而由图 7 可知,当过

渡电阻小于等于  $200 \Omega$  时,过渡电阻的变化对特征向量的影响很小,因此不同过渡电阻对故障定位精度的影响较小。

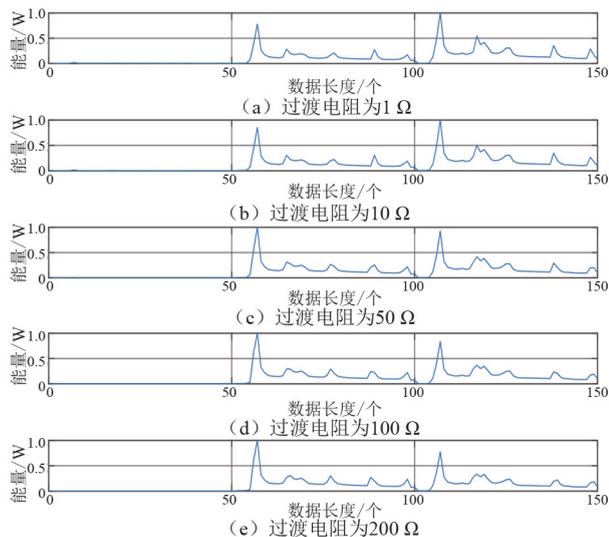


图 7 不同过渡电阻下特征向量波形

### 3 改进 CNN-LSTM 神经网络故障定位模型

为了提高 CNN-LSTM 定位模型准确度,对 CNN-LSTM 神经网络进行了改进。首先,提出了一种多尺度时间卷积模块作为对网络输入样本的初步特征提取,充分利用了不同时间尺度上的时间信息;然后,提出一种多重密集连接结构,能提取信号更深层次的特征;最后,利用 Ghost 模块实现网络轻量化后,利用 LSTM 回归机制实现对混联电网交流线路的故障定位。

#### 3.1 多尺度时间卷积模块

普通的卷积结构难以充分地提取信号特征信息<sup>[13]</sup>。为了充分利用不同时间尺度上的时间信息,使网络输入层提取的初始特征更加丰富,提出了一种多尺度时间卷积模块,如图 8 所示。

首先,使用两个  $1 \times 1$  卷积将输入特征降维为原来的一半;然后,使用  $1 \times 1$ 、 $3 \times 3$ 、 $5 \times 5$  的卷积提取左侧支路的时间特征信息,再将多尺度信息利用 concat 操作进行拼接后,由  $3 \times 3$  的卷积核进一步挖掘深层特征;最后,将两条支路特征进行拼接后作为输出。

#### 3.2 多重密集连接模块

DenseNet 是文献[14]提出的一种密集连接网

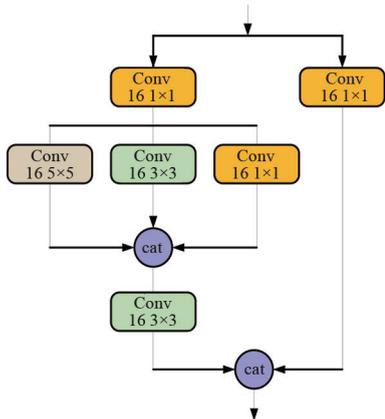


图 8 多尺度时间卷积层

络,通过多个 Dense 模块构成其网络基本结构。而 Dense 模块由多个卷积层利用密集连接构成,每个层都与前面所有层直接相连,密集连接的结构使得信息能够更好地传递和共享,增强了网络的特征表达能力。为了进一步提高 Dense 模块对深层故障距离信息的提取能力,设计了一种多重密集连接模块,通过将 4 个 Dense 模块再次利用密集连接的原理组合起来,以提取更深层次的信息,其结构如图 9 所示。

