

DOI:10.19651/j.cnki.emt.2107518

# 基于 GWO-TCN 网络的 HVDC 输电线路故障诊断<sup>\*</sup>

刘辉 李永康 张淼 刘维

(湖北工业大学 湖北省电网智能控制与装备工程技术研究中心 武汉 430068)

**摘要:**现有高压直流(HVDC)故障检测方法灵敏度低,难以识别高阻接地故障,提出了一种基于改进灰狼算法(GWO)优化时间卷积神经网络(TCN)的HVDC传输系统故障检测方法,整流侧检测装置采集的故障电流信号直接用作TCN的输入数据,克服了故障信号处理的繁琐过程。利用Simulink仿真软件建立±500 kV高压直流输电线路模型,对不同故障区域和故障类型进行仿真实验,使用基于LSTM模型,BiLSTM模型和CNN模型3种模型的故障检测方法进行比较。测试结果表明,GWO-TCN网络能够可靠、准确地在过渡电阻高达800 Ω时进行HVDC输电线路故障选极和选区。

**关键词:**时间卷积神经网络;灰狼优化算法;故障识别;高压直流输电

中图分类号:TM712 文献标识码:A 国家标准学科分类代码:470.4051

## Fault diagnosis of HVDC transmission lines based on GWO-TCN networks

Liu Hui Li Yongkang Zhang Miao Liu Wei

(Hubei Power Grid Intelligent Control and Equipment Engineering Technology Research Center, Hubei University of Technology, Wuhan 430068, China)

**Abstract:** The existing high voltage direct current (HVDC) fault detection methods have low sensitivity and are difficult to identify high resistance grounding faults. This paper proposes a HVDC transmission system fault detection method based on improved grey wolf optimizer (GWO) optimized time convolutional network (TCN). The fault current signal collected by the rectifier side detection device is directly used as the input data of TCN, which overcomes the cumbersome process of fault signal processing. The ± 500 kV HVDC transmission line model is established by using Simulink simulation software, and the simulation experiments are carried out for different fault areas and fault types. The fault detection methods based on LSTM model, BiLSTM model and CNN model are compared. The test results show that gwo-tcn network can reliably and accurately select the fault pole and selection of HVDC transmission line when the transition resistance is up to 800 Ω.

**Keywords:** temporal convolutional network;grey wolf optimizer;fault identification;high voltage direct current

## 0 引言

随着中国能源互联网战略的不断实施发展,高压直流输电(high voltage direct current,HVDC)工程在我国电网中所占比重不断增加。作为直流输电工程的重要组成部分,高压直流输电保护系统负责快速检测故障,确保直流输电工程的安全稳定运行。HVDC输电线路沿途环境复杂、输送距离长、发生故障的机率高。因此,提高高压直流输电系统和输电线路保护的可靠性、稳定性和安全性,具有重要的社会经济意义。

高压直流技术拥有高效的传输效率,世界各地的研究

人员对其进行了广泛的研究,在HVDC输电线路故障检测方面有很多优秀的策略。文献[1]提出使用卷积神经网络(convolutional neural networks,CNN)对HVDC输电线路进行区内外故障判别,但卷积网络结构对判别结果准确性的影响较大,针对不同结构的电力系统来调整卷积网络结构需要耗费大量时间。文献[2]使用Teager能量算子对HVDC输电线路发生故障时的正负极电流突变量能量比值组成特征向量,并使用1D-CNN对特征向量集进行训练和测试,同时实现区内外故障判别和故障极选择。文献[3]对HVDC输电线路发生故障时的暂态电流信号进行变分模态分解(variational mode decomposition,VMD)得到暂

收稿日期:2021-08-08

\*基金项目:国家自然科学基金(61903129)项目资助

态电流信号的本征模态函数(intrinsic mode function, IMF)分量,再利用暂态电流信号的本征模态函数分量计算多尺度模糊熵,最后使用多尺度模糊熵输入至 Softmax 分类器进行 HVDC 输电线路故障辨识。文献[4]使用 HVDC 输电线路发生接地故障时的交直流电压、电流等 13 种故障特征量利用支持向量机进行分类来实现故障辨识。文献[5]使用 HVDC 发生故障时的直流侧电压信号通过小波包变换提取故障特征后利用鸟群算法优化的 AdaBoost-SVM 对 HVDC 输电线路进行故障辨识。上述方法存在 HVDC 输电线路故障特征提取复杂和在对双极 HVDC 故障进行故障区内外辨识后需要另外的判据进行故障选极等问题。

