

# 基于瞪羚算法优化卷积神经网络的光储构网型逆变器优化控制技术

庞秀岚<sup>1</sup>, 李晓峰<sup>1</sup>, 杨 祺<sup>1</sup>, 李 究<sup>1</sup>, 李雪红<sup>1</sup>, 靳文星<sup>2</sup>

(1. 国家电投集团青海光伏产业创新中心有限公司, 青海 西宁 810008; 2. 东南大学 电气工程学院, 江苏 南京 210096)

**摘要:** 随着光伏、储能等清洁能源大规模接入电网, 构网型控制技术在处理缺乏同步性的新能源电力系统电压稳定问题时具有明显优势。然而, 如何自适应控制构网型光储逆变器参数, 使得电网阻抗发生变化时电压仍然保持稳定是当前亟须解决的一个问题。基于此, 文章提出一种基于瞪羚算法优化卷积神经网络的光储构网型逆变器优化控制方法。首先, 搭建构网型逆变器控制模型, 对输出电压稳定性进行分析; 其次, 基于卷积神经网络建立逆变器参数控制模型, 利用瞪羚优化算法寻优能力强、搜索速度快的特点优化卷积神经网络超参数, 提升模型特征学习能力, 输出逆变器控制参数; 最后, 选取某光储发电地区进行仿真验证。仿真结果表明, 所提构网型光储逆变器控制方法能够根据电网阻抗实时变化自适应优化控制参数, 实现电压稳定输出, 具有较强的实际工程意义。

**关键词:** 清洁能源; 构网型控制; 光储逆变器; 瞪羚算法; 卷积神经网络

**中图分类号:** TK51; TM73 **文献标志码:** A **文章编号:** 1671-5292(2025)05-0687-09

## 0 引言

随着“双碳”目标的推进, 建设以新能源为主的新型电力系统成为未来的趋势, 其中以光伏、储能为代表的清洁能源是新能源发电的重要部分<sup>[1,2]</sup>。新能源并网逆变器分为跟网型和构网型两类<sup>[3,4]</sup>, 其中: 跟网型逆变器测量的并网点相位作为电压相位参考基准, 对电网进行跟随, 可以等效成一个电流源, 但跟网型控制受大电网影响, 发生扰动时容易失稳; 构网型逆变器保持与电网同步, 可以等效成一个电压源, 能够自适应电压、频率扰动, 有利于提升新能源消纳能力。然而随着电网运行特性发生变化, 当前构网型逆变器控制容易造成电压失稳, 因此, 亟须提出一种新的构网型逆变器参数控制方法, 能够自适应电网运行变化, 进而提升系统稳定性。

目前, 已经研究了一些逆变器参数控制方法来解决新能源发电引起的振荡问题。文献[5]通过搭建状态空间和阻抗模型, 实现逆变器控制参数和稳态运行点对稳定性影响的分析。文献[6]分析了新能源控制参数和构网型控制参数之间的耦合

关系和不同状态下的灵敏度, 然而该参数控制方法面对满足电网动态变化和故障穿越需求时, 无法保证系统的稳定性。文献[7]使用解耦下垂系数和阻尼环路防止系统振荡, 但是如何设置具体阻尼系数难度较大。文献[8]针对并联至电网的构网型逆变器, 使用功率折合系数提升电网抗干扰能力。然而, 上述逆变器参数控制方法无法自适应电网状态, 面对电网阻抗变化的新能源电力系统, 不能动态更新参数来维持系统稳定。

针对电网阻抗变化导致的系统失稳问题, 文献[9-11]使用非线性控制器的方式提高系统鲁棒性, 然而该方法计算量大、电网阻抗动态响应能力不足。文献[12]使用电网阻抗估计技术控制调节器参数, 使得弱电网下的逆变器仍然保持高带宽和宽相位裕度。文献[13]提出在线更新逆变器串并联环路微分系数的方法, 将相角裕度作为约束, 提高了并网逆变器对系统的抗干扰能力和鲁棒性。

