

DOI:10.19651/j.cnki.emt.2314035

## 基于 GA-ADAM 优化的 BPNN 配电网潮流计算\*

刘会家<sup>1</sup> 冯铃<sup>1</sup> 艾璨<sup>2</sup>

(1.三峡大学电气与新能源学院 宜昌 443002; 2.湖北能源集团罗田平原地抽水蓄能有限公司 黄冈 438600)

**摘要:**潮流计算是电力系统运行与控制的基础。为解决配电网可再生能源渗透率不断增加带来的负荷点电压波动的不确定性,以及传统电力系统潮流数据收集能力不足导致潮流计算不准确等问题。本文提出了一种基于数据驱动的潮流分析模型,构建了一种基于 BPNN 结合 GA-ADAM 优化算法模型来分析随机性下配电网的潮流计算方法。首先,引入潮流初值信息、拓扑结构特征以及功率因数指标构建训练集,通过对回归模型的训练,充分挖掘节点电压与功率之间的映射关系。其次,使用 GA-ADAM 算法优化模型初值和权重参数。最后,基于 IEEE-33 节点配电网模型进行验证,本文模型潮流计算的最大误差  $3.93 \times 10^{-3}$ , 平均绝对误差  $1.46 \times 10^{-3}$ , 均方根误差  $1.81 \times 10^{-3}$ , 优化后的 BPNN 潮流计算电压误差值降低 37.66%。实际算例仿真结果表明,与其他方法比较,本文构建的模型各误差指标小、准确度高,提高了潮流计算的效率和准确性。

**关键词:**潮流计算;数据驱动;配电网;BPNN;GA

**中图分类号:** TM744 **文献标识码:** A **国家标准学科分类代码:** 470.4047

## Distribution network power flow calculation based on the BPNN optimized by GA-ADAM

Liu Huijia<sup>1</sup> Feng Ling<sup>1</sup> Ai Can<sup>2</sup>

(1. College of Electrical Engineering &amp; New Energy, China Three Gorges University, Yichang 443002, China;

2. Hubei Energy Group Luotian Pingyuan Pumped Storage Co., Ltd., Huanggang 438600, China)

**Abstract:** Power flow calculations are the basis for the operation and control of power systems. In order to solve the problems of uncertainty of voltage fluctuation at the point of load caused by the increasing penetration rate of renewable energy in the distribution network, and the inaccuracy of power flow calculation caused by the insufficient power flow data collection capacity of traditional power system. In this paper, a data-driven power flow analysis model is proposed, and a power flow calculation method based on back propagation neural network combined with genetic algorithm and adaptive moment estimation optimization algorithm is constructed to analyze the power flow calculation method of distribution network under randomness. Firstly, the initial power flow information, topological structure characteristics and power factor indicators are introduced to construct the training set, and the mapping relationship between node voltage and power is fully explored through the training of the regression model. Secondly, the GA-ADAM algorithm is used to optimize the initial value and weight parameters of the model. Finally, based on the IEEE-33 bus distribution network model, the maximum error is  $3.93 \times 10^{-3}$ , average absolute error is  $1.46 \times 10^{-3}$ , and root mean square error is  $1.81 \times 10^{-3}$  of the model power flow calculation in this article, the optimized BPNN power flow calculation voltage error value is reduced by 37.66%. The simulation results of actual examples show that compared with other methods, the model constructed in this paper has smaller error indicators and higher accuracy, which improves the efficiency and accuracy of power flow calculation.

**Keywords:** power flow calculation; data-driven; distribution network; BPNN; GA

## 0 引言

为贯彻“双碳目标”方针政策,构建新型电力系统深度

脱碳<sup>[1]</sup>是关键环节。潮流计算是电力系统分析中最基本、最重要的环节,也是系统安全、经济运行分析<sup>[2]</sup>和实时控制与调度的基础。近年来,高比例可再生能源大规模并网,储

收稿日期:2023-07-06

\* 基金项目:国家自然科学基金(52277108)项目资助

能、电动汽车等设备在配电网的渗透率逐渐增加导致用电形式多样化;源荷波动的随机和不确定性<sup>[5-7]</sup>影响电网的电能质量、供电可靠性等;电网状态改变可能会导致传统牛顿-拉夫逊(Newton-Raphson, N-R)法难以收敛;缺少相关信息的分布式能源并网带来的模型构建问题很难用传统模型驱动的潮流方程来描述。另一方面,在全球“大数据时代<sup>[6-7]</sup>”背景下,电力行业对数据量测、传输及储存有较好的积累,能监测配电网的运行方式及参数,这为数据驱动的潮流计算奠定良好的基础。因此本文提出数据驱动的潮流计算,即一种基于遗传算法(genetic algorithm, GA)和自适应矩估计(adaptive moment estimation, ADAM)优化的反向传播神经网络(back propagation neural network, BPNN)配电网潮流计算,以解决目前因配电网参数不准确、数据丢失、源荷等不确定性和随机性而带来的潮流计算问题。

