

基于时序卷积残差网络和鹧鸪优化算法的新能源电网安全稳定控制方法

张建新¹, 邱建¹, 朱煜昆^{2,3}, 朱益华^{2,3}, 杨欢欢¹, 徐光虎¹, 涂亮^{2,3}

(1.中国南方电网有限责任公司, 广东 广州 510663; 2.直流输电技术全国重点实验室(南方电网科学研究院有限责任公司), 广东 广州 510663; 3.广东省新能源电力系统智能运行与控制企业重点实验室, 广东 广州 510663)

摘要: 随着“双碳”目标的推进, 随机波动的新能源接入电网的规模和容量日益提升, 严重影响电网的安全稳定运行。针对大干扰故障电压稳定控制问题, 文章提出了一种基于时序卷积残差网络和鹧鸪优化算法的新能源电网电压安全稳定控制策略。首先, 利用时序卷积信息损失少、感受野宽以及残差网络深层特征提取能力强的优势, 构建基于时序卷积残差网络的电压稳定预测模型, 映射出敏感节点电压时序特征和电压稳定之间的关系; 其次, 构建电压稳定控制模型, 利用鹧鸪优化算法收敛速度快、搜索能力强的优势求解控制模型, 得出最佳切机和切负荷动作措施; 最后, 进行了仿真验证。验证结果表明, 所提方法提高了新能源电网电压安全稳定预测的准确性, 通过最佳的电压稳定控制策略提高了电网故障后的安全稳定运行水平。

关键词: 新能源; 大干扰故障; 时序卷积残差网络; 鹧鸪优化算法; 安全稳定控制

中图分类号: TK81; TM712 **文献标志码:** A **文章编号:** 1671-5292(2024)06-0845-08

0 引言

电网的安全稳定控制装置是保障电网受到干扰时维持系统稳定的二次装置, 主要安装于厂站, 多个安全稳定控制装置通过通信方式联合控制组成安全稳定的控制系统^[1,2]。安全稳定控制系统作为整个电力系统的第二道、第三道防线, 面对各种干扰时, 通过切机切负荷的方式实现系统低压减载、低频减载以及振荡解列等功能, 维持系统的稳定运行。随着“双碳”目标的推进, 高比例新能源接入电网使得系统运行更加复杂多变, 与同步发电机组相比, 新能源抗干扰能力弱、机械转动惯量低, 严重降低了电网的电压调节水平^[3,4]。当系统发生大干扰故障时, 复杂的潮流系统容易造成电网失稳, 更严重时会导致系统解列。因此, 亟需研究更加安全可靠、灵活准确的安全稳定控制方法来提高电网运行水平^[5-7]。

目前, 电网安全稳定控制方法主要是工作人员通过安全控制系统动作和预想动作进行对比判断。文献[8]整理了安全稳定控制系统故障类型, 但是没有将故障诊断方法应用其中。当面对大规模的电网数据时, 人工处理故障特征难度较大, 无

法准确实现电网稳定预测^[9]。目前相对成熟可靠、成本较低的电网安全控制系统是通过策略表的形式实现的。当发生大干扰故障时, 电网安全稳定控制装置通过故障类型、运行状态进行策略搜索, 实施应对措施, 该方法具有决策迅速的优势。然而, 面对新能源接入的复杂电网, 难以实现所有类型故障的精准判断, 容易出现决策失误的现象, 无法满足电网安全运行^[10,11]。

随着近年来人工智能技术的快速发展, 深度学习能够分析大量历史数据并且提取出有效信息, 建立输入输出隐藏特征关系^[12-15], 已经在电力系统中的态势感知^[12]、经济调度^[13]、能源管理^[14]以及负荷预测^[15]等领域得到深化应用。在电网安全稳定控制领域也取得了一定的成果。文献[16]提出了基于卷积神经网络和长短期记忆网络的电压稳定控制方法, 提升了大干扰故障后系统稳定运行水平。

