

# 基于并联 CNN-LSTM 的弱受端直流输电系统故障诊断

陈臣鹏, 陈仕龙, 毕贵红, 高敬业, 赵鑫, 李璐  
(昆明理工大学 电力工程学院, 云南 昆明 650500)

**摘要:** 现有的故障诊断手段面对复杂电网时,难以精确提取故障特征,急需适应性强、识别率高的故障诊断方法。鉴于此,提出一种基于压缩感知与并联卷积神经网络(CNN)和长短期记忆网络(LSTM)结合的电网故障诊断方法。搭建永富直流输电系统模型采集原始故障数据,原始故障数据应用压缩感知原理进行压缩采样,获得压缩域故障信号,以提高网络的计算效率。然后搭建了麻雀搜索算法(SSA)优化的并联 CNN-LSTM 深度学习模型。通过 SSA 确定并联 CNN-LSTM 的网络结构及参数,利用并联 CNN-LSTM 深度学习模型直接在故障的压缩域挖掘故障波形特征和时序特征,并对故障进行识别。仿真结果表明该模型相较于传统方法具有更高的故障诊断精度。

**关键词:** 弱受端直流输电系统; 故障诊断; 并联卷积神经网络(CNN); 长短期记忆网络(LSTM); 麻雀搜索算法(SSA)

中图分类号: TM721.1 文献标志码: A 文章编号: 1673-6540(2022)06-0083-09

doi: 10.12177/emca.2022.022

## Fault Diagnosis of Weak Receiving DC Transmission System Based on Parallel CNN-LSTM

CHEN Chenpeng, CHEN Shilong, BI Guihong, GAO Jingye, ZHAO Xin, LI Lu  
(School of Electric Power Engineering, Kunming University of Science and Technology,  
Kunming 650500, China)

**Abstract:** The traditional fault diagnosis methods have difficulty in accurately extracting fault characteristics in the case of complex power grids, and the fault diagnosis methods with high adaptability and recognition rates are urgently needed. A power grid fault diagnosis method based on the combination of compressed sensing, parallel convolutional neural network (CNN) and long short-term memory (LSTM) is proposed. A model of Yongfu DC transmission system is built to collect raw fault data, and the raw fault data are compressed and sampled by applying the principle of compressed sensing to obtain compressed domain fault signals to improve the computational efficiency of the network. Then, a parallel CNN-LSTM deep learning model with sparrow search algorithm (SSA) is built. The network structure and parameters of the parallel CNN-LSTM are determined by the SSA. The parallel CNN-LSTM deep learning model is used to mine the fault waveform and timing features directly in the compressed domain of the fault and identify the fault. The simulation results verify that the model has higher fault diagnosis accuracy compared with the traditional methods.

**Key words:** weak receiving DC transmission system; fault diagnosis; parallel convolutional neural network (CNN); long short-term memory (LSTM); sparrow search algorithm (SSA)

收稿日期: 2022-03-22; 收到修改稿日期: 2022-04-29

作者简介: 陈臣鹏(1996—),男,硕士研究生,研究方向为多端混合直流输电与深度学习。

李璐(1976—),女,博士,研究方向为高压直流输电、电力市场机制和可再生能源政策。(通信作者)

## 0 引言

永富直流输电系统是我国近期建成的省内直流输电系统<sup>[1]</sup>,因其逆变侧电源较弱为弱交流系统,若不及时清除受端交流系统发生的故障,会打破换流站的无功功率平衡,继而导致换相失败,连续的换相失败可能会造成输送功率中断,进而导致潮流大规模转移到交流线路,严重危害系统的安全。输电线路则是高压直流输电系统的另一重要组成部分,因其输电距离远,运行环境恶劣,故障发生概率高。在弱受端直流输电系统中,逆变侧交流系统故障与直流线路故障引起的电压跌落,信号变化十分相似,难以区分,若不加以区分将严重危害系统安全。因此,正确地诊断出交流系统故障和直流线路故障对提升弱受端直流输电系统的安全稳定至关重要<sup>[2]</sup>。

高压直流输电系统故障涵盖了海量的故障数据,故障诊断需要从诸多电气量中快速分析出故障关联特征,准确判断出故障类型。传统的故障诊断通常基于人工信号处理提取故障特征,利用小波分解、经验模态分解(EMD)和变分模态分解(VMD)等技术对原始信号进行求解分析。文献[3]首先分析了故障电压反行波在线路上的传播特征差异,其次利用小波变换提取高频电压反行波特征,从而诊断出直流电网输电线路的区内外故障。文献[4]采用经验模态分解与分形理论关联维数相结合的方法进行电压信号故障分析及特征量提取,结合极限学习机,实现高压输电线路不同故障类型诊断。