随着智能电网等相关技术的快速发展,配电网潮流计算方法已有较大进展。模型驱动潮流计算增强了对模型的认识和理解,提升可视化效果。传统潮流计算方法<sup>[8]</sup>用迭代数值法求解获取电压幅值和相角;文献[9]考虑直流,建立直流转直流变换器的统一稳态非理想模型,提出基于保留非线性算法的潮流计算模型;文献[10]虽采用解耦线性潮流(decoupled linear power flow, DLPF)法有效计算出电压幅值,但牺牲了电压相角计算的准确性;文献[11]考虑分布式电源,建立了配电线路、变压器和负荷的三相数学模型,提出三相潮流混合计算方法;文献[12]考虑综合能源,基于精细化热网构建潮流计算模型。随着量测装置和储存设备的发展,数据驱动<sup>[13]</sup>潮流法应运而生,并将非线性潮流模型线性化<sup>[14-17]</sup>处理,加快潮流计算速度。文献[18]通过偏最小二乘和贝叶斯线性回归法构建配电网节点有功、无功功率与节点电压、相角的映射关系,建立了线性回归模型;文献[19]构建恒阻抗、电流和功率静态负荷模型,提出三相不平衡下配电网最小二乘潮流线性回归法。机器学习能很好模拟非线性映射关系。文献[20-23]采用不同人工神经网络结构构建非线性潮流回归模型;文献[24]通过健壮的支持向量回归(support vector regression, SVR)法构建非线性潮流回归模型。

综上,潮流计算模型构建存在以下不足:1)模型驱动难以适应当今实时潮流带来的变化复杂的配电网,潮流计算的快速性和收敛性也无法得到可靠的保证;2)线性化模型的数据驱动无法表达非线性特征,对于非线性潮流计算模型考虑较为片面;3)基于机器学习构建的复杂非线性潮流回归模型,存在训练过程中复杂参数优化耗时的问题<sup>[25]</sup>及高计算开销影响潮流计算速度的问题,且在特征训练方面考虑较为单一。

为有效解决以上问题,本文采用改进的 BPNN 模型,选取电力系统的 3 种特征变量作为模型输入:潮流初值、拓扑结构特征、功率因数指标,提高了模型的泛化性和表达能力;通过仿真实验获取大量潮流数据,构建样本数据集,并

采用 BPNN 模型对非线性数据进行回归拟合,确定神经元个数;采用 GA 优化算法对 BPNN 初始权重和阈值进行优化,避免网络陷入局部最优;采用 ADAM 优化算法的自适应学习率和动量因子加快参数收敛速度、提高计算精度;最终确定最优模型并进行潮流计算,有效提高了潮流计算效率。综上,本文模型克服了传统模型驱动难以适应大规模数据集输入输出问题,提高了潮流计算的效率和准确性。

## 1 基于数据驱动的潮流计算模型

### 1.1 电力系统潮流模型

电力系统配电网是整个电网重要组成部分。在潮流计算过程中,可通过已知变量求未知变量,从而推算来获取整个配电网潮流数据。其变量主要有节点的有功功率、无功功率、电压幅值和相角,支路的有功、无功功率以及功率损耗。系统的运行状态则通过这些潮流变量来描述。传统物理模型驱动方法的方程如下:

$$\begin{cases} P_i = V_i \sum_{j \in i} V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) \\ Q_i = V_i \sum_{j \in i} V_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}) \end{cases} \quad (1)$$

式中:  $P_i$  和  $Q_i$  分别为节点  $i$  注入的有功、无功功率;  $V_i$  和  $V_j$  分别为节点  $i$  和  $j$  的电压幅值;  $G_{ij}$  和  $B_{ij}$  分别为导纳矩阵中第  $i$  行、 $j$  列的实部和虚部;  $\theta_{ij}$  为节点  $i$  和节点  $j$  之间的相角差。

式(1)在某一时刻是恒成立的,遵守能量守恒定律。传统 N-R 法用修正方程来进行潮流计算,通过迭代更新不断修正电压相角,直到式(2)的功率误差达到设定误差。

$$\begin{cases} \Delta P_i = P_i - V_i \sum_{j \in i} V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) \\ \Delta Q_i = Q_i - V_i \sum_{j \in i} V_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}) \end{cases} \quad (2)$$

式中:  $\Delta P_i$  为节点  $i$  的有功功率不平衡量,  $\Delta Q_i$  为节点  $i$  的无功功率不平衡量。

由于天气恶劣、线路老化等原因可能会造成线路上  $G$ 、 $B$  参数发生变化,导致导纳矩阵重新计算,整个系统潮流的电压相角均会发生变化;随着电力系统的规模逐渐增大,相应计算量也会成倍增加。潮流计算通过不同的求解方法减小不平衡量,得到最小不平衡量下方程的解。