随着近年来人工智能技术的快速发展, 在基于数据驱动分析的参数自适应调整上具有很好的

收稿日期: 2024-07-18。

基金项目: 国家电投集团科技项目(KYTC2023 GF03)。

作者简介: 庞秀岚(1966-), 女, 博士, 教授级高级工程师, 研究方向为电气工程及其自动化、新能源发电和储能。

E-mail: Pangxiulan\_12123@163.com

动态响应能力。文献[14]提出基于神经网络的多逆变器参数优化技术,将闭环极点和控制参数之间的关系进行特征映射,实现逆变器控制参数自适应更新。然而,神经网络属于机器学习算法,只能学习浅层特征,无法拟合复杂高维数据之间的关系<sup>[15]</sup>。随着深度学习迅速发展,卷积神经网络因非线性拟合能力和自学习能力强的优势被越来越多的学者所关注<sup>[16]</sup>。在参数优化方面,文献[17]采用粒子群算法优化卷积神经网络参数,提升了模型的输出精度。然而粒子群算法固有参数较多、求解时间长,无法满足光储构网型逆变器参数实时控制的需求。瞪羚算法是近年来提出的一种智能群体优化算法,具有寻优能力强、收敛速度快的优势<sup>[18]</sup>。

基于上述研究,本文将卷积神经网络应用于光储构网型逆变器参数控制中,提出一种基于瞪羚算法优化卷积神经网络的光储构网型逆变器优化控制方法。搭建构网型逆变器控制模型,对输出电压稳定性进行分析。基于卷积神经网络建立逆变器参数控制模型,通过瞪羚算法优化卷积神经网络超参数,提升模型特征学习能力,得到逆变器控制参数。经过试验表明,所提构网型光储逆变器控制方法能够根据电网阻抗实时变化自适应优化控制参数,实现电压稳定输出。

### 1 构网型逆变器控制原理

#### 1.1 原理分析

构网型逆变器控制及其接入大电网结构如图1所示,控制部分包含电流控制、电压控制、下垂控制,接入电网电路部分包含LC滤波器等效电阻  $r_f$  和等效电感  $L_f$ 、大电网等效电阻  $r_g$  和等效电感  $L_g$ 。构网型逆变器可以等效成电压源,控制方

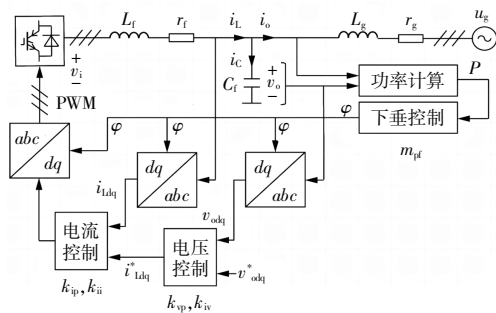


图1 构网型逆变器控制及其接入大电网结构

Fig.1 Grid type inverter control and its connection to the large power grid structure

式包含电流内环控制和电压外环控制。电流内环控制使并网电流同步指令电流,保证并网时维持较大的功率因素;电压外环控制起到维持直流电压稳定的作用。

电流内环控制表达式如下:

$$\begin{cases} Z_{i-pi} = k_{ip} + \frac{k_{ii}}{s} \\ G_i = \frac{Z_{i-pi}}{Z_{i-1}} \end{cases} \quad (1)$$

式中: $Z_{i-pi}$ 为电流内环控制中的PI调节器等效阻抗; $k_{ip}, k_{ii}$ 分别为电流调节比例系数、积分系数; $s$ 为拉式变换算子; $G_i$ 为电流内环控制增益系数; $Z_{i-1}$ 为电流内环控制虚拟等效阻抗。

电压外环控制表达式如下:

$$\begin{cases} Z_{v-pi} = k_{vp} + \frac{k_{iv}}{s} \\ G_v = \frac{Z_{i-1} // Z_{vc-1}}{Z_{v-pi}} \end{cases} \quad (2)$$

式中: $Z_{v-pi}$ 为电压外环控制中的PI调节器等效阻抗; $k_{vp}, k_{iv}$ 分别为电压调节比例系数、积分系数; $G_v$ 为电压外环控制增益系数; $Z_{vc-1}$ 为电压外环控制和滤波器电容的虚拟等效阻抗; $//$ 为阻抗并联的符号。

无下垂控制时的逆变器输出电压表达式为

$$v_{odq}^+ = G_v v_{odq}^{+*} - \frac{Z_{i-1} Z_{vc-1}}{Z_{i-1} + Z_{vc-1}} i_{odq}^+ \quad (3)$$

式中: $v_{odq}^+, v_{odq}^{+*}, i_{odq}^+$ 分别为逆变器无下垂控制情况下的正频率电压输出、电压参考、电流输出。

此时,逆变器输出阻抗为

$$Z_s = \begin{bmatrix} \frac{Z_{i-1} Z_{vc-1}}{Z_{i-1} + Z_{vc-1}} & 0 \\ 0 & \frac{Z_{i-1} Z_{vc-1}}{Z_{i-1} + Z_{vc-1}} \end{bmatrix} \quad (4)$$