上述方法中的信号分析方法、特征提取方法、故障诊断模型的选择均缺乏适应性和通用性。对于日趋复杂化的高压直流输电系统而言,摆脱理论分析和人工提取各电气量故障特征的过程是十分关键的。深度学习为故障诊断提供了新的途径,摒弃人工提取故障信号特征的过程,利用深度学习精确挖掘海量数据中的深层抽象特征<sup>[5-6]</sup>。

文献[7]利用卷积神经网络(CNN)提取交直流输电系统原始故障特征,通过人工逐步调整模型结构,实现故障分类诊断。文献[8]利用长短期记忆网络(LSTM)捕捉和提取故障前后的复杂时序特征,构建电网故障诊断模型,确定故障时刻和故障区域。上述方法将信号分析的方法与深度

学习结合,能够有效完成故障诊断任务。可以看出,深度学习方法能够迅速准确地提取数据中隐含的深层特征<sup>[9]</sup>,非常适合用于数据量大且复杂的高压直流输电系统故障诊断。

运用压缩感知(CS)理论可以提高模型的诊断效率,压缩感知理论可以利用采样点较少的压缩信号通过非线性重建算法完美地重建原始信号<sup>[10-12]</sup>,压缩信号在压缩域中能反映原始信号的整体特性。文献[13]用压缩感知原理获得采样点较少的压缩信号,实现基于压缩信号的直流电网故障准确定位。文献[14]运用贝叶斯压缩感知理论,求解高频瞬态电流压缩信号,利用所求压缩信号取得较高的故障定位准确性。

综合以上算法,本文提出一种基于压缩感知、麻雀搜索算法(SSA)和并联CNN-LSTM相结合(CS-SSA-CNN-LSTM)的弱受端直流输电系统故障诊断方法,主要对永富高压直流输电系统中的直流线路单相接地、交流系统单相接地、两相接地和三相接地四种故障类型进行诊断,旨在作为常规故障诊断方法的补充。模型舍弃了信号分析法人工选取特征的繁杂过程,首先搭建永富仿真模型采集原始数据,将原始数据应用压缩感知原理压缩采样,在压缩域中直接提取故障特征和识别,可以提高网络的计算效率。随后直接利用并联CNN提取压缩域中数据的深层抽象特征,并联的不同尺寸的卷积核可以提取不同尺度的波形特征。进一步利用LSTM提取其故障波形的时序特征。最后通过SSA确定并联CNN-LSTM的模型结构及参数,完成故障特征的学习和故障类型的识别。试验表明,该模型有自适应选择参数能力和优秀的特征提取能力,可以处理交直流输电系统中的复杂多维特征,能够准确可靠地诊断出故障类型,在故障诊断领域具有较好的适用性。

## 1 算法与优化原理

### 1.1 压缩感知原理

压缩感知是将原始信号亚采样压缩后,根据压缩信号利用重构算法得到恢复信号的过程。压缩感知的过程中, $\mathbf{x}$ 为 $N$ 维原始信号, $\mathbf{x}$ 本身不稀疏,但在某一变换域 $\psi$ 下是一个 $k$ 稀疏的向量<sup>[15]</sup>,表示为

$$\mathbf{x} = \psi \mathbf{s} \quad (1)$$

式中： $s$  为  $x$  在变换域  $\psi$  下的稀疏信号，除了  $k$  个非零值以外，其余值均为零或接近零。

将  $N$  维原始信号  $x$  通过观测矩阵  $\phi$  投影到  $M$  ( $M \ll N$ ) 维上，得到观测信号  $y$ ，表示为

$$y = \phi x = \phi \psi s = \theta s \quad (2)$$

式中： $y$  为  $M$  维观测信号； $\phi$  为  $M \times N$  维测量矩阵， $\theta = \phi \psi$  为传感矩阵<sup>[16]</sup>。

为了保证观测时不丢失信息，传感矩阵  $\theta$  应满足有限等距约束 (RIP) 条件。传感矩阵  $\theta$  满足 RIP 另一个等价条件是稀疏矩阵  $\psi$  和测量矩阵  $\phi$  不相关，所以运用与稀疏矩阵  $\psi$  不相关的测量矩阵  $\phi$  对原始信号进行压缩观测时，即可通过稀疏信号  $s$  对原始信号  $x$  进行重构恢复<sup>[17]</sup>。

而独立同分布的高斯随机矩阵与其他矩阵一般不相关，故选择一个  $M \times N$  独立同分布的高斯矩阵作为观测矩阵  $\phi$  即可满足 RIP 条件。在离散余弦变换域 (DCT) 对稀疏基  $\psi$  进行构建，为稀疏基  $\psi$  分配  $N \times N$  空间，再将长度为  $N$  的 DCT 系数进行逆离散余弦变换，获得其对应于  $x$  的分布，即获得了  $N \times N$  的稀疏基矩阵  $\psi$ 。在弱受端直流输电系统中，存在大量监测设备信号及高频复杂信号。压缩信号在大幅度减小测量数的前提下保留着原始数据的特征，有利于压缩感知理论在各类型复杂数据上的应用。