因此,本文首次探索了针对时序数据问题而特定设计的时间卷积神经网络(temporal convolutional network, TCN)用于 HVDC 系统故障识别,来实现对区内外故障辨别和故障极的辨识,并通过改进激活函数的方式优化神经网络模型性能。针对深度学习网络参数对 HVDC 系统故障辨识结果有较大影响的问题,引入了改进灰狼优化算法对时间卷积神经网络进行参数智能寻优,来提升时间卷积神经网络对 HVDC 系统的故障辨识准确率。以±500 kV 高压直流输电线路模型数据,验证了故障识别方法的有效性和识别结果的准确性。

## 1 时间卷积神经网络

传统的卷积神经网络具有强大的特征提取能力。时间卷积网络是从一维卷积神经网络改进而来的一种新型神经网络。它不仅保留了传统卷积神经网络中强大的特征提取能力,而且非常适合处理时间序列。目前,在流量估算,语音处理,机器翻译和人体运动识别等许多领域,TCN 已被证明优于长短时记忆网络(long short time memory, LSTM)。但是,TCN 在电力系统中的应用相对有限。现有的工作主要集中在风力涡轮机的故障检测,电能质量扰动的分类以及负荷预测。由于文章所使用的 HVDC 故障电流数据为时间序列数据,故选用具有时间序列数据处理能力的 TCN 时间卷积网络来解决 HVDC 输电线路的故障选区和选极问题。

### 1.1 时间卷积网络的基本原理与应用

时间卷积网络是在传统卷积神经网络基础上进行改进和优化而得到的一种新型网络结构,主要是一种解决序列问题的网络结构<sup>[6]</sup>。

TCN 模型由一维全卷积、因果卷积和空洞卷积组成。TCN 中的一维全卷积使每个网络隐藏层与输入网络层的长度相同,通过填充零的方式使得前后两个网络层的输入和输出之间的保持长度相同。因果卷积确保了序列模型中  $t$  时刻的输出仅限于和前一层网络中的  $(t-1)$  时刻之前的元素相关,  $t$  时刻之后的数据对特征的学习不会产生干扰,此特点与循环神经网络相似,因此 TCN 模型非常善于解决序列问题。与传统卷积相比,空洞卷积引入了扩张因子,通

过增大扩张因子的方式使卷积核的感受野获得指数式扩张。因果卷积与空洞卷积的组合极大增加了对因果卷积的感知野,从而获取长期的时间序列信息。TCN 网络的感受野依赖于网络深度、卷积核大小以及扩张因子。TCN 网络使用残差块替代卷积层从而加深网络深度,解决深层网络的训练问题。残差块由一维全卷积、因果卷积和空洞卷积等方法封装而成,同时包含 ReLU 单元、Weight Norm 单元。TCN 网络结构如图 1 所示<sup>[7]</sup>。

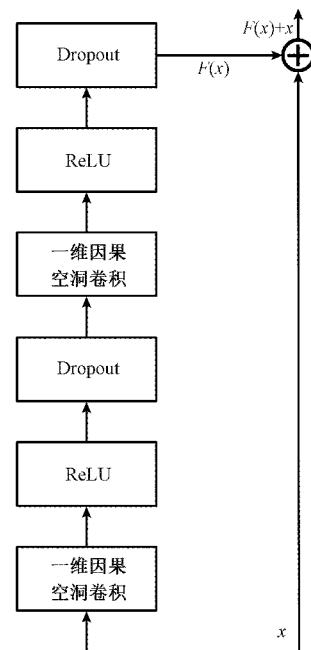


图 1 TCN 网络结构

时间卷积网络结构具有如下 5 点特点:1)由于卷积神经网络每一层使用相同的卷积核,因此一个长序列输入可以用 TCN 并行处理。2)引入空洞卷积能够在不增加池化的同时扩大感受野,所以 TCN 网络拥有灵活的感受野。3)时间卷积网络中加入了零填充使网络能够输入不同长度的数据。4)不会因为不同时间段共享参数而导致梯度爆炸或者消失,梯度更为稳定。5)更小的内存训练,时间卷积网络里同一层卷积核共享,所以能够占用更少内存。