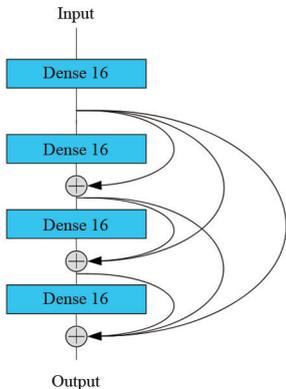


图 9 多重密集连接模块

3.3 Ghost 模块

Ghost 卷积模块是文献[15]于 2019 年提出的一种稀疏卷积层结构模块,通过利用部分传统卷积生成特征图以进一步生成 Ghost 特征图。由于卷积层的输出特征图会包含相似的冗余信息,而 Ghost 模块在去除这些冗余信息的同时,其特征提取能力也不会降低,Ghost 模块结构如图 10 所示。

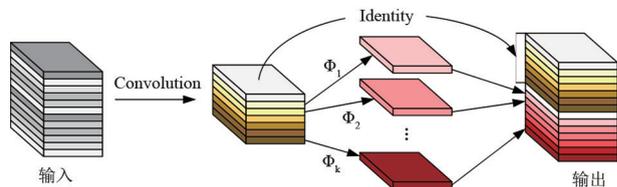


图 10 Ghost 模块结构

首先,通过普通卷积生成  $m$  个特征图,再通过分组线性运算得到  $n$  个 Ghost 特征图;最后,将各个特征图拼接起来输出  $m \times n$  个特征图。传统卷积参数数量为  $A_1$ ,而 Ghost 卷积参数数量为  $A_2$ ,通过式(7)计算可知,Ghost 卷积参数数量约为传统卷积计算量的  $1/n$ 。

$$\frac{A_1}{A_2} = \frac{m \cdot n \cdot c \cdot k \cdot k}{m \cdot c \cdot k \cdot k + (n - 1) \cdot m \cdot d \cdot d} \approx \frac{n \cdot c}{n + c - 1} \approx n \quad (7)$$

式中: $k$  为普通卷积核大小; $d$  为输入数据的空间维度; $c$  为输入数据的通道数。

由于原始 Ghost 模块通常运用于提取二维图像特征,使得改进模块中的卷积都是二维普通卷积,而这里所用特征为一维特征,因此需要将 Ghost 模块中的二维卷积替换为一维卷积,保持其他流程不变,以构成能够适用于一维信号的 Ghost 卷积,实现网络轻量化。

3.4 LSTM

LSTM 是循环神经网络(recurrent neural network, RNN)的一种变体,是针对 RNN 训练过程中易出现梯度消失与爆炸的现象所提出的神经网络<sup>[16]</sup>。LSTM 网络结构如图 11 所示。

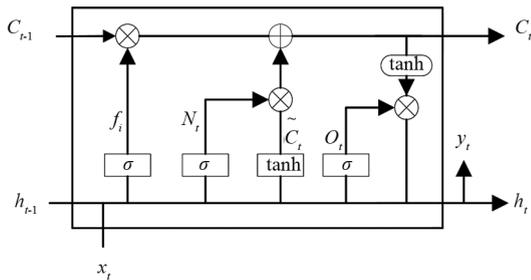


图 11 LSTM 结构

LSTM 主要由 3 个门组成,分别是遗忘门、输入门、输出门。图中: $\sigma$  为 sigmoid 激活函数; $x_t$  为  $t$  时刻的输入; $C_t$  为  $t$  时刻的细胞状态; $h_t$  为  $t$  时刻的输出。

3.5 改进 CNN-LSTM 神经网络模型

利用改进卷积神经网络进一步挖掘特征向量的隐性特征后,利用 LSTM 回归模型实现交直流混联电网交流线路的故障定位,并引入 Adam 优化器实现对梯度下降的优化,并利用梯度均值与梯度平方来决定权重的更新迭代。所提的改进 CNN-LSTM

