

基于改进卷积神经网络的新能源并网短路电流预测技术

于琳琳¹, 蒋小亮¹, 贾鹏¹, 孟高军², 丁咚¹

(1.国网河南省电力公司经济技术研究院, 河南 郑州 450052; 2.南京工程学院 电力工程学院, 江苏 南京 211167)

摘要: 随着新能源的大规模并网, 大电网短路电流特征更加复杂、难以预测。基于此, 文章提出了一种基于改进卷积神经网络的新能源并网短路电流预测技术。首先, 分析短路电流特点, 对短路电流进行变分模态分解, 得到本征模态函数; 其次, 对卷积神经网络进行改进, 利用多尺度特征提取将电流故障数据特征最大化, 引入注意力机制提取重要信息, 卷积过程中使用跳跃连接的方式防止前向传递时信息丢失, 有利于提高预测的准确性, 构建基于改进卷积神经网络的短路电流预测模型; 最后, 经过 PSCAD/EMTDC 电网模型进行验证。结果表明, 所提方法对短路电流峰值预测有着较高的精度, 与常见的极限学习机、支持向量机相比, 平均相对误差分别降低了 0.61%, 1.09%, 验证了文章所提方法的有效性。

关键词: 新能源; 改进卷积神经网络; 短路电流预测; 变分模态分解; 注意力机制

中图分类号: TK51; TK81; TM73 **文献标志码:** A **文章编号:** 1671-5292(2025)03-0408-08

0 引言

随着新能源接入电网的容量不断提升, 电力系统规模更加庞大, 导致发生短路时的故障特征更加复杂, 给传统的电力系统保护装置可靠性带来了严峻挑战。短路电流造成的热效应和电动力严重损坏电气设备, 并且短路电流峰值超过开关合分闸能力, 使得继电保护装置无法动作, 影响电力系统的安全稳定运行^[1-5]。故研究电网短路电流预测技术成为今后的一个热门方向^[6-8]。

目前, 国内外学者对短路电流预测研究取得了一定的成果。文献[9, 10]提出了基于安全点算法的电流预测方法, 预测误差较小。文献[11, 12]通过最小二乘算法减少指数量级运算, 节省计算空间, 实时分析采集的信号。然而, 上述方法需要较多的电流波形实现故障特征提取, 采集数据时间较长, 无法适用于开关准确、快速断开短路故障的场景。

随着近年来人工智能技术的快速发展, 在电流预测领域也取得了一定的进展^[13, 14]。文献[15]提出了改进 BP 神经网络算法, 减少预测时间, 提升了预测准确性。随着深度学习的迅速发展, 电流

预测精度进一步提升, 卷积神经网络是一种典型的有监督学习算法, 具有很强的非线性拟合能力。文献[16, 17]提出了基于循环神经网络的电流预测方法, 与 BP 神经网络、支持向量机相比, 网络预测精度更高、计算速度更快。因此, 相比于传统数学方法, 通过神经网络对电流进行预测, 预测速度更快, 能够更好地应用于断路器分合故障电流中, 应用前景广阔。文献[18, 19]提出了基于极限学习机的短路电流峰值预测方法, 经过仿真验证, 预测精度较高, 但是面对庞大复杂的电网, 极限学习机本身特征拟合能力弱, 电流预测准确性会大大降低。

本文提出一种基于改进卷积神经网络的新能源接入电网短路电流预测技术。对短路电流进行变分模态分解, 得到网络输入。利用多尺度特征、注意力机制和跳跃连接对卷积神经网络进行改进, 构建短路电流预测模型。通过实验结果表明, 所提方法具有较高的短路电流预测精度。