对于 HVDC 输电线路故障诊断来说,如何迅速准确的识别出信号是要解决的首要问题。相较于常见的神经网络模型,时间卷积网络能够做到保证准确率的同时更加迅速的识别故障信号类型,主要原因有如下 3 点:1)时间卷积网络能够并行处理 HVDC 输电线路故障信号,相较于常见串行处理数据的循环神经网络(recurrent neural network, RNN)和 LSTM 等网络,速度更快。2)通常来说,网络层数越多,训练越复杂,识别 HVDC 输电线路故障类型所耗费的时间越长。时间卷积网络采取空洞卷积,能够识别 HVDC 输电线路故障类型的同时减少层数的数量,进而缩短训练时间。3)常用于时序信号识别的 RNN 和 LSTM 等网络,采用逐层传递信息的方式,时间卷积网络采用残差连

接,能够跨层传递信息,所以训练速度更快<sup>[8]</sup>。

## 1.2 时间卷积神经网络改进

时间卷积网络一般采用 ReLU 激活函数,该激活函数确实能在一定程度上加速模型的收敛,但是 ReLU 激活函数在训练过程中存在导致神经元坏死等问题,十分脆弱。为了解决这个问题,在实际应用中会选择有指数修正单元 ELUs 或者参数化线性修正单元如 LeakyReLU 等来替代 ReLU 激活函数<sup>[9]</sup>。如图 2 所示,ReLU 是将所有的负轴上的值都设为 0;ELUs 在负轴上采用较小的指数函数代替 ReLU 负轴上的零值,使得负轴上的值能得以保留一部分;LeakyReLU 是给负轴的值赋予一个非零斜率,合理的选取斜率值不仅能在一定程度上增加模型在零点附近的拟合能力,还会降低模型过拟合的风险<sup>[10]</sup>。综上所述文章选用 LeakyReLU 激活函数作为文章时间卷积神经网络结构中的激活函数。

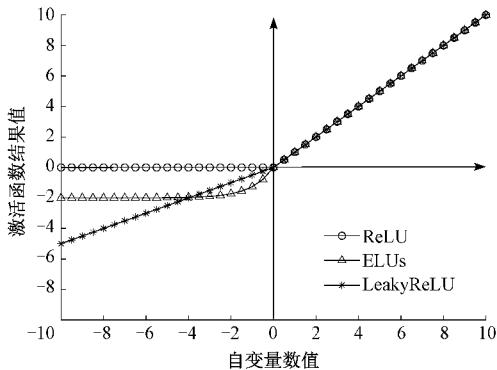


图 2 激活函数图像对比

## 2 改进灰狼算法

### 2.1 标准灰狼算法

灰狼群体具有森严的社会等级制度关系,大体可分为 4 个等级  $\alpha, \beta, \delta, \omega$ , 如图 3 所示,其中:狼  $\alpha$  为头狼,表示最优解;狼  $\beta$  为协助狼,表示次优解;狼  $\delta$  为服从狼,即服从狼  $\alpha$  和狼  $\beta$  的命令,表示第三优解;狼  $\omega$  没有自主决策能力,表示其余候选解<sup>[11]</sup>。

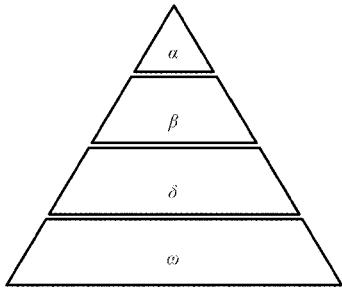


图 3 狼群阶层

设灰狼种群共有  $N$  个个体,第  $i$  只灰狼的位置为  $X_i = (X_i^{(1)}, X_i^{(2)}, \dots, X_i^{(D)})$ ,其中  $D$  表示搜索空间维数,狼群行动主要有包围行为和捕猎行为<sup>[12]</sup>。

包围行为,当灰狼发现猎物时,狼群就对猎物进行包围,设其与猎物之间的距离为  $D$ ,则:

$$D = |\mathbf{C} \cdot X_p(t) - \mathbf{X}(t)| \quad (1)$$

$$\mathbf{X}(t+1) = X_p(t) - \mathbf{A} \cdot D \quad (2)$$

式中:  $X_p$  和  $\mathbf{X}$  分别表示猎物和位置向量;  $\mathbf{A}$  和  $\mathbf{C}$  为系数向量,计算公式为:

$$\begin{cases} \mathbf{A} = 2a(\mathbf{r}_1 - 1) \\ \mathbf{C} = 2\mathbf{r}_2 \end{cases} \quad (3)$$