基于上述分析, 本文提出了一种基于时序卷积残差网络和鹧鸪优化算法的电网电压安全稳定控制策略。构建基于时序卷积残差网络的电压稳定预测模型, 映射学习敏感节点电压时序特征和

收稿日期: 2023-12-13。

基金项目: 南方电网公司重点科技项目(000000KK52210139)。

作者简介: 张建新(1983-), 男, 硕士, 教授级高级工程师, 研究方向为电力系统稳定分析与控制。E-mail: zhangjianx0057@126.com

电压稳定之间的关系。采用鹌鹑优化算法求解电压稳定控制模型并得到控制策略,输出最佳切机和切负荷动作措施。

1 电压稳定性评估

电网电压稳定性是通过电压可接受性描述的,用二元表 $\langle u_{cr}, \tau_{cr} \rangle$ 表示,电压降到 u_{cr} 以下的时间不能高于 τ_{cr} 。若电压降低值满足多个二元表 $[\langle u_{cr1}, \tau_{cr1} \rangle, \langle u_{cr2}, \tau_{cr2} \rangle, \dots, \langle u_{cm}, \tau_{cm} \rangle]$,则电力系统稳定。电压稳定评估量化指标 ξ_m 是通过赋予不同降低区间的权值以及将电压降低水平对电网稳定的影响进行细化得来的,计算式如下:

$$\xi_m = 1 - \frac{\sum_{r=1}^{n-1} K_r \int_{t_r}^{t_{r+1}} [u_N - u(t)] dt - K_n \int_{t_n}^{t_n} [u_N - u(t)] dt}{\sum_{r=1}^{n-1} K_r \int_{t_r}^{t_{r+1}} [u_N - u(t)] dt} \quad (1)$$

式中: K_r, K_n 为权值; u_N 为额定电压; n 为所有的二元表个数; $u(t)$ 为 t 时母线电压的值; t_r, t_r 分别为电压高于、低于 u_{cr} 的时刻。

若电网临界稳定, ξ_m 值取为0,对所有的权值逐个求解,得到:

$$\begin{cases} K_1(u_N - u_{cr1})\tau_{cr1} = 1 \\ K_1(u_N - u_{cr1})\tau_{cr2} + K_2(u_N - u_{cr2})\tau_{cr2} = 1 \\ \dots \\ K_1(u_N - u_{cr1})\tau_{cm} + K_2(u_N - u_{cr2})\tau_{cm} + \dots + K_n(u_N - u_{cm})\tau_{cm} = 1 \end{cases} \quad (2)$$

当暂态电压降落的最小值大于二元表中的 u_{cr} 时,电网电压稳定评估指标计算式如下:

$$\xi_m = \min \left[1 - \frac{\max \left[\int_{t_0}^{t_0 + \tau_{cm}} (u_N - u(t)) dt \right]}{(u_N - u_{cm})\tau_{cm}} \right] \quad (3)$$

式中: τ_{cm}, u_{cm} 分别为第 m 个二元表的时间门限值 and 电压门限值; t_0 为电压降低时刻。

2 电压稳定预测

传统的电压稳定预测主要是通过机理建模得出的,但该方法预测时间长、准确率低、在线使用效果较差。人工智能的方法能够不用复杂的机理

建模实现非线性映射,挖掘数据特征建立直流系统运行状态和电压暂态稳定之间的关系。本文构建了基于时序卷积残差网络的电网电压稳定预测模型,映射出节点电压时序特征和电压稳定之间的关系。

神经网络层数加深能够学习更加复杂的电气数据特征,但是随着网络模型层数的加深,训练难度也迅速增大,出现梯度消失的问题。残差网络作为卷积神经网络的一种特殊形式,添加回退机制和层间短接线解决了梯度消失的问题,大大降低了网络训练难度,保证了足够的梯度去更新参数。

对于节点电压构成的特征矩阵,各个通道特征轴具有很强的相关性,然而传统的卷积感受野小、各个通道相互独立,容易造成信息缺失,并且横向卷积计算时间长、参数多。针对这一问题,本文用时序卷积代替传统卷积,沿着时间轴方向卷积的同时增大了感受野,包含了所有的横向特征,进而提高了特征信息挖掘能力和横向感受野范围。通过建立轻量化时序卷积残差网络模型,线性节点时序电压和电压稳定之间的关系。