### 1.2 CNN 原理

CNN 由于其强大的空间特征提取能力，广泛应用于图像识别领域。典型的卷积神经网络结构如图 1 所示，包含输入层、卷积层、池化层、全连接层和输出层<sup>[18]</sup>。




图 1 CNN 的结构

卷积层通过卷积核遍历输入矩阵进行内积运算，提取输入矩阵的故障特征。卷积核的大小与提取的故障特征有着较强关联，较大的卷积核可以提高卷积层提取特征的效率；较小的卷积核能够提取到更精细的特征<sup>[19]</sup>。

池化层可以降低故障特征图的尺寸，从而减小模型参数规模。一般使用最大池化或平均池

化，将感知域中的值合并为单个值，即最大值或平均值。这在一定程度上减小了数据的计算量，减轻了模型的过拟合现象<sup>[20]</sup>。

全连接层首先整合卷积层和池化层提取的特征，将网络末端的池化层展开成一维向量，再把该向量作为输入，最后建立该向量与最终输出之间的全连接网络。

CNN 能够挖掘不同图像之间的潜在差别，也常用于诊断图像类的故障数据。弱受端直流输电系统的故障诊断就是判断输入数据的故障性质，故障类别主要包括直流线路故障和交流系统故障。显然故障诊断是一个多分类问题，适合利用 CNN 对故障数据进行空间特征提取。

### 1.3 LSTM 原理

长短期记忆网络 LSTM 是循环神经网络 (RNN) 的其中一种。隐含层的输入同时包括了输入层的输出和上一时刻隐含层的输出。利用这种结构，网络对过去的的数据产生记忆状态，并建立不同时段故障数据之间的依赖关系，因此能更好地处理时间序列问题<sup>[21-24]</sup>。LSTM 的结构如图 2 所示。参数更新的数学表达式如下：

$$\begin{cases} f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \\ i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \\ \tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \\ C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \\ o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \\ h_t = o_t * \tanh(C_t) \end{cases} \quad (3)$$

式中： $f_t$  决定遗忘门信息的保留或丢弃； $x_t$  为当前输入； $i_t$  为即将更新的值； $C_t$  和  $C_{t-1}$  分别为细胞当前时刻和上一时刻状态； $h_t$  和  $h_{t-1}$  分别为当前时刻和上一时刻的隐藏状态； $W_f, W_i, W_c, W_o$  为不同权重； $b_f, b_i, b_c, b_o$  为不同的偏置系数； $\sigma$  为 Sigmoid 函数。

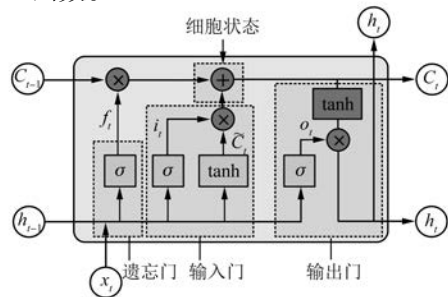


图 2 LSTM 的结构

由于 LSTM 神经网络包含记忆单元,可以将故障前与故障后发生的事联系起来,据此得出结论,因此能够挖掘样本在时间上的相关性信息,适合捕捉和提取故障前后的复杂时序特征,有利于提高弱受端直流系统的故障诊断准确率。

1.4 SSA 原理

Xu 等<sup>[25]</sup>受麻雀觅食行为的启发提出了 SSA。算法将麻雀种群分为发现者和加入者,二者身份动态变化,当一只麻雀变为发现者,必有一只麻雀变为加入者<sup>[26]</sup>。种群有可能遭遇捕食者,察觉捕食者的侦察者麻雀占种群的 10%~20%。给定每只麻雀的初始位置和适应度。发现者在搜寻食物时,若该区域安全,种群可以随机觅食,若区域有捕食者,种群迅速往安全区域转移。加入者若觉察发现者的食物更好,就会前往抢夺,如果抢夺成功,就会获得发现者的食物,否则继续监视发现者觅食<sup>[27-28]</sup>;侦察者能够发现捕食者,当麻雀处在种群边缘时容易遭遇捕食者,则向安全区域靠拢,当种群中心的麻雀察觉到危险时,则向附近其他麻雀靠拢,种群中加入者、发现者和侦察者的具体位置更新参考文献[29]。运用 SSA 对模型参数进行寻优,有利于构建最佳的故障诊断模型结构,进一步减少人为设定参数带来的误差。