1 新能源并网故障电流特征分析

1.1 特征分析

新能源接入的电网故障特征须要将锁相环偏

收稿日期: 2024-01-24。

基金项目: 江苏省重点研发计划(BE2021094)。

作者简介: 于琳琳(1984-), 女, 硕士, 高级工程师, 研究方向为电网规划技术。

通信作者: 孟高军(1987-), 男, 博士, 副教授, 研究方向为新能源与储能技术。E-mail: gjun_m@126.com

差 θ_{p11} 考虑进去,进而影响派克变换和派克反变换。交流侧发生故障会导致并网点电压低于 0.9 p.u.,新能源低压穿越使得外环电压断开,得出的内环电流表达式如下:

$$\begin{cases} i_d^{\text{ref}} = \begin{cases} i_{d0}^{\text{ref}}, \sqrt{(KI_N)^2 - (i_q^{\text{ref}})^2} \\ 0, \frac{U}{U_N} > 0.9 \\ 2\left(0.9 - \frac{U}{U_N}\right)I_N, 0.2 \leq \frac{U}{U_N} \leq 0.9 \\ KI_N, \frac{U}{U_N} < 0.2 \end{cases} \\ i_q^{\text{ref}} = \begin{cases} i_q^{\text{ref}} \\ 0 \\ 0 \\ 0 \end{cases} \end{cases} \quad (1)$$

式中: $i_d^{\text{ref}}, i_q^{\text{ref}}$ 分别为 d, q 轴内环电流参考值; i_{d0}^{ref} 为故障发生前逆变器有功内环电流 d 轴指令值; U_N, I_N 分别为额定电压、额定电流; K 为控制系数,本文取为 1.5。

故障暂态阶段,内环电流能够快速跟踪响应,可以得到:

$$\begin{cases} i_d = i_d^{\text{ref}} \\ i_q = i_q^{\text{ref}} \end{cases} \quad (2)$$

新能源交流侧发生故障,公共耦合点电压幅值迅速下降,故障后的耦合点电压计算式为

$$\begin{bmatrix} e_a \\ e_b \\ e_c \end{bmatrix} = E_m \begin{bmatrix} \cos\theta_1 \\ \cos(\theta_1 - 120^\circ) \\ \cos(\theta_1 + 120^\circ) \end{bmatrix} \quad (3)$$

式中: E_m 为耦合点电压幅值; θ_1 为故障后相位。

锁相环采集相位信息后的派克变换为

$$T_{2r/3s} = \frac{2}{3} \begin{bmatrix} \cos\alpha & \cos(\alpha - 120^\circ) & \cos(\alpha + 120^\circ) \\ -\sin\alpha & -\sin(\alpha - 120^\circ) & -\sin(\alpha + 120^\circ) \end{bmatrix} \quad (4)$$

式中: α 为正常状态下的 d 轴和 a 轴的夹角。

故障时相位突变,锁相环相位偏差为 $\Delta\theta_{p11}$,因此故障后的夹角为

$$\alpha' = \theta_0 - \Delta\theta_{p11} \quad (5)$$

式中: θ_0 为正常状态时的电压相位。

若故障跳跃角较小,利用泰勒展开式原理,省略高阶分量,则近似认为 $\sin\Delta\theta_{p11} = \Delta\theta_{p11}$ 。因此,经过派克变换后的电压表达式为

$$\begin{bmatrix} e_d \\ e_q \end{bmatrix} = T_{3s/2r} \begin{bmatrix} e_a \\ e_b \\ e_c \end{bmatrix} = E_m \begin{bmatrix} \cos\Delta\theta_{p11} \\ \sin\Delta\theta_{p11} \end{bmatrix} \approx E_m \begin{bmatrix} \cos\Delta\theta_{p11} \\ \Delta\theta_{p11} \end{bmatrix} \quad (6)$$

逆变器输出电压表达式为

$$\begin{bmatrix} u_d \\ u_q \end{bmatrix} = \begin{bmatrix} E_m + Ri_d^{\text{ref}} - \omega_0 Li_q^{\text{ref}} \\ E_m \Delta\theta_{p11} + Ri_q^{\text{ref}} + \omega_0 Li_d^{\text{ref}} \end{bmatrix} = \begin{bmatrix} M_1 \\ E_m \Delta\theta_{p11} + M_2 \end{bmatrix} \quad (7)$$

式中: u_d, u_q 分别为 d, q 轴端口电压; R, L 分别为逆变器端口到耦合点之间的电阻和电感; ω_0 为角频率; M_1, M_2 分别为 u_d, u_q 的常数项。