式中:  $\mathbf{r}_1, \mathbf{r}_2$  为随机向量,  $a = 2 - 2 \times \frac{t}{t_{\max}}$  为收敛因子,  $t_{\max}$  为最大迭代次数<sup>[13]</sup>。

捕猎行为,灰狼将猎物包围后,由狼  $\alpha, \beta, \delta$  带领狼群不断靠近猎物,用  $X_\alpha, X_\beta$  和  $X_\delta$  分别表示  $\alpha, \beta, \delta$  相对于猎物的位置,  $\mathbf{A}_i$  和  $\mathbf{C}_i$  表示系数向量,则  $\alpha, \beta, \delta$  位置更新公式为:

$$\begin{cases} D_\alpha = |\mathbf{C}_1 X_\alpha(t) - \mathbf{X}(t)| \\ D_\beta = |\mathbf{C}_2 X_\beta(t) - \mathbf{X}(t)| \\ D_\delta = |\mathbf{C}_3 X_\delta(t) - \mathbf{X}(t)| \end{cases} \quad (4)$$

$$\begin{cases} X_1(t+1) = X_\alpha(t) - \mathbf{A}_1 D_\alpha \\ X_2(t+1) = X_\beta(t) - \mathbf{A}_2 D_\beta \\ X_3(t+1) = X_\delta(t) - \mathbf{A}_3 D_\delta \end{cases} \quad (5)$$

$$X(t+1) = \frac{X_1(t+1) + X_2(t+1) + X_3(t+1)}{3} \quad (6)$$

### 2.2 标准灰狼算法的不足及改进

根据式(5)和(6)灰狼不断调整其与猎物的方向和距离,最后  $\alpha$  所在位置为问题的最优解,在实际应用中,灰狼算法存在收敛速度较慢,容易陷入局部最优解、很难收敛到全局最优解等不足,因此需对灰狼算法进行改进<sup>[14]</sup>。

改进自适应收敛因子,灰狼算法的求解结果与  $A$  值结果相关,而  $A$  值与收敛因子  $a$  密切相关,传统灰狼算法的  $a$  采用线性递减方式,容易陷入局部最优解,本文利用 Sigmoid 函数的特点,将其引入收敛因子更新过程中,计算公式为:

$$a = a_{\max} - \left(1 + \exp\left(-\frac{t}{t_{\max}}\right)\right)^{-1} \quad (7)$$

式中:  $t_{\max}$  表示最大迭代数,由式(7)可知,随着迭代次数的增加,  $a$  值呈现非线性减小,可发现多个潜在最优解<sup>[15]</sup>。

改进灰狼位置更新公式,引入惯性权重对灰狼位置进行更新,使灰狼尽快跳出局部最优解中  $\varphi$  为惯性权重,其变换方式为:

$$\varphi(t+1) = \varphi_{\max} - (\varphi_{\max} - \varphi_{\min}) \times \frac{t}{t_{\max}} \quad (8)$$

## 3 基于 GWO-TCN 的 HVDC 故障诊断

### 3.1 双极直流输电仿真模型

使用 MATLAB 中的 Simulink 软件搭建出土 500 kV 的双极 HVDC 模型。仿真系统示意图如图 4 所示。图中,

$L$ 为平波电抗器;D/F为直流滤波器; $f_1 \sim f_7$ 为现实状况HVDC系统可能会出现的故障类型, $f_1$ 为整流侧正极接地故障、 $f_2$ 为区内正极接地故障、 $f_3$ 为逆变侧正极接地故障、 $f_4$ 为整流侧负极接地故障、 $f_5$ 为区内负极接地故障、 $f_6$ 为逆变侧负极接地故障、 $f_7$ 为区内两极短路故障。本文所提模型仅针对 $f_1 \sim f_6$ 故障进行诊断。