时序卷积残差网络组件如图1所示,主要包含时序卷积层、短接线、修正线性激活单元以及批归一化层,具体的时序卷积残差网络模型由这些组件组合、堆叠形成。




图1 时序卷积残差网络组件

Fig.1 Temporal convolution residual network component

2.1 时序卷积层

时序卷积过程如图2所示,包含横向和纵向




图2 时序卷积过程

Fig.2 Temporal convolution process

两个方向。横向卷积增加或缩小宽度与输入特征的通道数相适应,所有的通道 j 均被感受野所覆盖,减少卷积核横向移动计算,大大节约了计算时间,提高了网络训练效率。纵向卷积根据节点电压时序特征沿着时间轴 i 移动的方向向下卷积,挖掘出特征序列时间轴方向的信息,每次滑窗计算后形成新的特征矩阵。

时序卷积层由 n 个不同的卷积核组成,对特征信息进行全方面提取,不同空间的局部特征形成不同信息的时序特征,沿着 j 通道方向合成这些序列,输出不同信息特征图,作为下层网络输入。

特征信号的时序卷积处理计算式如下:

$$x_{ij}^L = \text{con} \left[f \left(\sum_{i,j \in M_j^L} x_{(i+s,j)}^{L-1} K_{(i,j)}^L + b_j^L \right) \right] \quad (4)$$

式中: $x_{(i+s,j)}^{L-1}$, x_{ij}^L 分别为第 L 层的网络输入、输出; con 为沿着特征轴方向组合的多个卷积拼接结果; $f(\cdot)$ 为激活函数; K 为卷积核参数; b 为偏置; s 为每次在特定步长情况下沿着时间轴卷积移动的距离; M_j^L 为时序卷积矩阵。

2.2 短接线

在内部输入输出之间引入短接线的方式能够形成层数回退,假设输入 x 在加权后输出特征 $F(x)$,对相应部分相加得出最后的输出 $H(x)$,计算式如下:

$$H(x) = x + F(x) \quad (5)$$

通过短接线的方式使得内部权重从 $H(x)$ 变成 $H(x)-x$,梯度在反向传播过程中能够迅速、完整地接近输入层,提高参数寻优能力。

2.3 修正线性激活单元

为了防止网络模型特征学习复杂数据出现梯度消散的现象,引入修正线性激活单元,提高模型非线性学习能力,计算式如下:

$$\text{ReLU}(x_{in}) = \max(0, x_{in}) \quad (6)$$

式中: ReLU 为修正线性激活函数; x_{in} 为修正线性激活单元输入。

由式(6)可知,修正线性激活单元将所有负数控制为0,保留所有正数,具有较宽松的取值范围。

2.4 批归一化层

批归一化层统一所有数据尺度,使得网络的超参数敏感性降低,进而优化网络性能、提升训练速度。计算式如下:

$$\tilde{x} = \frac{x - \frac{1}{m} \sum_{i=1}^m x_i}{\sqrt{\frac{1}{m} \sum_{i=1}^m \left(x_i - \frac{1}{m} \sum_{i=1}^m x_i \right)^2 + \epsilon}} \gamma + \beta \quad (7)$$

式中: \tilde{x} 为网络自适应变化输出; x 为网络自适应变化输入; m 为每一批样本的数量; γ 和 β 分别为网络的缩放系数和平移系数,在反向传播中会自动更新优化。