对式(7)进行反派克变换,得到三相坐标系下的端口电压:

$$\begin{bmatrix} u_a \\ u_b \\ u_c \end{bmatrix} = T_{3s/2r} \begin{bmatrix} u_d \\ u_q \end{bmatrix}^T =$$

$$\begin{bmatrix} u_d \cos(\theta_0 + \Delta\theta_{p11}) - u_q \sin(\theta_0 + \Delta\theta_{p11}) \\ u_d \cos(\theta_0 + \Delta\theta_{p11} - 120^\circ) - u_q \sin(\theta_0 + \Delta\theta_{p11} - 120^\circ) \\ u_d \cos(\theta_0 + \Delta\theta_{p11} + 120^\circ) - u_q \sin(\theta_0 + \Delta\theta_{p11} + 120^\circ) \end{bmatrix} \quad (8)$$

以 a 相为例,其端口电压为

$$u_a = K_1 \cos(\theta_0 + \varphi) + K_2 e^{-\frac{2t}{\tau}} \cos\theta_0 + K_3 e^{-\frac{t}{\tau}} \cos[(\omega_0 + \omega_s)t + \gamma + \beta] + K_4 e^{-\frac{2t}{\tau}} \sin[(\omega_0 + 2\omega_s)t + \mu] \quad (9)$$

式中: $K_1, K_2, K_3, K_4, \varphi, \gamma, \beta, \mu$ 均为电压特征系数; ω_s 为谐波角频率; τ 为时间衰减系数。

输出电压和电流关系如下:

$$u_a = L \frac{di_a}{dt} + Ri_a + e_a \quad (10)$$

对故障电流 i_a 求解一阶线性微分方程,得到:

$$i_a(t) = Ce^{-\frac{R}{L}t} + e^{-\frac{R}{L}t} \int \left(\frac{u_a - e_a}{L} \right) e^{\frac{R}{L}t} dt \quad (11)$$

式中: C 为一阶线性微分方程系数。

将式(3)、式(10)带入式(11),得到故障电流表达式为

$$\begin{aligned} i_a = & Ce^{-\frac{R}{L}t} + I_1 \sin(\omega_0 t + \varphi) + I_2 \sin(\omega_0 t + \Delta\theta) + \\ & I_3 e^{-\frac{2t}{\tau}} \sin(\omega_0 t) + I_4 e^{-\frac{t}{\tau}} \sin[(\omega_0 + \omega_s)t + \gamma + \beta] + \\ & I_5 e^{-\frac{2t}{\tau}} \sin[(\omega_0 + 2\omega_s)t + \mu] \end{aligned} \quad (12)$$

式中: I_1, I_2, I_3, I_4, I_5 均为电流特征系数。

由式(12)可知,短路电流主要包含:两组工频分量;两组故障后振荡衰减的谐波,表示为三角函数和衰减指数函数相乘;工频分量相乘指数衰减函数的 2 倍频值;直流衰减分量,表示为指数衰减函数和常数相乘。

1.2 变分模态分解

变分模态分解是一种将原信号分解成若干本

征模态函数的技术,通过希尔伯特变换、多频段处理以及维纳滤波原理实现的。最优中心频带通过带宽最小的原则计算出来,各个本征模态表达式为

$$U_k=A_k(t)\cos[\varphi_k(t)] \quad (13)$$

式中: A_k, φ_k 分别为第 k 个本征模态函数的幅值和相位。

本征模态函数的约束条件为

$$\begin{cases} \min_{(\{u_k\}, \{\omega_k\})} \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) \cdot u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s.t. } \sum_k u_k(t) = f(t) \end{cases} \quad (14)$$

式中: $\{u_k\}$ 为所有本体集合; $\{\omega_k\}$ 为所有中心频率集合; $f(t)$ 为输入的原始信号; $\delta(t)$ 为狄拉克函数。

将式(14)变换成无约束的拉格朗日函数为

$$\begin{aligned} L(\{u_k\}, \{\omega_k\}, \lambda) = & \alpha \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) \cdot u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \\ & \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle \end{aligned} \quad (15)$$