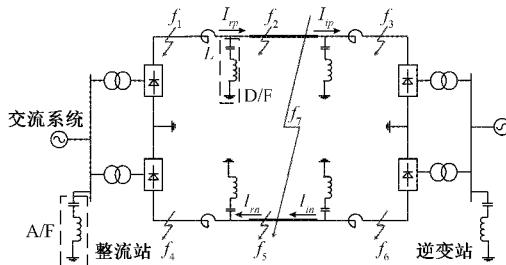


图4 双极直流输电仿真示意图

在区内分别设置故障发生的位置和过渡电阻值。其中,将过渡电阻设置为1、50、100、200、300、400、500、600和800  $\Omega$ ,设置区内故障发生位置为距离整流侧1、50、120、210、320、450、600、750、799 km。通过电流互感器采集HVDC输电线路发生短路故障时正极和负极的电流,并将正极电流和负极电流组合成为一个数据样本,共198组HVDC输电线路故障样本。

本文使用TCN网络所研究的双极HVDC输电线路故障诊断,其用途是判别HVDC系统的故障发生位置是在区内还是区外,区外即发生在整流侧或逆变侧。故障类型对应标签如表1所示。

表1 标签对应表

线路状态类型	标签
正常运行	0
整流侧正极故障	1
整流侧负极故障	2
区内正极故障	3
区内负极故障	4
逆变侧正极故障	5
逆变侧负极故障	6

如图5所示,HVDC输电线路区外发生故障时的故障电流谐波含量少,波形相对简单;区内发生故障时的故障电流谐波含量多,波形相对复杂,这使得不同类型的故障存在较大差异,因此,可以利用这一差异进行不同类型故障的辨识。

### 3.2 实验方法

将HVDC输电线路发生故障时的正极电流与负极电流组合成为一个故障电流数据样本,数据大小为 $2 \times 2400$ 。共198组数据。随机选取197组故障电流数据为深度学习网络测试数据集,剩余的1组数据为网络测试集。此时,设

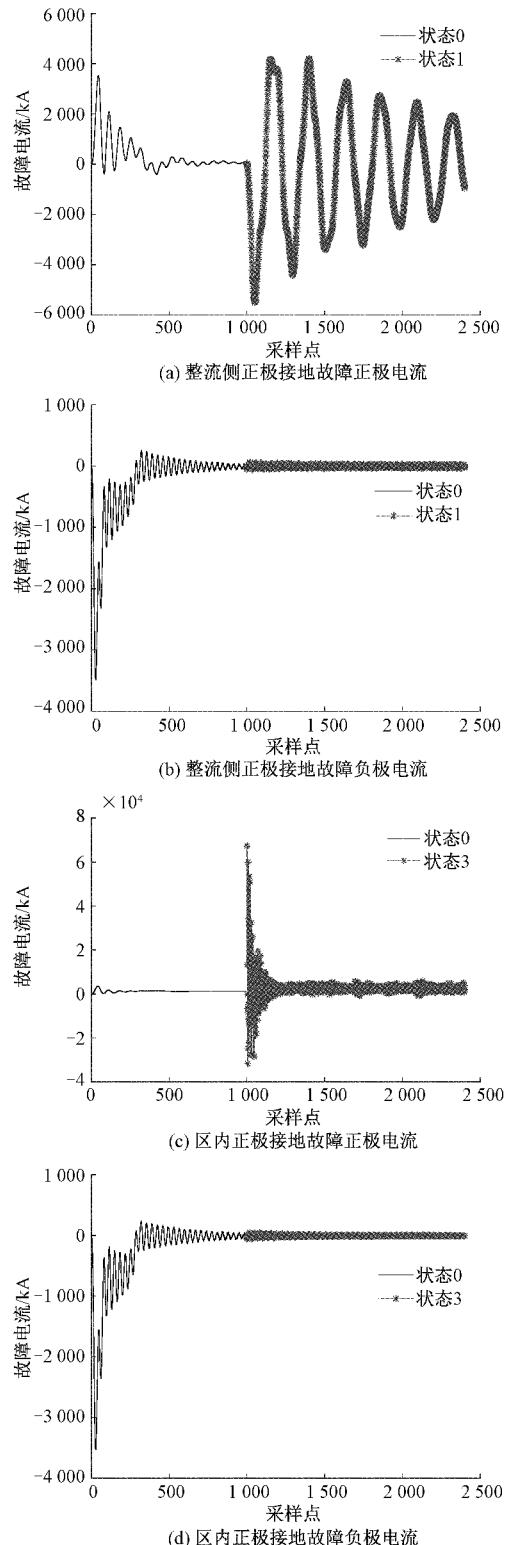


图5 区内和区外整流侧故障两极电流

置TCN参数,将网络初始的学习率设为0.01,区块数量为4,滤波器个数设为100,滤波器尺寸为2,最小训练样本数设为1,最大训练轮数设为30轮。网络的输出为 $1 \times 2400$ 的HVDC输电线路运行状态标签。如图6所示结果表明序