2 弱受端直流输电系统数据样本仿真

2.1 时序数据仿真

弱受端直流输电系统发生不同类型的故障期间,测量点所得的电气量包含不同的特征,据此可实现不同故障类型的诊断。利用 PSCAD/EMTDC 仿真软件搭建±500 kV 永富弱受端直流输电系统故障仿真模型,生成模型训练和测试所需的大量故障数据样本。本文研究的永富直流输电系统模型如图 3 所示,左右两侧交流系统

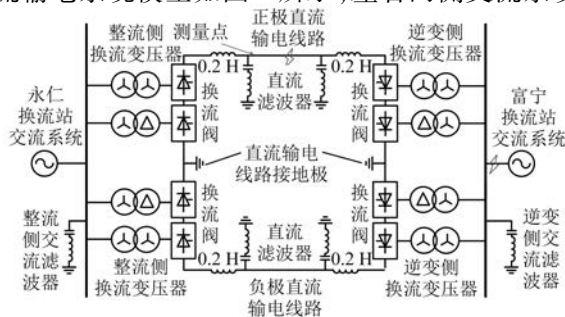


图 3 永富直流输电系统

分别为永仁换流站和富宁换流站。图 3 中元件的参数如表 1 所示。

直流输电线路故障和交流系统故障是弱受端直流输电系统中常见的故障。如图 3 所示,在正极直流线路配置测量点。在直流线路处设置单相接地故障,通过改变故障距离(变化步长为 50 km)、过渡电阻(0.01~400 Ω,变化步长为 40 Ω)等参数共计得到 100 组故障样本。在逆变侧交流系统分别设置单相接地、两相短路接地和三相接地故障,通过改变过渡电阻(0.01~400 Ω,变化步长为 4 Ω)得到 300 组故障样本。测量装置的采样频率设置为 10 kHz,数据窗长度设置为 400 ms,共计 4 000 个采样点,装置记录正极直流线路的电压  $u_{dc}$ ,得到满足并联 CNN-LSTM 模型输入的训练和测试数据  $X$ ,输出为四种故障类型  $Y$ ,分别对应直流线路故障  $f_{dc}$ ,交流系统单相接地  $f_{ac1}$ 、两相接地  $f_{ac2}$  和三相接地  $f_{ac3}$ :

$$\begin{cases} X = [u_{dc}] \\ Y = [f_{dc} f_{ac1} f_{ac2} f_{ac3}] \end{cases} \quad (4)$$

因此,原始数据输入矩阵的大小为 4 000×1,输出为四种故障类型。

表 1 永富模型元件参数

参数名称	参数值	
直流输送功率	单极/MW	1 500
	双极/MW	3 000
永仁换流站	电压/kV	525
	阻抗/Ω	10.56 ∠ 84.29°
富宁换流站	电压/kV	525
	阻抗/Ω	28.066 ∠ 85.24°
无功补偿容量	整流侧/Mvar	3 150
	逆变侧/Mvar	1 760
输电线路	长度/km	577
	平均电阻率/(Ω·m)	500
整流侧换流变压器	短路阻抗/%	16
	网侧绕组额定电压/kV	525
	阀侧绕组额定电压/kV	209.92
逆变侧换流变压器	额定容量/MVA	890.61
	短路阻抗/%	16
	网侧绕组额定电压/kV	525
整流侧换流变压器	阀侧绕组额定电压/kV	204.77
	额定容量/MVA	867.27
	额定直流电流/kA	3
平波电抗器/H	0.2	

## 2.2 数据预处理

本文将原始数据进行归一化处理,映射为区间 $[-1, 1]$ 内的值,使得故障特征在样本矩阵中均匀分布。归一化过程如下:

$$X^* = \frac{2(X - X_{\min})}{X_{\max} - X_{\min}} - 1 \quad (5)$$

式中: $X^*$ 为归一化后的值; $X$ 为原始数据; $X_{\min}$ 和 $X_{\max}$ 分别为原始样本中最小值与最大值。

归一化后再以7:3的比例划分为训练集(280组)和测试集(120组)。舍弃小波分解、经验模态分解和相模变换后人工提取故障特征的过程,直接利用深度学习模型对原始采集数据进行特征挖掘。

## 3 CS-SSA-CNN-LSTM 模型仿真

### 3.1 故障诊断模型与流程

模型首先利用压缩感知算法对归一化后的电压信号 $X^*$ 进行亚采样压缩,得到压缩域中的数据 $X_c^*$ ,缩短了每个电气量数据的长度,以提高计算

效率与精度。电力系统发生故障前后的电气量数据存在比较复杂的时序关联特征,这些特征中包含了反映故障的信息。CNN为前馈神经网络,卷积层通过卷积核在输入矩阵上卷积,生成特征向量,能够提取输入信号的空间特征,但CNN不包含记忆单元,对输入数据的顺序不敏感,无法准确捕捉时间特性。LSTM能够分析时间序列输入并抽取重要的时序信息保存到记忆单元中,利用新的输入不断更新。故LSTM适合捕捉和提取故障前后的复杂时序特征<sup>[30]</sup>。对于单一的CNN网络而言,虽然能挖掘故障数据的内在特征,但不能充分利用故障数据的时序性特征;而单一的LSTM模型虽然能充分利用数据的时序性特征,但对原始数据关联性分析不足。