为了保证分解的本征模态函数拥有中心频率的有限带宽,同时使得带宽之和最小,须要对固有模态函数和中心频率进行更新,使得式(15)的目标函数最小,通过交替方向算子得出拉格朗日函数最优解。整个求解过程如下。

初始化 $\{u_k^1\}, \{\omega_k^1\}, \lambda^1, n$, 所有值均设置为 0, α 初始化值设置为 2 000, 更新本体的计算式为

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)} \quad (16)$$

$\omega_k^{n+1}, \lambda^{n+1}$ 更新公式如下:

$$\begin{cases} \omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k(\omega)|^2 d\omega} \\ \lambda^{n+1} = \lambda^n + \tau \left(f - \sum_k u_k^{n+1} \right) \end{cases} \quad (17)$$

不断更新式(17),设置误差精度 ε , 直至满足式(18)误差精度要求,停止更新。

$$\sum_k \left\| \left\| u_k^{n+1} - u_k^n \right\|_2 \right\|_2^2 / \left\| \left\| u_k^n \right\|_2 \right\|_2^2 < \varepsilon \quad (18)$$

2 短路电流预测方法

随着新能源接入电网容量提升,短路电流是在复杂环境下获取的,容易受到外界因素影响,导致电流峰值预测难度加大。为了充分发挥卷积神经网络的故障提取能力,防止梯度退化、消失问题的发生,本文提出基于改进卷积神经网络的新能源接入电网短路电流预测方法,设计多尺度特征提取和跳跃连接模块,引入注意力机制,实现复杂环境下的短路电流预测。

本文提出的卷积神经网络用于短路电流预测,首先利用上一节变分模态分解方法将采集的短路电流进行变分模态分解,提取出短路电流时序本征模态函数,然后将多维时间尺度本征模态函数输入卷积神经网络中进行特征学习,最后经过输出得到短路电流峰值。

2.1 卷积神经网络

卷积神经网络是一种典型的深度学习算法,属于前馈神经网络,具有很强的非线性特征提取能力,主要包含卷积层、池化层、全连接层。多个卷积核逐层提取输入数据特征,空间上采用降采样的方式降低输入维度^[20,21]。

卷积层由多个卷积核构成,特征提取输入数据,每个卷积核包含权重和偏置,与上一层输出特征进行卷积,经过激活函数非线性变化后得出输出特征,具体表达式如下:

$$X_{i,j}^{l+1} = f \left(\sum_{j=1}^L \sum_{i=1}^m (X_{i,j}^l w_{i,j}^l) + b \right) \quad (19)$$

式中: $X_{i,j}^{l+1}$ 为第 $l+1$ 层网络特征图 i 的第 j 维值; $f(\cdot)$ 为激活函数; L 为卷积核的尺寸; $w_{i,j}^l$ 为第 l 层网络特征图 i 的第 j 维特征权值; b 为偏置。

2.2 注意力机制

注意力机制是将输入特征从水平、垂直两个方向进行平均池化,提取出最重要信息。两个方向的池化操作计算式如下:

$$\begin{cases} Z_c^h(h) = \frac{1}{W} \sum_{0 \leq i \leq W} x_c(h, i) \\ Z_c^w(w) = \frac{1}{H} \sum_{0 \leq j \leq H} x_c(j, w) \end{cases} \quad (20)$$

式中: $Z_c^h(h), Z_c^w(w)$ 分别为水平方向、垂直方向形成的

输入特征; x 为输入特征; c 为输入特征图通道编号; h,j 为某一特征图高度; i,ω 为某一特征图宽度; H,W 分别为特征图总的高度、宽度。

注意力层输出为

$$y_c(i,j)=x_c(i,j) \cdot g_c^h(i) \cdot g_c^w(j) \quad (21)$$

式中: $y_c(i,j)$ 为注意力层输出; i,j 分别为输入宽度、高度; $g_c^h(i),g_c^w(j)$ 分别为注意力权重水平方向和垂直方向的值。

2.3 多尺度特征提取

常规的卷积神经网络是通过固定尺寸的卷积核进行卷积的,提取特征时不能将复杂时间维度的短路电流全面学习到,故本文提出一种改进的卷积神经网络,即多尺度动态自适应卷积,其中多尺度特征提取的过程如图1所示。通过并行卷积的方式多尺度提取特征,有利于提高故障特征多尺度提取的能力和模型计算速度。