列中的故障类别识别率为 95.2%，辨识错误的主要原因为将 HVDC 系统启动时产生的振荡电流误判为发生故障。

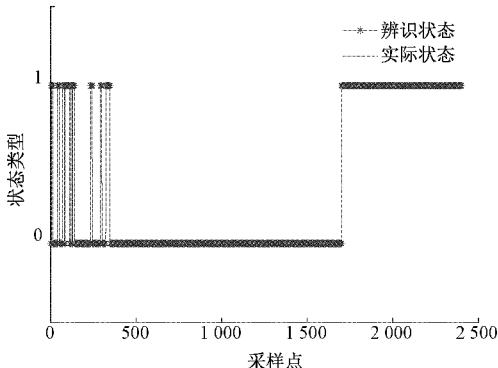


图 6 TCN 模型检测 HVDC 故障判别结果图

如图 7 所示,为了进一步优化 TCN 网络,为了使故障类型诊断准确率进一步提高,文章使用 GWO 灰狼优化算法对 TCN 网络中的区块数  $B$ 、滤波器数量  $N$  和滤波器大小  $S$  进行参数寻优。

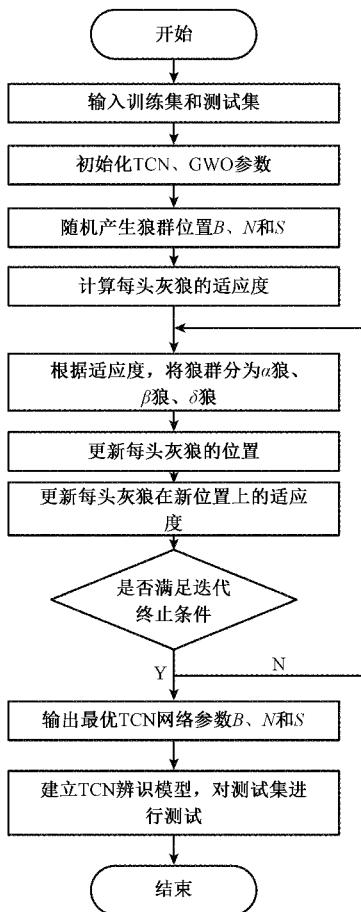


图 7 灰狼算法优化 TCN 网络参数流程

以元胞数组的形式输入 HVDC 故障电流,随机选取 197 个的数据作为训练集,剩余的 1 个为测试集输入至 GWO-TCN 模型。

初始化狼群数量、迭代次数,设置区块数  $B$ 、滤波器个数  $N$  和滤波器大小  $S$  的范围。

TCN 网络根据初始参数  $B$ 、 $N$  和  $S$  进行训练和测试,并以正确率最大化为目标。

GWO 以  $B$ 、 $N$  和  $S$  为猎物进行寻优,达到最大迭代次数时输出 GWO 全局最优。

将以元胞数组的形式输入 HVDC 故障电流分别作为 TCN 网络的训练集和测试集,采用最佳参数  $B$ 、 $N$  和  $S$  建立识别模型,并对测试样本进行 HVDC 输电线路运行状态辨识。

灰狼优化算法输出的参数为  $B$ 、 $N$  和  $S$ ,其中  $B$  为 TCN 网络中的区块数,  $N$  为滤波器数量,  $S$  为滤波器大小。

由于每次代入的数据不尽相同,所以每次 GWO 寻优结果有所偏差,以其中 1 次为例,迭代次数为 100,以整体识别正确率为寻优函数,寻优的变量为 TCN 的区块数、滤波器数量和滤波器大小。得到的寻优结果如图 8 所示。

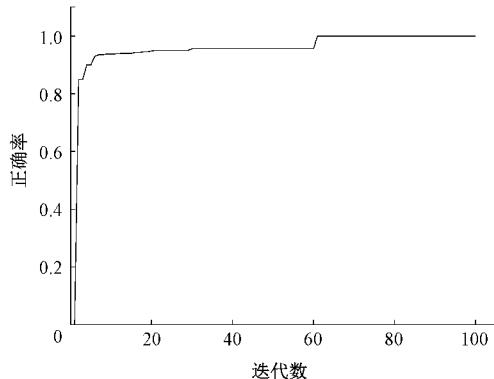


图 8 GWO 参数寻优迭代图

此时,寻优得到的区块数量为 4,滤波器个数设为 1 200,滤波器尺寸为 3。通过 GWO 算法优化了 TCN 网络参数后检测 HVDC 故障判别结果如图 9 所示,结果表明序列中的故障类型判别准确率为 100%。