2.5 电压稳定预测

本文基于时序卷积残差网络的电压稳定预测方法的模型求解过程如下。

步骤一:数据预处理。将关键节点母线电压时序数据作为网络输入来评估电压稳定水平,对数据进行归一化处理。

步骤二:时序卷积残差网络模型结构的确定。确定网络层数和每层神经元个数,本文使用ReLU激活函数,能够使得一些神经元值为0,防止出现过拟合的现象。

步骤三:利用训练集确定网络参数。使用训练集的关键节点母线电压时序数据作为网络输入,前向传播时序卷积残差网络。网络输出的是电压稳定评估量化指标 ξ_m ,若 ξ_m 高于阈值 ξ ,说明系统电压稳定;若 ξ_m 低于 ξ ,说明系统电压失稳。计算网络的输出电压稳定预测和实际电压状态的误差损失函数,根据损失函数最小原则反向更新网络参数,最后形成基于时序卷积残差网络的电压稳定预测模型。

3 电压稳定控制策略

3.1 电压稳定控制模型

电网电压稳定控制是一个动态优化的过程,仅仅使用切机或者切负荷的行为容易导致电网功率失去平衡,加重系统失稳程度。本文通过同时考虑切机和切负荷的方式进行优化控制,构建切机切负荷容量最小的控制模型,如下所示:

$$\min \left(\sum_{i=1}^{N_G} \Delta P_{G,i} u_i + \sum_{j=1}^{N_L} \Delta P_{L,j} u_j \right) \quad (8)$$

式中: $\Delta P_{G,i}$ 为第 i 个节点的发电机切除容量; $\Delta P_{L,j}$ 为第 j 个节点的负荷切除容量; N_G, N_L 分别为发电

机、负荷切除节点个数; u_i, u_j 分别为发电机、负荷切除系数。

切负荷系数 u_j 是通过维持电压稳定前提下考虑供电可靠性确定的, 发生大干扰故障时切除一定比例的负荷, 故 u_j 是 0~1 的连续变量。发电机通常是整台退出的, 故切机系数 u_i 是离散整数, 计算式如下:

$$u_i = \begin{cases} 1 & \text{第 } i \text{ 个母线切机动作} \\ 0 & \text{第 } i \text{ 个母线切机不动作} \end{cases} \quad (9)$$

以电压控制约束条件以满足电网运行状况, 设置电压稳定评估指标 ξ_m 高于阈值 ξ , 约束式如下:

$$\xi_{k,0} + \left(\sum_{i=1}^{N_G} \Delta P_{G,i} u_i \right) \lambda_{k,i} + \left(\sum_{j=1}^{N_L} \Delta P_{L,j} u_j \right) \lambda_{k,j} \geq \xi \quad (10)$$

式中: $\xi_{k,0}$ 为大干扰故障后不实施稳定控制措施时第 k 个节点的电压稳定评估指标; $\lambda_{k,i}$ 为电压稳定控制灵敏度。

$$\lambda_{k,i} = \frac{\xi_k - \xi_{k,0}}{\Delta P_i} = \frac{\Delta \xi_k}{\Delta P_i} \quad (11)$$

还要将功率平衡的约束条件考虑进去, 计算式如下:

$$S_{b,\min} \leq \sum_{i=1}^{N_G} \Delta P_{G,i} u_i - \sum_{j=1}^{N_L} \Delta P_{L,j} u_j \leq S_{b,\max} \quad (12)$$

式中: $S_{b,\min}, S_{b,\max}$ 分别为将发电机调频考虑进去时的不平衡容量最小值、最大值。

3.2 模型求解

鹈鹕优化算法是一个新的元启发式算法, 通过鹈鹕狩猎行为建立的数学模型进行最优解的求解, 具有收敛速度快、参数简单、全局搜索和局部搜索能力强的优势^[17]。

3.2.1 初始化

如果空间维度为 m , 鹈鹕数量为 n , 那么在 m 维空间中第 i 个鹈鹕的位置为

$$\mathbf{X}_i = [X_{i1}, X_{i2}, \dots, X_{im}] \quad (13)$$

在 m 维空间的所有 n 个鹈鹕位置为

$$\mathbf{X} = \begin{bmatrix} X_1 \\ X_2 \\ \dots \\ X_n \end{bmatrix} = \begin{bmatrix} X_{11} & X_{12} & \dots & X_{1m} \\ X_{21} & X_{22} & \dots & X_{2m} \\ \dots & \dots & \dots & \dots \\ X_{n1} & X_{n2} & \dots & X_{nm} \end{bmatrix} \quad (14)$$