故本文结合二者的优点建立并联CNN-LSTM故障诊断模型,如图4所示。先通过双支路卷积分别提取输入矩阵的内在特征,再将特征融合后输入LSTM网络,充分挖掘故障数据在时序上的特征,最后建立特征与各种故障间的关系。




图4 故障诊断模型

并联CNN-LSTM模型中,两路卷积核的大小和数量、池化层的大小、LSTM神经元个数、Dropout层的丢弃率、学习率和batch size等直接影响模型的诊断精度,需要求解合适的模型参数,以提高模型在输电系统故障诊断方面的适用性。通过SSA对模型结构和训练参数进行优化,免除了人工选取参数环节,避免了人为造成的不确定性因素,强化了模型的自适应选择参数能力。基于CS-SSA-CNN-LSTM的故障诊断流程如图5所示。

### 3.2 压缩倍数的选择

弱受端直流输电系统实测电气信号数据量大

且复杂,若直接利用原始数据训练模型,计算量将十分庞大,冗长的原始数据内含有细微噪声,会被卷积网络过度捕捉,影响模型的诊断精度。图6为永富直流系统在某一过渡电阻下发生故障时的电压变化,具体对应逆变侧交流系统发生单相接地、两相接地、三相接地和直流线路故障时的电压变化。发生不同故障时,由于受到过渡电阻的影响,测量点所测得的故障电压较为相似,故障特征不明显,诊断难度较大。

为提高模型的诊断效率和准确率,利用压缩感知算法对原始电气信号进行亚采样压缩,将数据长度缩短数倍,压缩感知过程如图7所示。压

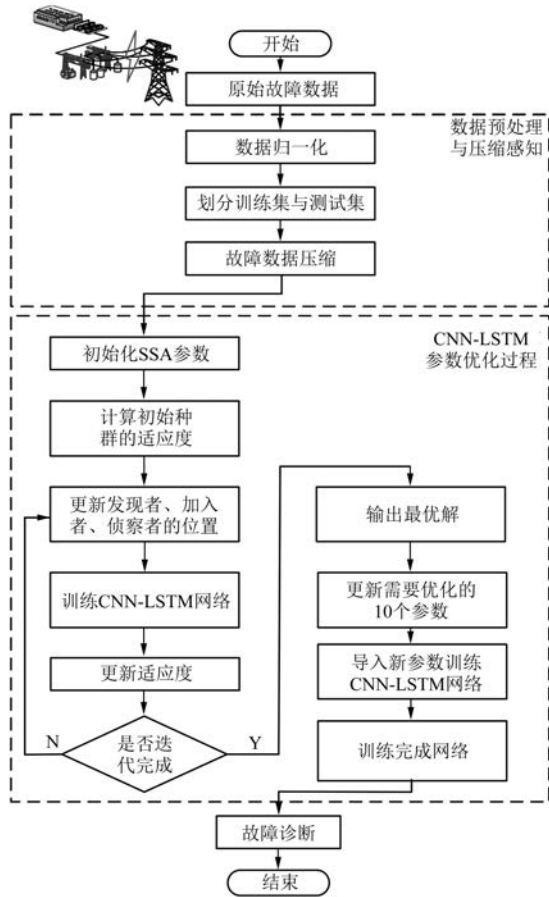


图5 故障诊断流程图

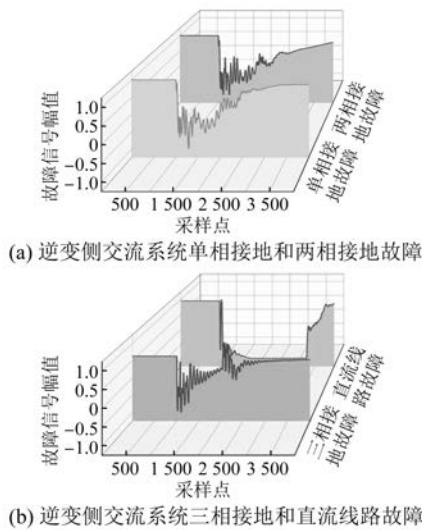


图6 永富直流系统发生不同故障时的电压变化

缩倍数过大会丢失原始数据的特征,压缩倍数过  
小则会因数据长度过长而导致模型过度提取细微

噪声信号,进而影响准确率。合适的压缩倍数会  
在不丢失特征的前提下提高计算效率和准确率。

本文将原始数据压缩 10 倍、15 倍和 20 倍后  
分别放入 CNN 模型进行训练并诊断,诊断结果见  
表 2。观察得知压缩 15 倍时诊断效果最佳,故后  
续试验将压缩倍数设为 15 倍。图 8 为永富直流  
系统发生不同故障时电压在压缩域中的变化,  
图 8(a)为逆变侧发生单相接地和两相接地时电  
压在压缩域中的变化,图 8(b)为逆变侧发生三相  
接地和直流线路故障时电压在压缩域中的变化。  
原始  $4\ 000 \times 1$  的输入矩阵经  $266 \times 4\ 000$  的观测矩  
阵  $\phi$  压缩后大小变为  $266 \times 1$ 。