逆变器受下垂控制影响输出不对称阻抗,其中下垂控制表达式为

$$G_{pf} = m_{pf} \frac{1}{1 + \frac{s}{\omega_f}} \quad (5)$$

式中: $G_{pf}$ 为下垂控制系数; $m_{pf}$ 为下垂增益系数; $\omega_f$ 为截止低通滤波器角频率,经过低通滤波器能够降低高频噪声含量。

最终考虑下垂控制的逆变器输出阻抗表达式为

$$Z_o = \begin{bmatrix} \frac{Z_{i-1}Z_{vc-1}}{Z_{i-1}+Z_{vc-1}} + Z_{pf}^+ & Z_{pf}^- \\ Z_{pf}^- & \frac{Z_{i-1}Z_{vc-1}}{Z_{i-1}+Z_{vc-1}} + Z_{pf}^+ \end{bmatrix} \quad (6)$$

式中: $Z_{pf}^+$ , $Z_{pf}^-$ 分别为等效下垂控制虚拟正阻抗、负阻抗。

$$\begin{cases} Z_{pf}^+ = \frac{jV_0^+}{2 \left[ \frac{s}{G_{pf}} + j \frac{(I_0^+ - I_0^-)}{2} \right]} \\ Z_{pf}^- = \frac{jV_0^-}{2 \left[ \frac{s}{G_{pf}} + j \frac{(I_0^+ - I_0^-)}{2} \right]} \end{cases} \quad (7)$$

式中: $V_0^+$ , $I_0^+$ 分别为稳态电压、电流正频率; $V_0^-$ , $I_0^-$ 分别为稳态电压、电流负频率。

## 1.2 稳定性分析

利用戴维南等效电路求得的构网型逆变器输出电压为

$$\begin{cases} v_o(s) = \left[ v_s(s) + \frac{Z_o(s)}{Z_g(s)} u_g(s) \right] \frac{1}{G_o(s)} \\ G_o(s) = \frac{1}{1 + \frac{Z_o(s)}{Z_g(s)}} = \sum_{i=1}^n \left( \frac{R_i}{s - \lambda_i} + M_i \right) \end{cases} \quad (8)$$

式中: $v_o(s)$ , $Z_o(s)$ 分别为逆变器输出电压、输出阻抗; $u_g(s)$ , $Z_g(s)$ 分别为大电网电压、大电网阻抗; $v_s(s)$ 为等效的电压源输出电压; $G_o(s)$ 为闭环传递函数; $\lambda_i$ 为第*i*个极点; $n$ 为极点个数; $M_i$ 为常数项; $R_i$ 为等效电阻。

逆变器的输出稳定性由极点决定,当所有极点实部均为负时,输出稳定;当存在一个极点实部为正时,会在对应极点频率发生振荡。

## 2 构网型逆变器参数控制模型

根据上一节分析可知,逆变器输出稳定性与逆变器输出阻抗、电网输出阻抗有关。因此,大电网阻抗发生变化时,构网型逆变器极点发生变化,若越过虚轴会使系统失稳。针对电网阻抗变化造成的系统失稳的问题,须控制逆变器输出阻抗使系统保持稳定,即调整逆变器控制参数。基于此,本文提出一种基于卷积神经网络的构网型逆变器参数自适应控制技术。将实时测量的电网阻抗作为卷积神经网络模型输入,逆变器控制参数作为输出,特征映射输入、输出关系,根据电网阻抗变

化自适应更新逆变器控制参数,使系统一直保持稳定输出。

### 2.1 卷积神经网络

卷积神经网络是一种典型的深度学习,非线性拟合能力和特征提取能力强,能够拟合电网阻抗和逆变器控制参数之间的关系,由卷积、激活、池化、全连接构成<sup>[19,20]</sup>。

#### 2.1.1 卷积层

网络最核心的部分就是卷积操作,卷积核通过权值共享的方式遍历所有输入点,能够在更短的时间内提取特征。计算式为

$$x_{i+1} = W_i \otimes x_i + b_i \quad (9)$$

式中: $x_i$ 为第*i*层的输入; $W_i$ 为第*i*层输入的卷积核权值; $\otimes$ 为进行卷积操作的运算符; $b_i$ 为第*i*层输入的偏置。