初始化鹈鹕位置为

$$x_{ij} = l_j + \alpha \cdot (v_j - l_j) \quad i=1, 2, \dots, n; j=1, 2, \dots, m \quad (15)$$

式中: x_{ij} 为第 i 个鹈鹕的第 j 维位置; α 为随机数,

在 0~1 内变化; v_j, l_j 分别为第 j 维模型求解最大值、最小值。

3.2.2 向猎物移动

鹈鹕在这个阶段识别猎物位置时会朝着猎物移动, 随机分布搜索空间, 提高了算法的全局搜索能力, 每次迭代的鹈鹕位置为

$$x_{ij}^{p_1} = \begin{cases} x_{ij} + \sigma \cdot (P_j - I \cdot x_{ij}), & F_p < F_i \\ x_{ij} + \sigma \cdot (x_{ij} - P_j), & \text{其他} \end{cases} \quad (16)$$

式中: $x_{ij}^{p_1}$ 为第 i 个鹈鹕经过第一个阶段后的第 j 维位置; F_p 为猎物目标值; σ 为随机数, 在 0~1 内变化; I 为整数, 取值为 1 或者 2; P_j 为第 j 维的猎物位置。

若目标值得到优化, 则位置更新计算式如下:

$$x_i = \begin{cases} x_i^{p_1}, & F_i^{p_1} < F_i \\ x_i, & \text{其他} \end{cases} \quad (17)$$

式中: $x_i^{p_1}$ 为新的第 i 个鹈鹕位置; $F_i^{p_1}$ 为第 i 个鹈鹕在第一阶段后新的目标函数。

3.2.3 掠过水面

鹈鹕经过水面后张开翅膀将猎物放在喉咙, 提高了局部搜索能力, 每次迭代的鹈鹕位置更新计算式如下:

$$x_{ij}^{p_2} = x_{ij} + R \cdot (1 - t/T) \cdot (2\beta - 1) x_{ij} \quad (18)$$

式中: $x_{ij}^{p_2}$ 为第 i 个鹈鹕经过第二个阶段后的第 j 维位置; β 为随机数, 在 0~1 内变化; R 为整数, 取值为 1 或者 2; t 为目前的迭代次数; T 为设置的最大迭代次数。

若目标值得到优化, 则位置更新计算式如下:

$$x_i = \begin{cases} x_i^{p_2}, & F_i^{p_2} < F_i \\ x_i, & \text{其他} \end{cases} \quad (19)$$

式中: $x_i^{p_2}$ 为第 i 个鹈鹕新的位置; $F_i^{p_2}$ 为第 i 个鹈鹕在第二阶段后新的目标函数。

3.2.4 求解流程

在电压稳定控制前, 基于时序卷积残差网络的电压稳定预测模型对电压稳定性进行评估, 如果评估结果为电压不稳定, 应重新初始化鹈鹕优化算法参数, 直到电压稳定预测模型评估电压稳定时, 才能利用鹈鹕优化算法求解电压稳定控制模型, 解决电压稳定评估和电压稳定控制的问题。

将电压稳定控制结果,即切机切负荷容量设置为鸚鵡优化算法的个体,具体步骤如下。

步骤一:初始化鸚鵡优化算法参数:鸚鵡位置、速度、迭代次数、种群规模。

步骤二:根据各个鸚鵡的位置调节切机切负荷容量。

步骤三:根据系统电压节点母线序列,得出基于时序卷积残差网络的电压稳定预测情况。如果电压稳定,则计算电压稳定控制模型目标函数值,根据目标函数找到鸚鵡最佳位置,更新鸚鵡位置;如果电压失稳,则鸚鵡位置不更新。