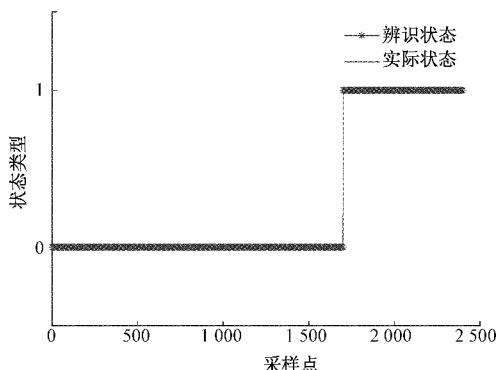


图 9 GWO-TCN 模型检测 HVDC 故障判别结果

### 3.3 各模型 HVDC 故障诊断效果对比

为了进一步验证 GWO-TCN 模型在 HVDC 故障诊断方面的优越性,本文使用 TCN、LSTM、双向长短期记忆网

络(bi-directional long short-term memory, BiLSTM)和CNN进行对比。

本文使用辨识准确率和训练时间作为输电线路故障辨识方法的评价指标,辨识准确率 $acc = N_{acc}/N$ ,其中 $N_{acc}$ 为检测样本采样点辨识标签与检测样本采样点实际标签相同的个数,N为检测样本采样点的总个数。为了验证结果的准确性,每一项实验均进行10次,并且每一次实验随机选取数据集中197个数据作为训练集,剩余的1个HVDC输电线路故障样本作为测试集。

图10表明将HVDC输电线路故障电流数据输入至使用改进激活函数的GWO算法对TCN网络参数寻优的GWO-TCN模型,经过网络训练后随机选取十组数据进行HVDC输电线路故障类型检测,每一次检测结果的准确率都远高于没有经过GWO算法优化参数的TCN网络。且GWO-TCN模型进行HVDC输电线路故障类别检测结果准确率高且性能稳定。如表2所示,GWO-TCN模型经过网络训练后,随机选取10组数据对HVDC输电线路故障类型检测的10次平均检测结果的准确率都远高于没有GWO优化参数的TCN网络故障检测方法,CNN网络的故障检测平均准确率低于LSTM和BiLSTM网络,而且GWO-TCN模型的网络训练时间为104 s,TCN模型的网络训练时间为125 s,GWO-TCN模型的网络训练时间相较TCN模型的网络训练时间缩短了16.8%。

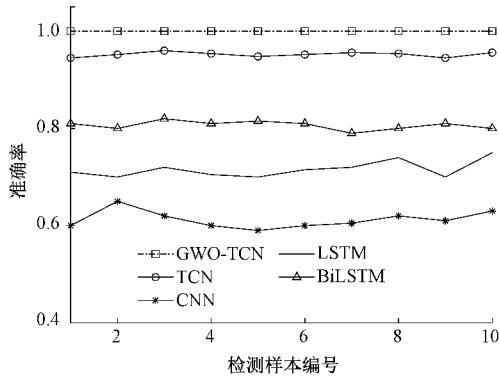


图10 检测结果准确率对比

表2 HVDC输电线路故障检测方法的性能

检测方法	平均准确率	网络训练时间/s
TCN	0.952	125
GWO-TCN	1	104
CNN	0.608	328
LSTM	0.724	134
BiLSTM	0.814	156

#### 4 结论

本文在时间卷积网络的基础上,通过改进激活函数的方式优化神经网络模型性能,并通过使用Sigmoid函数改

进收敛因子的灰狼优化算法对时间卷积网络的区块数、滤波器数量和滤波器3个网络参数进行参数寻优。解决了传统时间卷积网络将HVDC系统启动时产生的振荡电流误判为故障采样点的情况。通过GWO算法优化TCN网络参数后运用于HVDC输电线路故障选区并同时选极,其效果显著,准确率明显高于未使用GWO算法优化参数的TCN网络,HVDC输电线路故障选区选极辨识率为100%。并能实现在过渡电阻高达800Ω时对HVDC输电线路进行准确故障辨识。