神经网络结构如图 12 所示。

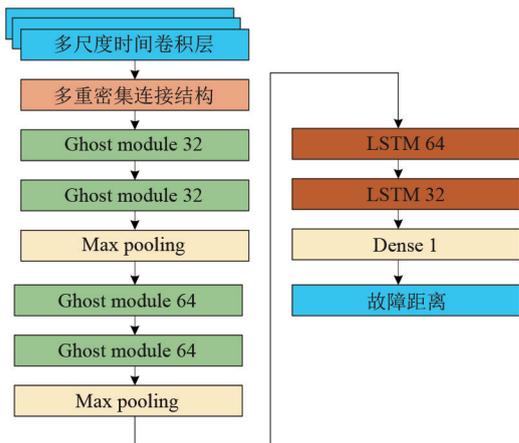


图 12 改进 CNN-LSTM 神经网络结构

## 4 基于同步挤压小波变换与 CNN-LSTM 的故障定位模型

### 4.1 故障定位流程

基于同步挤压小波变换与 CNN-LSTM 的故障定位流程如图 13 所示,具体流程如下:

- 1) 采集故障线路单端故障三相电压信号。
- 2) 利用克拉克变换对故障三相电压解耦,得到故障电压  $\alpha$ 、 $\beta$ 、0 模分量。
- 3) 对故障电压  $\alpha$ 、 $\beta$ 、0 模分量分别通过同步挤压小波变换并求其时频矩阵某频率区间内的能量和后,组合并归一化至 0~1 区间内得到特征向量。

4) 对不同故障距离的多种故障情况下的故障电压原始数据通过步骤 1~3 处理后,构建数据集;并以 1:9 的比例划分验证集与训练集,将验证集与训练集中未包含的故障情况作为测试集。

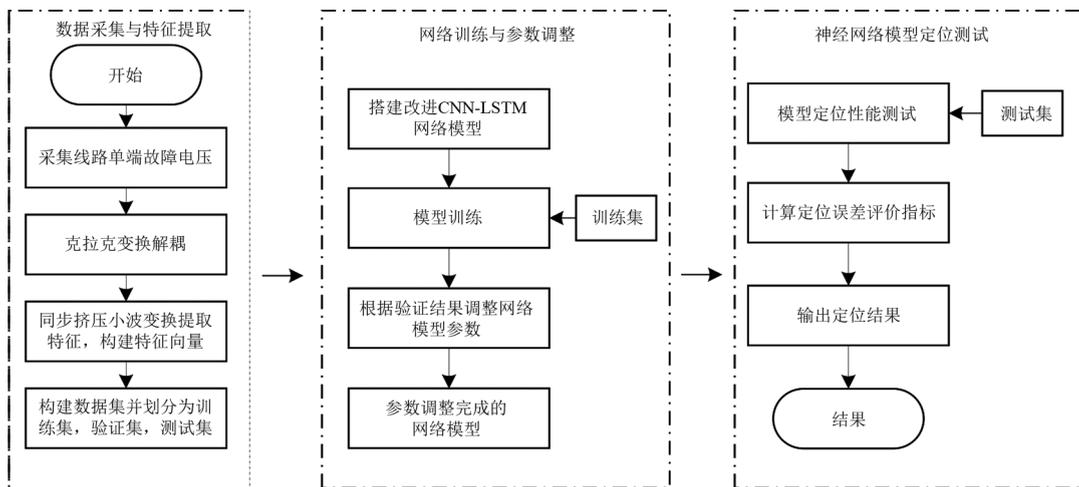


图 13 基于同步挤压小波变换与改进 CNN-LSTM 的故障定位流程

5) 改进 CNN-LSTM 神经网络模型训练与验证,利用 LSTM 回归模型实现故障定位,并微调模型参数。

6) 利用测试集对训练好的网络进行测试,计算多个评价指标,输出定位结果。

### 4.2 评价指标

通过神经网络的回归机制实现故障定位,因此需要多个评价指标来评价网络回归效果的优良与否,因此选择决定系数  $R^2$  来评估模型对数据的拟合程度,其表达式如式(8)所示;选择均方误差  $M_{SE}$  作为损失函数,其表达式如式(9)所示;选择平均绝对误差  $M_{AE}$  来评估定位结果的误差值,其表达式如式(10)所示。