步骤四:更新所有鸚鵡位置,判断是否收敛或者达到最大迭代次数,如果没有达到,返回步骤二;否则输出最后的各个切机切负荷容量。

求解流程如图 3 所示。

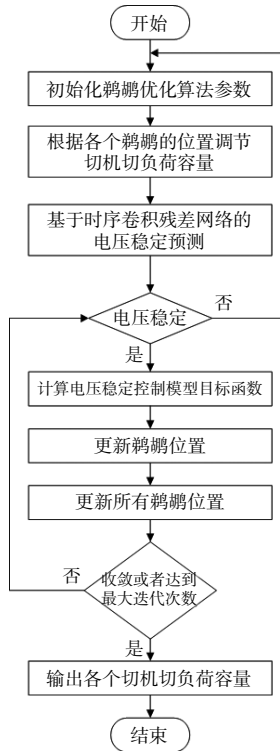


图 3 电压稳定控制流程

Fig.3 Voltage stability control process

4 仿真验证

4.1 数据集构建

为了验证本文方案的有效性,使用 PSASP 仿真软件搭建某地区电力系统模型进行暂态计算,地理接线图如图 4 所示,包括母线、发电厂、换流站、新能源发电区域。等值电路如图 5 所示,节点总数为 85。整个系统额定功率为 10 000 MW,额




图 4 电力系统地理接线图

Fig.4 Power system geographical wiring diagram

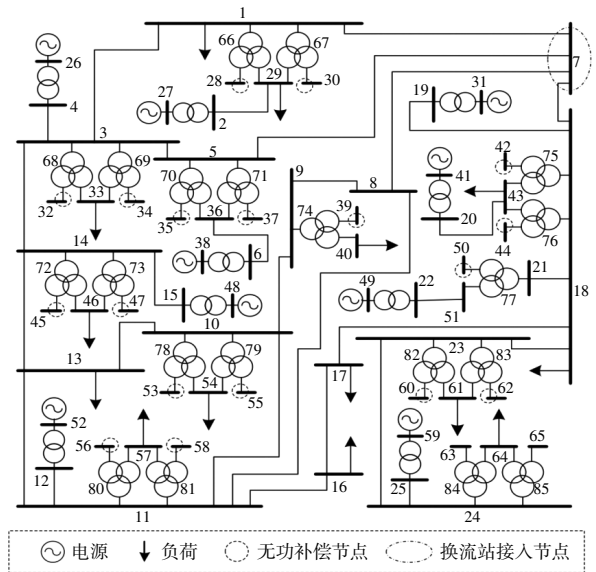


图 5 等值电路图

Fig.5 Equivalent circuit diagram

定电压为 220 kV。

4.2 电压稳定预测

基于时序卷积残差网络的电压稳定预测模型网络的输入为 35 个关键节点有功母线电压时序值,采样点个数为 2 000;网络的输出为电压稳定预测结果,即电压稳定评估量化指标 ξ_m 。因此,网络输入数据维度为 2 000×35,输出维度为 1×1。

模型的评价指标主要包含准确率、漏检率和误检率,计算式如下:

$$\begin{cases} A_{CC} = \frac{T_s + T_{us}}{T_s + F_s + T_{us} + F_{us}} \\ L_A = \frac{F_s}{T_s + F_s + T_{us} + F_{us}} \\ F_A = \frac{F_{us}}{T_s + F_s + T_{us} + F_{us}} \end{cases} \quad (20)$$

式中: A_{CC} 为准确率; L_A 为漏检率; F_A 为误检率; T 为预测正确的样本个数; F 为预测错误的样本

个数; s 为预测稳定的样本; us 为预测不稳定的样本。

下面确定时序卷积残差网络神经元个数。将时序卷积残差网络神经元个数分别从 100 设置到 500;使用 600 组数据集进行训练,观察 A_{cc} 的变化,以 A_{cc} 最大为原则确定神经元个数。通过实验结果,得到准确率和时序卷积残差网络神经元个数之间的关系,如图 6 所示。从图 6 中可知,当神经元个数为 400 时, A_{cc} 最大。因此将时序卷积残差网络神经元个数设置为 400。




图 6 电压稳定预测准确率和神经元个数之间的关系
Fig.6 The relationship between the accuracy of voltage stability prediction and the number of neurons