#### 2.1.2 激活层

激活层目的是非线性变化卷积的结果,提升网络泛化能力,通过添加激活函数的方式进行此运算,表达式为

$$y_i = f(x_{i+1}) = f(W_i \otimes x_i + b_i) \quad (10)$$

式中: $y_i$ 为经过第*i*层输入后的激活层输出; $f(*)$ 为激活函数。

#### 2.1.3 池化层

激活层输出的特征维度过高时会发生过拟合问题,通过池化操作可以避免这一现象。常见池化运算为最大值运算,选取池化区域内的最大值作为代表,实现降维效果,计算式为

$$\begin{aligned} \max\text{-pooling}(f[i-1], f[i], f[i+1]) = \\ \max(f[i-1], f[i], f[i+1]) \end{aligned} \quad (11)$$

式中: $\max\text{-pooling}$ 为最大池化运算符; $\max(*)$ 为最大值运算; $f[i]$ 为池化区域内的第*i*个特征值。

#### 2.1.4 全连接层

全连接层是卷积神经网络输出的最后一层,将多维特征展开成一维特征,有利于分类器输出最优值,每层之间神经元相互连接,具体过程为

$$o(t) = F(wt + b) \quad (12)$$

式中: $t$ , $o(t)$ 分别为全连接层输入、输出; $F(*)$ 为全连接激活函数; $w$ , $b$ 分别为全连接层权值、偏置。

### 2.2 瞪羚算法

卷积神经网络包含所有中间层神经元个数、学习率、批大小等众多超参数,人为选择这些参数

难度大,使用智能优化算法找出最佳网络超参数,能够极大提高网络性能。

瞪羚算法是近年来提出的一种模拟瞪羚捕食过程的智能群体优化算法,具有寻优能力强、收敛速度快的优势。

### 2.2.1 初始化

瞪羚种群随机初始化公式为

$$x_{ij}=rand \cdot (\max_j - \min_j) + \min_j \quad (13)$$

式中: $x_{ij}$  为种群第  $i$  个瞪羚在第  $j$  维的值; $rand$  为随机数; $\max_j, \min_j$  分别为第  $j$  维向量最大值、最小值。

### 2.2.2 布朗运动

布朗运动是一种随机分子热运动,位移过程遵循正态分布,计算式为

$$f_b = \frac{1}{\sqrt{2\pi\delta^2}} \exp\left[-\frac{(x-\mu)^2}{2\delta^2}\right] \quad (14)$$

式中: $\mu, \delta$  分别为高斯分布的均值、标准差,并且  $\mu=0, \delta=1$ 。

### 2.2.3 莱维飞行

莱维飞行通过高低距离交替飞行的方式随机搜索寻优,能够有效协调算法的全局搜索和局部搜索,计算式为

$$L(\beta) = 0.05 \frac{x}{|y|^{\frac{1}{\beta}}} \quad (15)$$

式中: $\beta$  为莱维飞行系数,取值为 1.5; $y = \text{Normal}(0, 1^2)$ ;  $x = \text{Normal}(0, \sigma_x^2)$ 。

$$\sigma_x = \left[ \frac{\Gamma(1+\beta) \sin\left(\frac{\pi\beta}{2}\right)}{\Gamma\left(\frac{1+\beta}{2}\right) \beta 2^{\frac{\beta-1}{2}}} \right]^{\frac{1}{\beta}} \quad (16)$$

式中: $\Gamma(\cdot)$  为伽马函数。

### 2.2.4 开发阶段

开发阶段用于没有捕食者的场景,自由的瞪羚通过布朗运动更新位置,计算式为

$$G_{j+1} = G_j + s \cdot r \cdot r_b \cdot (E_j - r_b G_j) \quad (17)$$

式中: $G_j$  为第  $j$  次迭代时的解; $s$  为移动速率; $r$  为 0~1 的随机数; $r_b$  为布朗运动随机向量; $E_j$  为第  $j$  次迭代时最优瞪羚构成的矩阵。

### 2.2.5 探索阶段

瞪羚发现捕食者时分别采用莱维飞行和布朗

运动进行逃跑。

#### ①第一阶段

瞪羚发现猎物前期通过莱维飞行的计算式为

$$G_{j+1} = G_j + s_{\max} \cdot \lambda \cdot r \cdot r_L \cdot (E_j - r_L G_j) \quad (18)$$

式中: $s_{\max}$  为最大飞行速率; $\lambda$  取值为 -1 或 1,代表两种飞行方向; $r_L$  为莱维飞行随机向量。

#### ②第二阶段

$$G_{j+1} = G_j + s_{\max} \cdot \lambda \cdot A \cdot r_b \cdot (E_j - r_L G_j) \quad (19)$$