图1 多尺度特征提取架构

Fig.1 Multi scale feature extraction architecture

对输入特征进行融合、池化、归一化以及激活操作得出输出特征,整个过程为

$$Z=f(\mathcal{R}(X_{\max})) \quad (22)$$

式中: $f(\cdot)$ 为激活函数; X_{\max} 为最大池化输入特征; \mathcal{R} 为归一化行为。

各个卷积的权重经过自适应函数和全连接层得出,表达式为

$$\begin{cases} a_s = \frac{e^{A_z}}{e^{A_z} + e^{B_z} + e^{C_z} + e^{D_z}} \\ b_s = \frac{e^{B_z}}{e^{A_z} + e^{B_z} + e^{C_z} + e^{D_z}} \\ c_s = \frac{e^{C_z}}{e^{A_z} + e^{B_z} + e^{C_z} + e^{D_z}} \\ d_s = \frac{e^{D_z}}{e^{A_z} + e^{B_z} + e^{C_z} + e^{D_z}} \end{cases} \quad (23)$$

式中: a_s, b_s, c_s, d_s 分别为各个输入层卷积的权重。

所有卷积权重乘上对应尺度卷积核后相加,

得出输出相量 Y 的值,计算过程为

$$\begin{cases} Y=a_s X_1 + b_s X_2 + c_s X_3 + d_s X_4 \\ a_s + b_s + c_s + d_s = 1 \end{cases} \quad (24)$$

2.4 跳跃连接

常规卷积神经网络前后卷积层首尾相连,无法学习到输入层和下一层之间的关系,降低了特征学习的效率。基于此,本文采用跳跃连接的方式,结构如图2所示。




图2 跳跃连接

Fig.2 Jump connection

从图2中可知,前一卷积层输入和后一卷积层中间加入跳跃连接线,使得后面卷积层既能学习到前一卷积之后的特征,又能学习到前一层的输入信息,提高了学习效率。

3 电流预测方案

3.1 网络模型

基于改进卷积神经网络的新能源接入电网短路电流预测模型的输入数据、输出数据如下。

输入数据:当电网发生故障时,震荡过程会在半个周期内结束,因此为了保险起见,采集一个周期短路电流数据,并且采样率设置为2.4 kHz,对提取的短路电流进行变分模态分解,得出的4个本征模态函数为模型输入数据。因此本文设置的模型输入数据维度为 4×2400 。

输出数据:Softmax分类器具有很强的分类能力,短路电流峰值作为网络输出,故输出数据维度为 1×1 。

3.2 电流预测过程

本文提出的新能源接入电网短路电流预测方法步骤如下。

步骤一:预处理。将样本划分为训练集和测试集两类,采集的电网短路电流作为输入数据,归一化处理这些输入数据,计算式如下:

$$\hat{x}_i = \frac{x_i - \min(x_i)}{\max(x_i) - \min(x_i)} \quad (25)$$

步骤二:对采集的短路电流进行变分模态分解,得出本征模态函数,将其输入至模型中。

步骤三:将训练集输入到模型中,前向传播网

络深层次学习短路故障电流特征, 使用 BPTT 算法和交叉损失函数反向传播网络更新参数, 得到最佳参数的模型。

步骤四: 利用测试集验证所构建最佳参数模型对短路电流的预测能力, 进而验证本文方法的有效性。

整个模型的预测流程如图 3 所示。

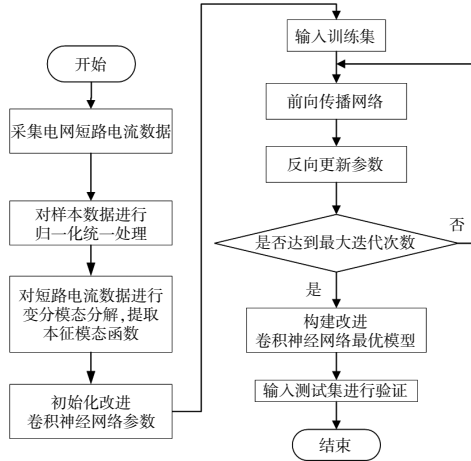


图 3 短路电流预测流程

Fig.3 Short circuit current prediction process

4 仿真验证

4.1 数据集构建

如图 4 所示, 在 PSCAD/EMTDC 仿真软件里构建新能源接入电网模型, 验证本文方法的有效性。分布式电源包含光伏发电机和风力发电机, 其中光伏发电机 80 个, 每个光伏发电机额定容量为 1 MW; 风力发电机 40 个, 每个风力发电机容量为 2 MW。仿真步长设置为 1 s, 采样率为 2 400 Hz。送出线路参数如下: 长度为 300 km; 单位距离的正负序阻抗 r_1 、电感 l_1 、电容 c_1 分别为 0.075 8 Ω /km, 0.839 22 mH/km, 0.014 μ F/km; 单位距离的零序阻抗 r_0 、电感 l_0 、电容 c_0 分别为 0.154 21 Ω /km, 2.643 9

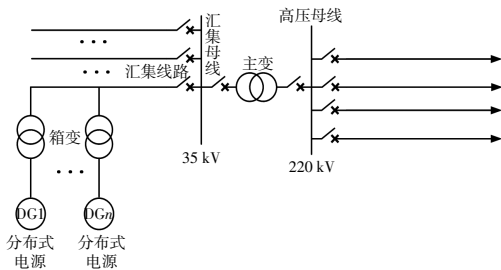


图 4 分布式新能源接入电网拓扑图

Fig.4 Topology diagram of distributed new energy integration into the power grid

mH/km, 0.009 296 μ F/km。

4.2 网络结构

设置输入层卷积尺寸为较大的 32×32, 提高对输入数据的感受野, 设置隐藏层卷积尺寸为较小的 4×4, 更加充分提取短路电流故障数据。分别设置三相短路故障、两相短路接地 (AB 相接地、BC 相接地、AC 相接地)、两相间短路故障 (AB 相、BC 相、AC 相)、单相接地故障 (A 相接地、B 相接地、C 相接地) 10 种故障。

对模型效果进行评价, 评价计算式如式 (26) 所示。

$$\begin{cases} \mathcal{E}_{MAPE} = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \\ \mathcal{E}_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \end{cases} \quad (26)$$

式中: \mathcal{E}_{MAPE} , \mathcal{E}_{RMSE} 分别为平均相对误差和均方根误差, 两者值越小, 说明模型越完美; n 为样本数量;

\hat{y}_i, y_i 分别为预测值和实际值。

为了更好地确定改进卷积神经网络的隐藏层层数, 分别在不同隐藏层层数下进行初步电流预测, 设置迭代次数为 100, 得出 MAPE 和隐藏层层数之间的关系如图 5 所示。从图 5 中可知, 当隐藏层层数达到 4 时, MAPE 最小, 为 0.74%, 若此时仍然提高隐藏层层数, MAPE 有所上升, 使得网络出现过拟合现象, 故在后面训练中设置隐藏层层数为 4。




图 5 故障诊断准确率和隐藏层层数的关系

Fig.5 The relationship between fault diagnosis accuracy and the number of hidden layers

当设置隐藏层层数为 4 时, 模型损失函数随迭代次数增加的变化过程如图 6 所示。从图 6 中可知, 当迭代次数为 200 次以上时, 模型损失函数达到稳定的最小值, 即 0.86。为了防止迭代次数过多对网络造成负担, 后续验证中选择迭代次数为 200。




图6 损失函数和迭代次数的关系

Fig.6 The relationship between loss function and iteration times

4.3 结果分析

选取 25 个样本,对本文方法、极限学习机和支持向量机进行训练预测,不同方法的电流预测结果如图 7 所示。从图 7 中可知,本文所提预测方法离实际值最近,显然改进卷积神经网络的短路电流预测曲线更加接近真实的情况,拟合程度更高。