图7 压缩感知过程

表 2 不同压缩倍数时 CNN 的诊断精度

压缩倍数	准确率/%
10	94.166 7
15	95.833 3
20	89.166 7

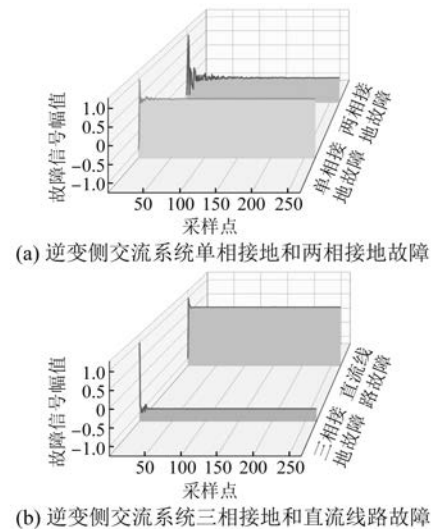


图8 永富直流系统发生不同故障时  
电压在压缩域中的变化

### 3.3 模型参数寻优

SSA 优化并联 CNN-LSTM 模型的参数设置: 种群规模  $N$  为 5; 优化迭代次数为 10; 发现者个数  $p_{\text{num}}$  为 1; 预警值为 0.8; 需要优化 10 个参数, 故优化维度为 10 维。其中, 10 个参数的取值范围如下: 学习率的范围是 0.001~0.01; batch size 的范围是 1~100; 双支路卷积核的大小范围是 1~10, 卷积核数量的范围是 1~20; 双支路池化核大小范围是 2~10; LSTM 神经元数量范围为 1~100; Dropout 层的丢弃率范围是 0.1~0.9; 以测试集的诊断误差为适应度函数。CS-SSA-CNN-LSTM 的最优适应度变化迭代过程如图 9 所示, 可以看出 SSA 在参数寻优过程中展现出良好的全局搜索能力。优化后的 CNN-LSTM 模型具体参数如表 3 所示。预测模型的其他主要参数如表 4 所示。




图 9 适应度变化曲线

表 3 SSA 优化后的模型参数

优化的参数	优化的结果
支路 1 卷积核大小	1×2
支路 2 卷积核大小	1×4
支路 1 池化核大小	1×4
支路 2 池化核大小	1×3
支路 1 卷积核个数	9
支路 2 卷积核个数	8
LSTM 神经元个数	73
Dropout 层的丢弃率	0.203 8
学习率	0.007 2
Batch size	22

表 4 预测模型的其他参数

参数名称	参数值
优化器	adam
卷积 padding 方式	same
卷积步长	1
池化步长	1

SSA 优化后的模型在迭代 2 000 次的过程中, 准确率迅速上升并且收敛于 100%, 损失函数也迅速下降并收敛于 0, 如图 10 所示, 说明本文所建立的模型在弱受端直流输电系统故障诊断方面的可行性。




图 10 模型准确率和损失值

### 3.4 不同模型故障诊断试验结果对比分析

将并联 CNN-LSTM 模型与传统 CNN 模型和 LSTM 模型的诊断效果进行对比。传统的 CNN 模型主要由输入层、卷积层、池化层、全连接层和输出层组成, 卷积核大小和数量分别为  $1 \times 4$  和 8。LSTM 模型由序列输入层、LSTM 层、Dropout 层、全连接层和输出层组成, LSTM 神经元个数取 73 个, Dropout 层丢弃率取 20.38%。三者具体诊断结果分别绘制混淆矩阵, 如图 11 所示, 随机划分的测试集中直流线路故障有 26 组, 交流系统单相接地、两相接地和三相接地故障分别有 31 组、30 组和 33 组, 将诊断结果与真实标签作对比。由于传统 CNN 模型无法提取数据的时序性特征, 将 5 组单相接地故障错误诊断为直流线路故障, 精度为 95.833 3%。

LSTM 模型虽然能提取时序性特征, 但由于深层特征挖掘不充分, 将 1 组直流线路故障错误诊断为单相接地故障, 将 3 组两相接地故障错误诊断为单相接地故障, 精度为 96.666 7%。