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (8)$$

$$M_{SE} = \frac{1}{n} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (9)$$

$$M_{AE} = \frac{1}{n} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (10)$$

式中: $y_i$ 为实际故障距离; $\hat{y}_i$ 为预测故障距离; $\bar{y}$ 为故障距离的平均值。

## 5 网络测试与定位实验结果

### 5.1 网络收敛性验证

依据图 1 所示交直流混联电网进行实验,以线路 6 为故障线路,以 100 kHz 为采样频率,线路 6 长度为 100 km,为了使样本中包含的不同故障距离信息更加丰富,从故障线路首端 3 km 处为起点,以

1 km 为步长,直到 97 km 处截止,设置发生故障类型包括单相接地 (AG, BG, CG)、两相接地故障 (ABG, ACG, BCG)、两相相间短路故障 (AB, AB, BC)、三相短路故障 (ABC),过渡电阻为 1 Ω、10 Ω、50 Ω、100 Ω、200 Ω,共有 4750 组故障样本。

将样本集以 9 : 1 的比例划分为训练集与验证集,通过改进 CNN-LSTM 神经网络进行训练与验证,设置网络训练 epoch 为 200, batchsize 为 32,学习率为 0.000 1。经过 200 次训练后得到如图 14 所示的网络损失曲线图。

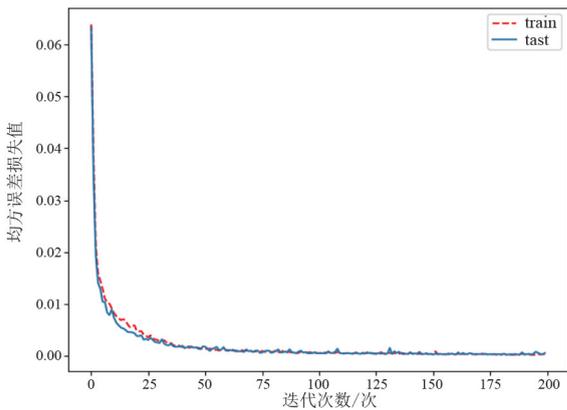


图 14 网络损失曲线

分析图 14 可知,网络训练过程中,训练 40 轮左右网络基本收敛,训练至最终 200 轮时均方误差损失值接近  $2 \times 10^{-4}$ ,因此所提网络具有较好的收敛速度与收敛性。

## 5.2 故障定位结果与性能分析

### 5.2.1 故障定位结果

所提网络模型经过 200 次训练后,验证集的决定系数  $R^2$  为 0.999 1,平均绝对误差为 0.068%,从验证集结果来看网络训练效果较好。

由于验证集中样本是在 4750 组故障样本中随机挑选 10%组成的,剩余 90%为训练集,因此验证集定位结果不能完全表征所提算法定位结果,需要利用不同故障位置发生其他过渡电阻的故障信息对训练好的网络进行定位测试。

测试集中样本组成如下:以故障位置在 10 km、40 km、70 km 处为不同故障距离,对应线路全长的 10%、40%、70%处,每个故障位置发生共 10 种故障,以 20 Ω 与 150 Ω 为过渡电阻,一共 60 组故障样本。将测试集输入至训练好的网络中进行测试,得到的测试集的定位结果如图 15 所示,测试集定位结果与实际故障位置的平均绝对误差为 0.235%,即平