为了验证网络的训练效果,做出网络损失函数和迭代次数之间的关系曲线,如图 7 所示。




图 7 损失函数和迭代次数的关系
Fig.7 Relationship between loss function and number of iterations

从图 7 中可知,当迭代次数达到 500 时,网络趋于稳定,最小损失函数值为 0.38,说明网络训练效果较好。

为了验证本文方法对电压稳定预测效果的优越性,将本文所提的时序卷积残差网络与卷积神经网络、残差网络进行比较,得出不同方法的预测结果,如图 8、表 1 所示。从图 8 和表 1 中可知,当迭代次数达到 500 时,3 种方法的电压稳定预测准确率均达到最高,其中本文方法的准确率最高,同时漏检率和误检率最低,说明本文方法能够很好地预测电力系统的电压稳定性。




图 8 不同方法电压稳定预测结果
Fig.8 Voltage stability prediction results of different methods

表 1 不同方法电压稳定预测结果对比
Table 1 Comparison of voltage stability prediction results of different methods

方法	准确率/%	漏检率/%	误检率/%
本文方法	99.03	0.62	0.35
卷积神经网络	94.57	3.98	1.45
残差网络	87.62	7.85	4.53

4.3 电压稳定控制结果

考虑发电机的需求和负荷重要程度,将部分发电机节点和负荷节点作为控制节点。选取如图 4 所示的母线 1,2,3,4,5,12 作为切机点,母线 1,3,9,10,14,15 作为切负荷点。1,2,3,4,5,12 切机点可切除的容量分别为 13.45,25.63,17.92,21.67,8.11,14.41 p.u.;1,3,9,10,14,15 切负荷点可切除的容量分别为 8.45,9.24,6.72,7.34,7.88,8.91 p.u。

为了验证本文所提鹈鹕优化算法电压稳定控制方法的有效性,采取的电压优化控制措施如下:1,2,3,4,5,12 切机点可切除的容量分别为 0,0,10.42,0,6.23,0 p.u.;1,3,9,10,14,15 切负荷点可切除的容量分别为 4.21,0,0,0,3.56,2.62 p.u。

为了验证本文所提鹈鹕优化算法电压稳定控制方法的优越性,将本文方法与粒子群算法、遗传算法进行对比,不同方法下节点 9 的母线电压恢复结果如图 9 所示。从图 9 中可知:本文所提方法




图 9 母线电压恢复效果
Fig.9 Bus voltage recovery effect

的电压恢复效果最好,接近故障前电压;遗传算法的电压恢复效果最差,离故障前电压最远。

不同方法的目标函数随迭代次数的变化如图10所示。从图10中可知,与粒子群算法、遗传算法相比,本文方法的目标函数优化性能最优,电力系统应用性更强。




图10 不同方法目标函数结果对比

Fig.10 Comparison of objective function results of different methods

5 结束语

本文提出了一种基于时序卷积残差网络和鸚鵡优化算法的新能源电网电压安全稳定控制策略。基于时序卷积残差网络构建电压稳定预测模型,采用鸚鵡优化算法求解电压稳定控制模型,得出最佳切机和切负荷动作方式。仿真结果表明,本文方法有利于提高新能源电网电压稳定水平,与粒子群算法、遗传算法相比,控制策略效果更优。

参考文献:

[1] 唐建兴,翟勇,刘明顺,等.基于逻辑运算的新能源电网安稳控制策略研究[J].可再生能源,2022,40(5):675-682.

[2] 白申义,李建敏,许圣龙,等.大电网实时快速安全稳定控制系统研制[J].自动化仪表,2021,42(8):77-83.

[3] 葛维春,张诗钜,崔岱,等.海上风电送出与就地消纳技术差异综述[J].电测与仪表,2022,59(5):23-32.

[4] 杨冬锋,冉子旭,姜超.面向规模化风电消纳的电-气-氢能源互联系统协同规划[J].东北电力大学学报,

2023,43(3):91-100.