并联 CNN-LSTM 模型则充分挖掘数据的深层特征和时序性特征, 诊断结果与真实标签完全对应, 准确率达 100%。从结果来看, 该模型在弱受端直流输电系统中的故障诊断效果优于传统方法。

## 4 结 语

本文提出了一种基于 CS-SSA-CNN-LSTM 的弱受端直流输电系统故障诊断模型, 解决了故障数据过多, 难以充分挖掘数据的特征导致机器学习

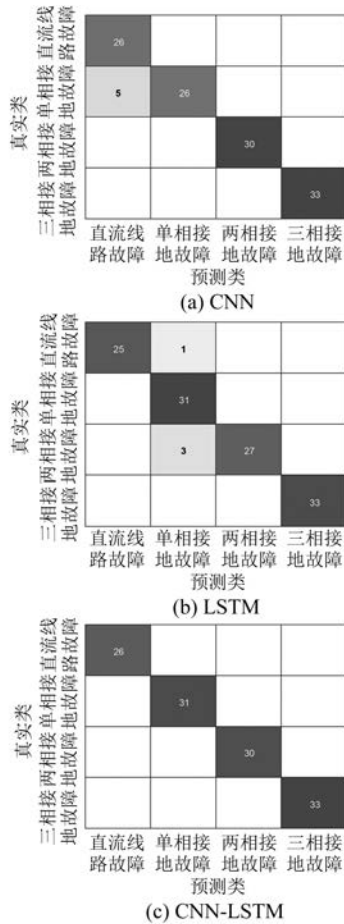


图 11 不同模型故障诊断结果混淆矩阵

习效果不佳的问题。通过算例仿真得到的主要结论如下：

(1) 该模型通过压缩感知算法亚采样压缩原始数据,选择合适的压缩倍数,在不丢失特征的前提下提高计算效率和准确率。

(2) 针对压缩域故障数据,结合 CNN 和 LSTM 二者的优点,应用双支路卷积和 LSTM 模型充分挖掘数据的深层特征和时序性特征。

(3) 应用 SSA 优化出了充分适应算例的模型结构,免除了人工选取参数环节,提高了模型在输电系统故障诊断方面的适用性。

【参考文献】

[ 1 ] 束洪春,王璇,田鑫萃,等. 交流故障下永富直流换流器差动保护误动风险分析[J]. 高电压技术, 2018,44(2): 478.  
 [ 2 ] 陈义宣,肖亮,李玲芳,等. 异步联网下多直流送出系统的功率稳定性分析及评价标准[J]. 高电压技

术,2019,45(1): 243.  
 [ 3 ] 谢仲润,邹贵彬,杜肖功,等. 基于真双极的 MTDC 电网直流线路快速保护[J]. 中国电机工程学报, 2020,40(6): 1906.  
 [ 4 ] 缪希仁,林瑞聪. 基于关联维数与极端学习机的高压输电线路雷击过电压故障识别[J]. 高电压技术,2016,42(5): 1519.  
 [ 5 ] 杨洁,万安平,王景霖,等. 基于多传感器融合卷积神经网络的航空发动机轴承故障诊断[J/OL]. 中国电机工程学报, 2021-11-02. <https://kns.cnki.net/kcms/detail/11.2107.TM.20211101.1325.007.html>.  
 [ 6 ] 王涤,马爱军,归宇,等. 基于 P-CNN 的局部放电绝缘故障融合诊断[J]. 高电压技术, 2020,46(8): 2897.  
 [ 7 ] 张大海,张晓炜,孙浩,等. 基于卷积神经网络的交直流输电系统故障诊断[J]. 电力系统自动化, 2022,46(5): 132.  
 [ 8 ] 李舟平,姚伟,曾令康,等. 基于长短期记忆网络的电网故障区域定位与故障传播路径推理[J]. 电力自动化设备,2021,41(6): 164.  
 [ 9 ] 石重托,姚伟,黄彦浩,等. 基于 SE-CNN 和仿真数据的电力系统主导失稳模式智能识别[J/OL]. 中国电机工程学报, 2021-11-08. <https://kns.cnki.net/kcms/detail/11.2107.TM.20211105.1639.046.html>.  
 [ 10 ] 龚彧,赵峰,李冬华,等. 基于压缩感知的架空线路舞动波形重构方法[J]. 电力系统保护与控制, 2021,49(9): 97.  
 [ 11 ] 丁晖,赵海丞,刘家强,等. 基于压缩感知的电力设备状态感知技术[J]. 高电压技术, 2020,46(6): 1877.  
 [ 12 ] 冯双,崔昊,吴熙,等. 基于对角化 LDPC 压缩感知和 k-近邻算法的广域系统宽频振荡监测方法[J]. 电网技术,2021,45(8): 3025.  
 [ 13 ] 贾科,冯涛,赵其娟,等. 基于故障高频电压稀疏量测的直流配电网双极短路故障定位[J]. 电力系统自动化,2020,44(1): 142.  
 [ 14 ] 高冰,崔泽坤. 基于高频暂态稀疏测量的复杂直流配电网故障定位[J]. 电力系统保护与控制,2021,49(16): 38.  
 [ 15 ] 王艳,李煜,赵洪山,等. 配电设备监测信号的压缩感知与设备异常识别[J/OL]. 高电压技术,2022,48(1): 11.  
 [ 16 ] 周东旭,王丰华,党晓婧,等. 基于压缩观测与判别字典学习的干式变压器声纹识别[J]. 中国电机工