式中: $A$  为累积效应系数。

## 3 构网型逆变器优化控制方案

### 3.1 优化控制模型

卷积神经网络具有非线性拟合能力和特征提取能力强的优势,能够拟合电网阻抗和逆变器控制参数之间的关系。然而卷积神经网络包含所有中间层神经元个数、学习率、批大小等众多超参数,人为选择这些参数难度大,本文使用瞪羚算法优化卷积神经网络超参数,找出最佳网络超参数,极大提高网络性能。在模型优化前期,根据减少损失函数的原则实时动态更新卷积神经网络参数;在模型优化后期,找出最低损失函数对应的参数,此时保持参数不变,使模型具有最佳的构网型逆变器参数控制水平。

构网型逆变器参数控制模型如图 2 所示,将电网阻抗数据输入至卷积神经网络中,经过卷积、激活、池化、全连接操作输出逆变器最佳控制参数。




图 2 优化控制模型

Fig.2 Optimization control model

模型输入、输出如下。

①模型输入为电网阻抗,即电网等效电阻  $r_g$ 、等效电感  $L_g$ ,若训练集样本数量为  $n$ ,则训练集输入为

$$x_{in} = \begin{bmatrix} r_g(1) & r_g(2) & \cdots & r_g(n) \\ L_g(1) & L_g(2) & \cdots & L_g(n) \end{bmatrix} \quad (20)$$

②模型输出为逆变器控制参数,主要包含电流调节比例系数  $k_{ip}$ 、电流调节积分系数  $k_{ii}$ 、电压调节比例系数  $k_{vp}$ 、电压调节积分系数  $k_{vi}$ 、下垂增益系数  $m_{df}$ ,输出为

$$y_{out} = \begin{bmatrix} k_{ip}(1) & k_{ip}(2) & \cdots & k_{ip}(n) \\ k_{ii}(1) & k_{ii}(2) & \cdots & k_{ii}(n) \\ k_{vp}(1) & k_{vp}(2) & \cdots & k_{vp}(n) \\ k_{iv}(1) & k_{iv}(2) & \cdots & k_{iv}(n) \\ m_{pf}(1) & m_{pf}(2) & \cdots & m_{pf}(n) \end{bmatrix} \quad (21)$$