图7 不同方法电流预测结果对比

Fig.7 Comparison of current prediction results using different methods

为了验证本文方法的先进性,将所提方法与极限学习机、支持向量机进行对比,得出的电流预测评价结果如图 8 和表 1 所示。从图 8 中可以看




图8 不同方法误差值结果对比

Fig.8 Comparison of error values from different methods

出:本文所提改进卷积神经网络的 MAPE 最低,当迭代次数达到 112 次时即可收敛,保持最低的 MAPE 不变;极限学习机和支持向量机效果较差,MAPE 较高,迭代次数分别达到 123 和 147 时才会收敛。从表 1 中可知,相比于极限学习机、支持向量机,本文所提方法的 MAPE 分别降低了 0.61%,1.09%,RMSE 分别降低了 5.99,14.88。说明本文方法在求解新能源接入电网短路电流预测中拥有更佳的求解性能。

表 1 不同方法模型求解效果对比

Table 1 Comparison of different method models for solving effects

方法	迭代次数	MAPE/%	RMSE
极限学习机	123	1.53	8.35
支持向量机	147	2.01	17.24
本文方法	112	0.92	2.36

为了验证本文所提方法对不同过渡电阻接地故障均有较好的预测效果,对不同方法在不同过渡电阻下的效果进行对比,结果如表 2 所示。从表 2 中可知,本文所提方法对故障电流预测仍然具有较低的 MAPE 和 RMSE,相比于极限学习机和支持向量机,预测效果仍然最好,验证了所提方法的有效性。

表 2 在不同过渡电阻下不同方法模型求解效果对比

Table 2 Comparison of different method models for solving effects under different transition resistances

过渡电阻/ Ω	本文方法		支持向量机		极限学习机	
	RMSE	MAPE/%	RMSE	MAPE/%	RMSE	MAPE/%
10	3.67	1.67	28.96	6.43	12.54	2.65
20	3.89	1.98	31.84	7.32	16.83	2.86
30	4.76	1.36	36.48	8.64	13.63	2.57
40	4.23	1.23	29.43	5.37	10.75	2.36
50	5.73	1.77	39.67	6.49	11.34	2.97
60	4.88	1.92	42.17	7.52	19.42	2.53
70	3.23	1.36	38.63	4.42	20.64	2.48
80	4.01	1.86	42.67	5.74	15.64	2.94
90	4.64	1.06	52.51	8.86	14.87	3.03
100	3.59	1.72	38.56	5.79	19.04	2.69

5 结论

本文构建了基于改进卷积神经网络的短路电流预测模型,并经 PSCAD/EMTDC 电网模型进行验证。结果表明,所提方法对短路电流峰值预测有着较高的精度,与常见的极限学习机、支持向量机相比,MAPE 分别降低了 0.61%,1.09%,RMSE 分

别降低了 5.99, 14.88, 验证了本文方法的有效性。

参考文献:

- [1] 刘素梅, 王丹枫, 李伟, 等. 适应电流差动保护的光伏电站边界接入容量分析[J]. 可再生能源, 2023, 41(5): 644-652.
- [2] 李吉峰, 唐克, 王孜航, 等. 计及多源互补特性的新型电力系统分布式电源承载能力评估[J]. 东北电力大学学报, 2023, 43(1): 62-68.
- [3] 施晓蓉, 李谟发, 周献. 逆变型分布式电源接入配电网的电流纵联保护研究[J]. 电力科学与技术学报, 2023, 38(5): 143-149.
- [4] 蔡传庆, 缪希仁, 吴晓梅, 等. 选择性低压短路保护技术[J]. 电器与能效管理技术, 2015(14): 1-6.
- [5] 张运洲, 单葆国. 中国电力系统发展运营面临的挑战和对策[J]. 中国电力, 2017, 50(1): 2-6.
- [6] 黄吕超, 张露阳, 胡源源, 等. 基于长短期记忆网络的短路电流过零点预测方法 [J]. 高电压技术, 2023, 49(12): 5022-5031.
- [7] 王梦娇, 魏新劳. 粒子群优化极限学习机的短路电流预测技术[J]. 电机与控制学报, 2022, 26(1): 68-76.
- [8] 马啸, 刘畅, 陈乐, 等. 应对不确定性短路电流超标的保护柔性跳闸策略[J]. 中国电机工程学报, 2019, 39(19): 5782-5792, 5906.
- [9] Polt A, Frohlich K. Two new methods for fast fault type detection by means of parameter fitting and artificial neural networks[J]. IEEE Transactions on Power Delivery, 1999, 14(4): 1269-1275.
- [10] Potal A, Frohlich K. A new algorithm enabling controlled short circuit interruption[J]. IEEE Transactions on Power Delivery, 2003, 18(3): 802-808.
- [11] 黄智慧, 张冬波, 邹积岩, 等. 基于改进 RLS 算法的短路电流相控开断控制系统设计[J]. 高电压技术, 2016, 42(10): 3214-3220.
- [12] 黄智慧, 段雄英, 邹积岩, 等. 基于改进 RLS 算法的故障电流参数估计[J]. 中国电机工程学报, 2014, 34(15): 2460-2469.
- [13] 王煜尘, 窦银科, 孟润泉. 基于模糊 C 均值聚类-变分模态分解和群智能优化的多核神经网络短期负荷预测模型[J]. 高电压技术, 2022, 48(4): 1308-1319.
- [14] 罗凤章, 张旭, 杨欣, 等. 基于深度学习的综合能源配电系统负荷分析预测 [J]. 高电压技术, 2021, 47(1): 23-32.
- [15] 陈建明, 张盼盼. 灰色 BP 神经网络模型在电力系统短路电流峰值预测中的应用[J]. 轻工学报, 2018, 33(4): 79-85.
- [16] 庞传军, 张波, 余建明. 基于 LSTM 循环神经网络的短期电力负荷预测[J]. 电力工程技术, 2021, 40(1): 175-180, 194.
- [17] 张洋, 姬波, 卢红星, 等. 基于 LSTM 神经网络的短期高压负荷电流预测方法 [J]. 计算机科学, 2019, 46(6): 49-54.
- [18] 陈俊杰, 缪希仁. 基于二维云模型的短路电流峰值预测[J]. 电力系统保护与控制, 2018, 46(23): 94-101.
- [19] 鄧萍, 缪希仁, 吴晓梅. 低压系统短路故障建模及电流预测技术[J]. 电力系统保护与控制, 2016, 44(7): 39-46.
- [20] 张若愚, 吴俊勇, 李宝琴, 等. 基于迁移学习的电力系统暂态稳定自适应预测 [J]. 电网技术, 2020, 44(6): 2196-2205.
- [21] 刘甚臻, 马超. 基于小波变换和混合深度学习的短期光伏功率预测[J]. 可再生能源, 2023, 41(6): 744-749.

Short circuit current prediction technology for new energy connected to the power grid based on improved convolutional neural network

Yu Linlin¹, Jiang Xiaoliang¹, Jia Peng¹, Meng Gaojun², Ding Dong¹

(1.State Grid Henan Electric Power Company Economic and Technological Research Institute, Zhengzhou 450052, China; 2.School of Electrical Engineering, Nanjing Institute of Technology, Nanjing 211167, China)

Abstract: With the large-scale integration of distributed power sources, the short-circuit current characteristics of large power grids become more complex and difficult to predict. Based on this, this article proposes a new energy grid short-circuit current prediction technology based on improved convolutional neural networks. Firstly, analyze the characteristics of short-circuit current, perform variational mode decomposition on short-circuit current, and obtain the intrinsic mode function; Secondly, the convolutional neural network is improved by utilizing multi-scale feature extraction to maximize the features of current fault data, introducing attention mechanisms to extract important information, and using skip connections during the convolutional process to prevent information loss during forward transmission, which is beneficial for improving the accuracy of prediction. A short-circuit current prediction model based on the improved convolutional neural network is constructed; Finally, the PSCAD/EMTDC power grid model was validated, and the experimental results showed that the proposed method has high accuracy in predicting the peak short-circuit current. Compared with common limit learning machines and support vector machines, the average relative error decreased by 0.61% and 1.09%, respectively. This verified the effectiveness of the proposed method and laid the foundation for limiting short-circuit current in large power grids.

Keywords: new energy; improving convolutional neural networks; short circuit current prediction; variational mode decomposition; attention mechanism