[5] 周毅,李一晨,傅幼书,等.电网弹性备用参与下的机组组合优化决策研究[J].哈尔滨理工大学学报,2023,28(3):56-66.

[6] 王龙飞,张建承,王博文,等.柔性励磁提升受端电网暂态稳定特性研究[J].浙江电力,2022,41(10):72-77.

[7] 摆世彬,田志浩,刘刚,等.考虑功角稳定与暂态过电压的新能源送端电网储能系统优化配置模型[J].可再生能源,2023,41(7):971-977.

[8] 黄龙祥,苗世洪,赵峰,等.大电网暂态稳定概率评估方法及风险指标研究[J].电力自动化设备,2013,33(11):105-110.

[9] 杨少波,刘道伟,安军,等.基于长短期记忆网络的电网动态轨迹趋势预测方法[J].中国电机工程学报,2020,40(9):2854-2866.

[10] 李君,何敏,黄守道,等.基于相暂态功率方向的有源配电网接地故障区段定位算法[J].高电压技术,2023,49(8):3205-3215.

[11] 王瑞梅,丛伟,王泽乾,等.基于工作电压相位比较的智能配电网故障判断方法[J].供用电,2023,40(6):26-33.

[12] 许鹏,孙毅,张健,等.基于人工智能代理的负荷态势感知及调控方法[J].电力系统自动化,2019,43(3):178-186.

[13] 杜继成,白江,鲁功强,等.基于人工智能的电网智能调度平台构建技术研究[J].电子器件,2023,46(2):573-577.

[14] 郭方洪,徐博文,张文安,等.基于学习优化的智能电网能量管理研究综述[J].控制与决策,2022,37(5):1089-1101.

[15] 胡洋,程志江,崔澜.基于LSTM的变频太阳能-空气源热泵系统逐时负荷预测研究[J].可再生能源,2022,40(7):866-873.

[16] 张哲,秦博宇,高鑫,等.基于CNN-LSTM网络的电网电压稳定紧急控制策略[J].电力系统自动化,2023,47(11):60-68.

[17] 王渴心,周军,王岩.基于鸚鵡优化和极限学习机的锂离子电池健康状态估计[J].电气应用,2023,42(11):16-25.

A new energy power grid security and stability control method based on time series convolutional residual network and pelican optimization algorithm

Zhang Jianxin¹, Qiu Jian¹, Zhu Yukun^{2,3}, Zhu Yihua^{2,3}, Yang Huanhuan¹, Xu Guanghu¹, Tu Liang^{2,3}
(1.China Southern Power Grid Co.,Ltd., Guangzhou 510663, China; 2.National Key Laboratory of DC Transmission Technology (China Southern Power Grid Research Institute Co.,Ltd.), Guangzhou 510663, China; 3.Guangdong Provincial Key Laboratory of Intelligent Operation and Control of New Energy Power System, Guangzhou 510663, China)

Abstract: With the advancement of the "dual carbon" goal, the scale and capacity of randomly fluctuating new energy connected to the power grid are increasingly increasing, seriously affecting the safe and stable operation of the power grid. This paper proposes a power grid voltage security and stability control strategy based on time series convolutional residual network and Pelican optimization algorithm for the problem of voltage stability control in large disturbance faults. Firstly, taking advantage of the advantages of low loss of temporal convolutional information, wide receptive field, and strong deep feature extraction ability of residual networks, a voltage stability prediction model based on temporal convolutional residual networks is constructed, mapping the relationship between sensitive node voltage temporal features and voltage stability; Secondly, a voltage stability control model is constructed to output control strategies, and the Pelican optimization algorithm is utilized to solve the control model with its fast convergence speed and strong search ability, resulting in the optimal measures for machine and load shedding actions. Finally, after simulation and verification, the experimental results show that the proposed method improves the accuracy of voltage safety and stability prediction in the power grid, and improves the safe and stable operation level of the power grid after faults through the optimal voltage stability control strategy.

Keywords: new energy; large interference fault; time series convolutional residual network; pelican optimization algorithm; security and stability control