### 3.2 评估过程

使用瞪羚算法优化卷积神经网络超参数流程如图3所示。

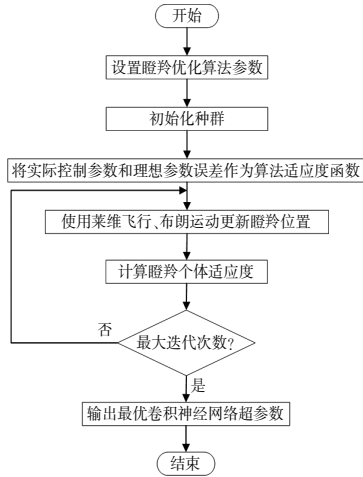


图3 卷积神经网络超参数优化流程

Fig.3 Optimization process of hyperparameters in convolutional neural networks

基于瞪羚算法优化卷积神经网络的光储构网型逆变器优化流程如图4所示。

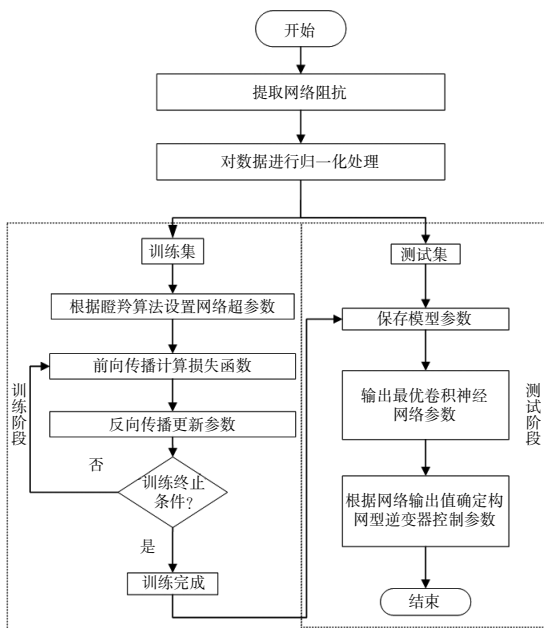


图4 构网型逆变器参数控制流程

Fig.4 Parameter control process of grid type inverter

具体步骤如下。

步骤一:提取电网阻抗,按照式(20)将输入数据划分成训练集和测试集。

步骤二:将输入数据输入卷积神经网络中,经过卷积、激活、池化、全连接操作后,前向计算损失函数,反向更新模型参数。

步骤三:如果未满足终止条件,返回步骤二,否则继续下一步。

步骤四:将在线阻抗数据作为测试集输入至已经训练好的卷积神经网络模型中。

步骤五:实时更新构网型逆变器参数,根据实际电网稳定性情况验证本文所提逆变器参数控制方法的有效性。

## 4 实验

### 4.1 仿真环境

为了验证本文所提出的基于瞪羚算法优化卷积神经网络的光储构网型逆变器优化控制方法效果,搭建如图5所示的光储构网型逆变器接入大电网模型,包含光伏发电设备、储能设备、构网型逆变器、大电网4个部分,其中构网型逆变器参数如表1所示。选取样本数量为1000,其中,训练集样本个数为800,测试集样本个数为200。




图5 光储构网型逆变器接入大电网模型

Fig.5 Model of photovoltaic energy storage grid inverter connected to large power grid

表1 构网型逆变器参数

Table 1 Parameters of grid type inverter

参数	数值
额定功率 $S_N/\text{MVA}$	100
额定电压 $U_N/\text{kV}$	23
滤波器等效电阻 $r_f/\text{p.u.}$	0.1
滤波器等效电感 $L_f/\text{p.u.}$	0.04
滤波器等效电容 $C_f/\text{p.u.}$	0.1
电流调节比例系数 $k_{ip}$	0.7
电流调节积分系数 $k_{ii}$	380
电压调节比例系数 $k_{vp}$	0.2
电压调节积分系数 $k_{iv}$	800
下垂增益系数 $m_{pf}$	0.06

4.2 瞪羚算法优化结果

使用瞪羚优化算法优化卷积神经网络，以实际逆变器控制参数和网络输出的逆变器控制参数误差为适应度函数，通过瞪羚算法找出适应度最低的最佳网络超参数，瞪羚算法寻优过程如图 6 所示。从图 6 中可知，当算法迭代次数达到 77 次时，适应度达到最低值 0.87，继续增大迭代次数，适应度保持稳定。说明本文提出的瞪羚优化算法具有寻优能力强、收敛速度快的优势，极大提高了卷积神经网络的性能。优化后的卷积神经网络超参数如表 2 所示。




图 6 瞪羚算法优化结果

Fig.6 Optimization results of gazelle algorithm

表 2 瞪羚算法优化的卷积神经网络超参数

Table 2 Optimization of convolutional neural network hyperparameters for gazelle algorithm

超参数	最佳取值
学习率	0.006
批大小	553
卷积、激活、池化交替个数	3
卷积层 1 神经元个数	194
池化层 1 的池化因子	12
卷积层 2 神经元个数	279
池化层 2 的池化因子	10
卷积层 3 神经元个数	357
池化层 3 的池化因子	8
全连接层神经元个数	256

4.3 结果分析

为了验证电网阻抗发生变化时本文提出的构网型逆变器参数自适应调节方法的效果，设置电网等效电阻、电感变化如图 7 所示。初始电阻、电感分别为 0.1 p.u.、0.04 p.u.，在 1 s 时刻，电阻、电感分别改变为 0.041 p.u.、0.114 p.u.，在 2 s 时刻，电阻、电感分别改变为 0.088 p.u.、0.027 p.u.。




图 7 电网等效电阻、电感变化曲线

Fig.7 Equivalent resistance and inductance variation curve of power grid

使用瞪羚优化算法优化后的卷积神经网络对逆变器参数进行优化，网络损失函数随迭代次数的变化如图 8 所示。从图 8 中可知，当网络迭代次数达到 700 时，损失函数仅有 0.46。说明网络输出的逆变器参数和理想参数误差较低，能够充分拟合电网参数和逆变器参数之间的映射关系。




图 8 卷积神经网络损失函数变化

Fig.8 Changes in the loss function of convolutional neural networks

经过卷积神经网络特征学习后的逆变器控制参数，即  $k_{ip}, k_{ii}, k_{vp}, k_{iv}, m_{pf}$  的变化曲线分别如图 9~13 所示，未使用参数自适应优化和使用本文自适应参数优化方法的电压输出曲线如图 14 所示。从图 14 中可知：不使用参数自适应优化方法的逆变器输出电压在阻抗变化时振荡，系统发生失稳；使用本文方法后逆变器各个控制参数能够根据电网