- 程学报, 2020, 40(19): 6380.
- [17] 杨镛. 压缩感知雷达成像中的模型失配问题研究 [D]. 长沙: 国防科学技术大学, 2016.
- [18] 徐敏锐, 李云, 卢树峰, 等. 基于 D-S 证据组合规则的双模型融合局部放电模式识别方法 [J]. 电力自动化设备, 2021, 41(11): 153.
- [19] 陈健宁, 周远翔, 白正, 等. 基于多通道卷积神经网络的油纸绝缘局部放电模式识别方法 [J]. 高电压技术, 2022, 48(5): 1705.
- [20] 郑炜, 林瑞全, 王俊, 等. 基于 GAF 与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, 2021, 49(11): 97.
- [21] 缪希仁, 林蔚青, 肖洒, 等. 基于条件互信息与 LSTM 的特高压变压器顶层油温预测方法 [J/OL]. 电网技术, doi: 10.13335/j.1000-3673.pst.2021.1313.
- [22] 王振浩, 王翀, 成龙, 等. 基于集合经验模态分解和深度学习的光伏功率组合预测 [J/OL]. 高电压技术, doi: 10.13336/j.1003-6520.hve.20210971.
- [23] 梁海峰, 袁芑, 高亚静. 基于 CNN-Bi-LSTM 网络的锂离子电池剩余使用寿命预测 [J]. 电力自动化设备, 2021, 41(10): 213.
- [24] 殷豪, 张铮, 丁伟锋, 等. 基于生成对抗网络和 LSTM-CSO 的少样本光伏功率短期预测 [J/OL]. 高电压技术, doi: 10.13336/j.1003-6520.hve.20210946.
- [25] XU X, PENG L, JI Z, et al. Research on substation project cost prediction based on sparrow search algorithm optimized BP neural network [J]. Sustainability, 2021, 13(24): 13746.
- [26] 马晨佩, 李明辉, 巩强令, 等. 基于麻雀搜索算法优化支持向量机的滚动轴承故障诊断 [J]. 科学技术与工程, 2021, 21(10): 4025.
- [27] XING Z, YI C, LIN J, et al. Multi-component fault diagnosis of wheelset-bearing using shift-invariant impulsive dictionary matching pursuit and sparrow search algorithm [J]. Measurement, 2021, 178: 109375.
- [28] 林涛, 刘航鹏, 赵参参, 等. 基于 SSA-PSO-ANFIS 的短期风速预测研究 [J]. 太阳能学报, 2021, 42(3): 128.
- [29] 曾亮, 雷舒敏, 王珊珊, 等. 基于 OVMD-SSA-DELM-GM 模型的超短期风电功率预测方法 [J]. 电网技术, 2021, 45(12): 4701.
- [30] 向玲, 王朋鹤, 李京蓄. 基于 CNN-LSTM 的风电机组异常状态检测 [J]. 振动与冲击, 2021, 40(22): 11.

(上接第 28 页)

- [7] 朱红卫, 冷军. 含发电机及多感应电动机工业负荷母线失电残压分析 [J]. 能源工程, 2021(5): 71.
- [8] 曹祯, 董桂成, 朱庆海, 等. 快速切换装置在石化行业应用存在的问题及解决方案 [J]. 电气技术, 2021, 22(6): 106.
- [9] 李希年, 庞清乐, 孙静. 基于瞬时对称分量变换的单相电压暂降检测 [J]. 电力系统及其自动化学报, 2018, 30(1): 76.
- [10] 夏杰, 张建文, 王金川. 基于 FFT 与形态加权动态时间规整的电压暂降源辨识新方法 [J]. 电测与仪表, 2019, 56(1): 28.
- [11] 赵凤展, 杨仁刚. 基于短时傅里叶变换的电压暂降扰动检测 [J]. 中国电机工程学报, 2007, 27(10): 28.
- [12] 刘连光, 贾文双, 肖湘宁, 等. 用小波变换和有效值算法实现电压凹陷的准确测量 [J]. 电力系统自动化, 2003, 27(11): 30.
- [13] 郑智聪, 王红, 齐林海. 基于深度学习模型融合的电压暂降源识别方法 [J]. 中国电机工程学报, 2019, 39(1): 97.