均定位误差为 235 m,具有较高的定位精度。

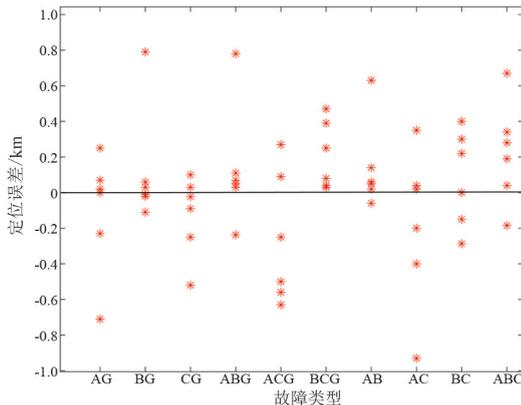


图 15 测试集定位结果

图 15 中展示了不同故障类型下的测试集定位结果,其中最大误差出现于 AC 相间短路故障中的一个样本,定位误差达到 0.903 km,小于 1 km,因此所提算法能够有效定位交流线路的多种故障情况,无须提前对故障类型进行划分,且受过渡电阻干扰较小。

### 5.2.2 定位模型抗噪性能分析

考虑到实际电网运行中存在噪声干扰的影响,因此验证算法的抗噪能力尤为重要<sup>[17]</sup>。电网故障信息在通过同步相量测量装置传输到调度室的过程中,很容易受到周边电子设备的噪声干扰,这类噪声通常呈正态分布,与高斯白噪声相似,因此选择在测试样本原始数据中添加信噪比为 35~50 dB 的高斯白噪声,以模拟实际情况下的噪声干扰现象。所提算法在不同噪声干扰下的定位结果如表 2 所示。

表 2 网络在不同噪声干扰的定位结果

附加噪声信噪比/dB	模型定位平均绝对误差/%	模型最大定位误差/%
50	0.156	0.747
45	0.135	0.780
40	0.305	0.807
35	2.492	7.362

分析表 2 定位结果可知,所提定位算法在附加噪声信噪比高于 40 dB 时具有较高的定位准确率,定位平均误差均小于 0.305%,对应故障定位平均误差小于 305 m,且最大定位误差小于 1 km,但在面对噪声干扰较大时(低于 40 dB),定位误差较大,因此该算法具有一定的抗噪性,达到 40 dB。

### 5.2.3 不同模型定位结果分析

将所提的改进 CNN-LSTM 故障定位与其他定

位模型进行对比,对比网络模型包括支持向量机 (support vector machine, SVM)、径向基神经网络 (radial basis function neural network, RBF)、RNN、CNN、Tansformer 与 CNN-GRU 神经网络模型。采用相同的训练集与验证集对网络进行训练与验证,并通过无噪声情况下的相同测试集进行测试,以验证集定位结果的平均绝对误差与测试集定位结果的平均绝对误差为评价指标,得到不同网络验证集定位结果与测试集定位结果如表 3 与图 14 所示。

表 3 不同神经网络模型定位结果对比表

网络模型	验证集平均绝对误差/%	测试集平均绝对误差/%
SVM	0.944	1.347
RBF	0.586	0.987
RNN	1.707	2.349
CNN	0.276	0.861
Tansformer	0.092	0.459
CNN-GRU	0.087	0.654
所提网络模型	0.068	0.235

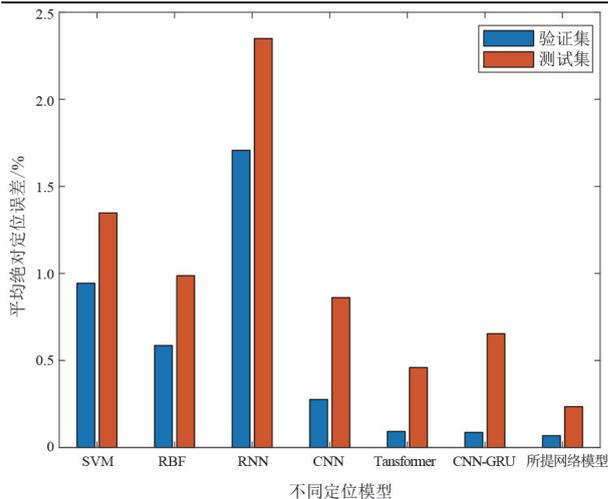


图 16 不同神经网络模型定位结果对比

分析表 3 和图 16 可知,所提的交直流混联电网交流线路故障定位模型在 7 种故障定位模型中有最高的定位精度。其中 Transformer 与 CNN-GRU 尽管在验证集的平均绝对误差较小,但在利用测试集进行测试的过程中会出现较大的误差,而所提网络模型无论是在验证集与测试集均有最好的定位精度。