相比CNN网络,由于输电线路接地短路故障样本为时间序列数据,所以具有时间序列数据处理能力的时间卷积神经网络和长短期记忆神经网络更加适合,在网络训练中,时间卷积神经网络相比长短期记忆神经网络的训练准确率更高、过程更稳定且训练时间更短。

本文所提GWO-TCN网络模型方法仅使用了HVDC输电系统进行验证,今后的工作可以针对目前实际工程中运用较多的另外两种高压直流输电系统,即基于电压源换流器的柔性高压直流输电系统(voltage source converter based high voltage direct current transmission, VSC-HVDC)和基于模块化多电平换流器(modular multilevel converter, MMC)的柔性高压直流输电系统(MMC-HVDC)进行HVDC输电系统故障诊断模型改进,使检测方法更具有普适性和可迁移性。

#### 参考文献

- [1] 魏东,龚庆武,来文青,等.基于卷积神经网络的输电线路区内外故障判断及故障选相方法研究[J].中国电机工程学报,2016,36(S1):21-28.
- [2] 王桥梅,吴浩,杨杰,等.基于Teager能量算子和1DCNN的HVDC输电线路故障识别方法[J].智慧电力,2021,49(5):93-100.
- [3] 王桥梅,吴浩,胡潇涛,等.基于VMD多尺度模糊熵的HVDC输电线路故障识别方法[J].电力系统及其自动化学报,2021,33(5):134-144.
- [4] 胡伟,沈煜,刘浴霜,等.改进支持向量机的MMC-HVDC系统故障识别[J].智慧电力,2019,47(7):91-97.
- [5] 郑小霞,彭鹏.优选小波包和AdaBoost-SVM的柔性直流输电变流器故障诊断[J].电力系统及其自动化学报,2019,31(3):42-49.
- [6] GAN Z, LI C, ZHOU J, et al. Temporal convolutional networks interval prediction model for wind speed forecasting[J]. Electric Power Systems Research, 2021,191:106865.
- [7] 林世平,陈璐,陈开志,等.基于时间卷积网络的机器阅读理解[J].福州大学学报(自然科学版),2020,48(3):276-282.
- [8] ZHU R, LIAO W, WANG Y. Short-term prediction

- for wind power based on temporal convolutional network[J]. Energy Reports, 2020,69: 424-429.
- [9] 张西宁,刘书语,余迪,等.改进深度卷积神经网络及其在变工况滚动轴承故障诊断中的应用[J].西安交通大学学报,2021,55(6):1-8.
- [10] 金涛,王晓峰,田润澜,等.基于改进1DCNN+TCN的雷达辐射源快速识别方法[J/OL].系统工程与电子技术, 2021; 1-9 [2021-08-05 ]. <http://kns.cnki.net/kcms/detail/11.2422.tn.20210713.1314.009.html>.
- [11] PRADHAN M, ROY P K, PAL T. Oppositional based grey wolf optimization algorithm for economic dispatch problem of power system [J]. Ain Shams Engincering Journal, 2018,9(4): 2015-2025.
- [12] 李小伟,陈楚,陶毅刚,等.基于IGWO-BP的配电网接线方式综合评价[J].电子测量技术,2020,43(3): 71-76.
- [13] SHAKARAMI M R, DAVOUDKHANI I F. Wide-area power system stabilizer design based on Grey Wolf Optimization algorithm considering the time delay[J]. Electric Power Systems Research, 2016, 133: 149-159.
- [14] 张志宏,刘传领.基于灰狼算法优化深度学习网络的网络流量预测[J].吉林大学学报(理学版),2021,59(3): 619-626.
- [15] 杨晓敏.改进灰狼算法优化支持向量机的网络流量预测[J].电子测量与仪器学报,2021,35(3):211-217.

#### 作者简介

刘辉,博士,教授,硕士生导师,主要研究方向为电网控制与智能制造、电力电缆故障诊断。

E-mail:huiliu@hbust.edu.cn

李永康(通信作者),硕士研究生,主要研究方向为电网控制与智能制造、电力电缆故障诊断。

E-mail:101910291@hbust.edu.cn

张森,硕士研究生,主要研究方向为电网控制与智能制造。

E-mail:836673931@qq.com

刘维,硕士研究生,主要研究方向为电力电缆故障诊断。

E-mail:101910205@hbust.edu.cn