图 9  $k_{ip}$  变化曲线

Fig.9  $k_{ip}$  variation curve




图 10  $k_i$  变化曲线

Fig.10  $k_i$  variation curve




图 11  $k_v$  变化曲线

Fig.11  $k_v$  variation curve




图 12  $k_w$  变化曲线

Fig.12  $k_w$  variation curve




图 13  $m_d$  变化曲线

Fig.13  $m_d$  variation curve




图 14 逆变器输出电压变化曲线

Fig.14 Inverter output voltage variation curve

阻抗的变化进行实时更新,在 1 s 时刻发生的电网阻抗变化场景,电压经过 0.2 s 的短暂振荡后保持稳定,2 s 时刻发生的电网阻抗变化场景,电压经过 0.5 s 的短暂振荡后保持稳定。说明经过本文所提逆变器参数自适应方法调节后,能够在电网阻抗变化后控制参数使系统恢复稳定,验证了本文方法的有效性。

为了验证本文算法的优越性,将本文方法与人工神经网络、未经超参数优化的传统卷积神经网络进行对比,模型优化结果如表 3 所示。从表 3 中可知,本文方法稳定后的输出电压质量最优,人工神经网络输出电压质量最差,计算时间最短。这是因为人工神经网络属于浅层机器学习,参数少、计算量低,但是特征学习能力弱,无法充分拟合电网阻抗和逆变器参数之间的关系;传统卷积神经网络虽然特征学习能力强,但是没有经过超参数优化,在拟合电网阻抗和逆变器参数之间的关系方面有待进一步提升,训练效率较低,计算量大,计算时间变长;本文提出的卷积神经网络超参数经过瞪羚算法优化后极大提升了网络的性能,提高了特征映射电网阻抗和逆变器参数的效率,计算时间只比人工神经网络多 0.05 s 就能达到最优的电压输出。说明了本文方法在实际电网运行中能够以较快的速度及时响应,得到逆变器控制参数,使电压保持最佳输出,验证了本文方法综合性能最优。