## 6 结 论

针对交直流混联电网交流线路故障易受直流线路复合故障的影响,导致定位困难的问题,

上面提出一种基于同步挤压小波变换结合改进 CNN-LSTM 的混联电网交流线路故障定位方法,该模型具有较好的收敛速度,对故障距离的拟合程度达到 99.91%,测试集定位结果平均绝对误差为 0.235%,得出了以下结论:

1) 所提算法具有一定的抗噪性,达到 40 dB,可考虑在数据预处理中添加去噪算法进行处理,提高抗噪性能。

2) 所提算法在面对混联电网交流线路发生不同过渡电阻、不同类型的故障,能够实现较为精确的故障定位,其定位精度受过渡电阻与故障类型的影响较小。

3) 相较于传统智能定位方法中的浅层神经网络与目前常用于回归预测的部分深度神经网络,所提改进 CNN-LSTM 具有更好的定位精度。但由于所提方法需要进行神经网络训练,因此对故障信号的要求较高,且由于实际电网故障数据难以获得,需要搭建符合实际电网参数的电网仿真模型以获取大量故障样本数据。当定位对象发生变化时,同样需要通过建模来获取故障数据,并通过网络训练与测试实现故障定位。因此所提方法的精确性与适用性在一定程度上受到不同电网结构的影响。

4) 所提算法无须提取故障波头即可实现故障定位,避免了由于线路参数与其他干扰造成的故障波头难以提取的问题。

## 参考文献

- [1] 李泽文,曾祥君,夏翊翔,等.高压交流输电线路故障行波定位技术综述[J].长沙理工大学学报(自然科学版),2022,19(3):104-121.
- [2] 余泽轩,帕孜来·马合木提.基于改进双端法的高压交流输电线路故障定位[J].光电子·激光,2021,32(10):1099-1104.
- [3] 崔超奇,王占山,杨东升,等.一种不受波速影响的 T 型输电线路故障定位方法[J].电测与仪表,2017,54(18):15-21.
- [4] 李跃,郑涛,文安.基于单端量的超高压交流输电线路单相接地故障测距方法研究[J].电力系统保护与控制,2020,48(6):27-33.
- [5] BELAGOUNE S, BALI N, BAKDI A, et al. Deep learning through LSTM classification and regression for transmission

line fault detection, diagnosis and location in large-scale multi-machine power systems [ J ]. Measurement, 2021, 177:109330.

[ 6 ] 叶鑫杰,兰生,肖思捷,等.基于小波包能量熵和 DBN 的 MMC-HVDC 输电线路单极接地故障定位方法[ J ].南方电网技术,2021,15( 2 ):82-91.

[ 7 ] WANG X H, ZHOU P, PENG X G, et al. Fault location of transmission line based on CNN-LSTM double-ended combined model[ J ].Energy Reports,2022,8(S5):781-791.

[ 8 ] 杨玉萍,吴浩,田海鹏等.高压直流输电线路单端智能故障定位方法[ J ].电力系统及其自动化学报,2023,35(9):120-129.

[ 9 ] ZHANG F, LIU Q Y, LIU Y L, et al. Novel fault location method for power systems based on attention mechanism and double structure GRU neural network [ J ]. IEEE Access,2020,8:75237-75248.

[ 10 ] 张晓炜. 基于深度学习的混合直流系统故障诊断方法研究[ D ].北京:北京交通大学,2022.