表 3 不同算法结果对比

Table 3 Comparison of results from different algorithms

方法	稳定后的输出电压/p.u.	计算时间/s
人工神经网络	0.84	0.31
传统卷积神经网络	0.92	1.23
本文方法	0.99	0.36

## 5 结论

本文提出了一种基于瞪羚算法优化卷积神经网络的光储构网型逆变器优化控制方法,主要取得以下成果。

①搭建了构网型逆变器控制模型,分析了输出电压稳定性。

②基于卷积神经网络建立逆变器参数控制模型,通过瞪羚算法优化卷积神经网络超参数,提升模型特征学习能力,输出逆变器控制参数。

③选取某光储发电地区进行仿真验证,经过

试验表明,所提构网型光储逆变器控制方法能够根据电网阻抗实时变化自适应优化控制参数,实现电压稳定输出,具有很强的实际工程意义。

#### 参考文献:

- [1] 崔杨,安宁,付小标,等.面向高比例新能源电力系统调峰需求的储能容量配置方法综述[J].东北电力大学学报,2023,43(1):1-8.
- [2] 桑丙玉,杨波,陶以彬,等.计及新能源功率概率分布特征的储能配置优化方法[J].可再生资源,2024,42(4):561-568.
- [3] 熊小玲,李昕悦,周琰,等.基于陷波器的构网型换流器同步频率谐振抑制策略[J].电工技术学报,2024,39(12):3827-3839.
- [4] 魏林君,叶华,迟永宁.基于状态重构的构网型风机与储能系统联合频率支撑控制策略[J].高电压技术,2023,49(12):5095-5104.
- [5] 张勇,孙同越,李云丰,等.风电场融合电池储能的稳定性分析及阻尼控制器参数解析计算[J].电网技术,2023,47(9):3517-3527.
- [6] Zhao Fangzhou, Wang Xiongfei, Zhou Zichao, et al. Control interaction modeling and analysis of grid-forming battery energy storage system for offshore wind power plant [J]. IEEE Transactions on Power Systems, 2022,37(1):497-507.
- [7] Zhou Ziqi, Pugliese S, Langwasser M, et al. Subsynchronous damping by battery storage system in grid forming control mode[A]. Proceedings of 2022 IEEE Energy Conversion Congress and Exposition[C]. Detroit, MI, USA; IEEE, 2022.
- [8] Li Gaoxiang, Chen Yandong, Luo An, et al. An enhancing grid stiffness control strategy of STATCOM/BESS for damping sub-synchronous resonance in wind farm connected to weak grid [J]. IEEE Transactions on Industrial Informatics, 2020, 16(9):5835-5845.
- [9] 马兴,徐瑞林,陈民铀,等.弱电网下并网逆变器自适应  $H_{\infty}$  控制方法 [J]. 电力系统自动化,2018,42(13):189-195.
- [10] Vieira R P, Martins L T, Massing J R, et al. Sliding mode controller in a multiloop framework for a grid-connected VSI with LCL filter[J]. IEEE Transactions on Industrial Electronics, 2018, 65(6):4714-4723.
- [11] Wu T F, Hsieh H C, Hsu C W, et al. Three-phase three-wire active power filter with D- $\Sigma$  digital control to accommodate filter-inductance variation [J]. IEEE Journal of Emerging and Selected Topics in Power Electronics, 2016, 4(1):44-53.
- [12] 许津铭,谢少军,唐婷.弱电网下 LCL 电流控制滤波并网逆变器自适应 [J]. 中国电机工程学报,2014,34(24):4031-4039.
- [13] 杜燕,崔林波,杨向真,等.并网逆变器的阻抗自适应控制方法[J].电力系统自动化,2018,42(6):120-127.
- [14] Zhang C, Mijatovic N, Cai X, et al. Artificial neural network-based pole-tracking method for online stabilization control of grid-tied VSC [J]. IEEE Transactions on Industrial Electronics, 2022, 69(12):13902-13909.
- [15] 何迪,王聪聪,陈红兵,等.应用 PSO-RBF 神经网络预测太阳能 PV/T 系统的热、电性能 [J]. 可再生资源,2024,42(4):455-463.
- [16] 陈胜,刘鹏飞,王平,等.基于 LSTM 人工神经网络的电力系统负荷预测方法[J].沈阳工业大学学报,2024,46(1):66-71.
- [17] 肖白,李道明,穆钢,等.基于 SA-PSO 算法优化 CNN 的电能质量扰动分类模型[J].电力自动化设备,2024,44(5):185-190.
- [18] Agushaka J O, Ezugwu A E, Abualigah L. Gazelle optimization algorithm: a novel nature-inspired metaheuristic optimizer [J]. Neural Computing and Applications, 2023, 35(5):4099-4131.
- [19] 钱进宝,刘晓光,蔡玺,等.基于自适应学习率卷积神经网络的新型配电网源网荷储无功协调优化技术[J].可再生资源,2024,42(2):267-275.
- [20] 魏冬梅.基于卷积神经网络的移动网络目标跟踪与控制[J].沈阳工业大学学报,2023,45(3):342-347.

# Optimization control technology of optical storage network inverter based on gazelle algorithm optimized convolutional neural network

Pang Xiulan<sup>1</sup>, Li Xiaofeng<sup>1</sup>, Yang Qi<sup>1</sup>, Li Xian<sup>1</sup>, Li Xuehong<sup>1</sup>, Jin Wenxing<sup>2</sup>

(1.SPIC Qinghai Photovoltaic Industry Innovation Center Co.,Ltd., Xining 810008, China; 2.School of Electrical Engineering, Southeast University, Nanjing 210096, China)

**Abstract:** With the large-scale integration of clean energy sources such as photovoltaics and energy storage into the power grid, grid type control technology has obvious advantages in dealing with voltage stability issues in new energy power systems that lack synchronization. However, how to adaptively control the parameters of grid type photovoltaic storage inverters to maintain voltage stability even when the impedance of the power grid changes is an urgent problem that needs to be solved. Based on this, a method for optimizing the control of optical storage grid inverters using a convolutional neural network optimized by the gazelle algorithm is proposed. Firstly, build a control model for grid type inverters and analyze the stability of output voltage; Secondly, based on the convolutional neural network, an inverter parameter control model is established, and the Gazelle optimization algorithm is utilized to optimize the hyperparameters of the convolutional neural network with strong optimization ability and fast search speed, improving the model's feature learning ability and outputting inverter control parameters; Finally, a certain photovoltaic power generation area was selected for simulation verification. The experiment showed that the proposed grid type photovoltaic inverter control method can adaptively optimize control parameters based on real-time changes in grid impedance, achieve stable voltage output, and have strong practical engineering significance.

**Keywords:** clean energy; network type control; optical storage inverter; gazelle algorithm; convolutional neural network