[ 11 ] 董新洲,汤涌,卜广全,等.大型交直流混联电网安全运行面临的问题与挑战[ J ].中国电机工程学报,2019,39( 11 ):3107-3119.

[ 12 ] 段建东,李浩,雷阳,等.利用同步挤压小波变换的高压交直流混联系统交流线路暂态方向保护[ J ].中国电机工程学报,2019,39( 13 ):3833-3842.

[ 13 ] 卞景艺,刘秀丽,徐小力,等.基于多尺度深度卷积

神经网络的故障诊断方法[ J ].振动与冲击,2021,40( 18 ):204-211.

[ 14 ] LANDOLA F, MOSKEWICZ M, KARAYEV S, et al. Densenet: Implementing efficient convnet descriptor pyramids[ R/OL ].[ 2023-05-09 ].DOI:10.48550/arXiv.1404.1869.

[ 15 ] HAN Kai,WANG Yunhe,TIAN Qi, et al. GhostNet: more features from cheap operations [ C ]//IEEE/CVF Conference on Computer Vision and Pattern Recognition ( CVPR ),June 13-19,2020,Seattle,USA. IEEE,2020:1577-1586.

[ 16 ] GREFF K, SRIVASTAVA R K, KOUTNIK J, et al. LSTM: a search space odyssey[ J ]. IEEE Transactions on Neural Networks and Learning Systems, 2017, 28(10):2222-2232.

[ 17 ] 邵庆祝,谢民,王同文,等.基于深度随机配置网络的电网故障诊断方法[ J ].控制工程,2022,29( 12 ):2213-2220.

作者简介:

陈伟哲(1999),男,硕士研究生,研究方向为交直流混联电网故障诊断;

宋弘(1973),男,硕士,教授,研究方向为电力系统故障诊断;

吴浩(1980),男,博士,教授,研究方向为电力系统保护与控制。(收稿日期:2023-11-07)

(上接第 65 页)

[ 9 ] 陈祉如,郭亮,杜艳,等.基于改进层次分析法的电能计量系统综合评价[ J ].山东大学学报(工学版),2022,52( 6 ):167-175.

[ 10 ] 云玉新,赵富强,张磊,等.结合相关系数及改进层次分析法的油浸式变压器质量评估[ J ].重庆理工大学学报(自然科学),2022,36( 5 ):203-210.

[ 11 ] 沙金,郑斯斯.基于改进层次分析法的工程教育认证课程毕业要求达成度评价[ J ].大众科技,2022,24( 2 ):129-132.

[ 12 ] 熊文祥,陈永刚.基于集对可拓和改进层次分析法的铁路通信系统安全评估[ J ].计算机系统应用,2022,31( 2 ):285-290.

[ 13 ] 孟建佛,王双银,张静怡,等.基于改进层次分析法的小水电生态环境影响评价[ J ].水利与建筑工程学报,2022,20( 1 ):103-107.

[ 14 ] 李银久,李秋华,焦树林.基于改进层次分析法、CRITIC 法与复合模糊物元 VIKOR 模型的河流健康评价[ J ].

生态学杂志,2022,41( 4 ):822-832.

[ 15 ] 王晓天,张英华,秦挺鑫,等.基于熵值法改进层次分析法马拉松急救能力评价模型的构建[ J ].中国安全生产科学技术,2021,17( 9 ):169-174.

[ 16 ] 周恩泽,黄勇,向淳,等.基于物元可拓的输电线路山火风险评估模型[ J ].南方电网技术,2022,16( 1 ):145-154.

作者简介:

周林(1971),男,高级工程师,从事输变电工程技术管理工作;

彭宇辉(1972),男,高级工程师,从事输变电工程建设和运行管理工作;

刘晔(1989),女,高级工程师,从事输变电信息化项目建设管理和运行维护工作;

任成君(1987),男,高级工程师,从事输变电设备技术管理工作;

孙文成(1985),男,高级工程师,从事输变电工程建设和运行管理工作。

(收稿日期:2023-11-03)