式(2)为非线性潮流方程,从本质上说就是节点电压关于节点注入功率的非线性方程组,而从数据驱动的角度来看,忽略易变化的  $G$ 、 $B$  线路参数,可通过数据挖掘技术来建立电压、功率变量之间的映射关系,以训练得到的数据与实际数据之间的最小损失为目标,构建数据驱动潮流模型进行潮流计算,将模型驱动合理转化为数据驱动。在某个  $t$  时刻,矢量表示如下:

$$x_t = (P_1^t, \dots, P_n^t, Q_1^t, \dots, Q_n^t, \Delta U_1^t, \dots, \Delta U_{n-1}^t, \lambda_1^t, \dots, \lambda_n^t) \quad (3)$$

$$y_t = (V_1^t, \dots, V_n^t, \theta_1^t, \dots, \theta_n^t) \quad (4)$$

式中:  $x_t$  和  $y_t$  分别为  $t$  时刻的自变量和因变量;  $n$  为电力系统节点数;  $P_n^t$ 、 $Q_n^t$  分别为  $t$  时刻节点  $n$  注入的有功、无功功率,  $\Delta U_{n-1}^t$  为  $t$  时刻  $n-1$  条支路上的电压差,  $\lambda_n^t$  为  $t$  时刻节点  $n$  的功率因数,  $1 \sim n$  为配电网节点编号。

在 BPNN 潮流回归模型中, 建立自变量和因变量参数如下:

$$\mathbf{X} = [x_1 \cdots x_t \cdots x_T] \quad (5)$$

$$\mathbf{Y} = [y_1 \cdots y_t \cdots y_T] \quad (6)$$

式中:  $\mathbf{X}$  和  $\mathbf{Y}$  为矩阵, 而非向量, 其列数表示不同时间的不同数据集, 行数表示不同的变量。自变量  $\mathbf{X}$  包括式(3)中  $n$  个节点的功率、拓扑结构特征向量及功率因数指标; 因变量  $\mathbf{Y}$  表示配电网  $n$  个节点的电压幅值和相角。整体抽象表达如式(7)、(8)。

$$\mathbf{Y}' = \mathbf{A}\mathbf{X} + \mathbf{B} \quad (7)$$

$$e = \frac{1}{k} \sum_{m=1}^k (\mathbf{Y} - \mathbf{Y}')^2 \quad (8)$$

式(7)为数据驱动潮流回归模型, 参数依次为因变量矩阵、回归参数矩阵、自变量矩阵和偏置项; 式(8)构建损失函数为目标函数,  $e$  为模型预测值与真实值之间的误差;  $\mathbf{Y}$  和  $\mathbf{Y}'$  分别为真实值和预测值。

数据驱动的神经网络训练与模型驱动的 N-R 法进行潮流计算时, 其思想有异曲同工之妙, 在网络回归训练时设定权重、偏置初值, 以最小损失函数  $e$  为目标不断更新修正初值, 当电压相角损失达到最小误差要求时, 确定回归参数, 进而确定潮流计算模型。

## 1.2 拓扑结构特征向量构建

一方面, 电力系统日益复杂化使信息量快速增加, 高比例新能源大量接入使运行方式逐渐多样化, 导致传统导纳矩阵构建在计算和更新量方面存在较大问题, 加大计算难度; 另一方面, 为完整刻画电网运行状态, 将拓扑特征融入潮流模型训练会更完善, 通过识别拓扑变化进行相应潮流计算, 使得潮流模型更具泛化性。

目前, 针对拓扑结构变化的特征向量表示有导纳矩阵法、0~1 向量法等。但随着目前电力系统规模的扩大, 这些方法存在信息湮没等问题。为解决该问题, 本文采用支路中断前后各母线电压差作为特征向量来表征支路的不确定性。

从功率平衡方程可知, 在一定的系统状态下, 每条母线的电压变化可直接反映导纳矩阵的变化, 进而反映拓扑结构的变化, 具体特征向量表达如下:

$$\Delta \dot{U}_{ij} = \dot{U}_{ij}^{\text{before}} - \dot{U}_{ij}^{\text{after}} \quad (9)$$

式中:  $\Delta \dot{U}_{ij}$  为支路中断前后各母线的电压差;  $\dot{U}_{ij}^{\text{before}}$  和  $\dot{U}_{ij}^{\text{after}}$  分别为支路中断前后各母线的电压。在进行计算时, 其中负载取平均值, 分布式能源取最大输出, 发电机组取正常状态。采用该拓扑结构特征向量不仅解决了拓扑信息湮没的问题, 而且其差值大小还有效表征支路开断对各支路影响程度<sup>[26]</sup>。

## 1.3 其他特征向量构建

在电力系统潮流计算中, 不仅要求功率在系统中时时处处平衡, 且有功、无功功率间的平衡状态也是影响潮流计算的关键信息, 因此将功率因数水平指标作为特征向量之一构建。衡量指标为电力系统的全局和局部指标。系统的局部功率因数指标如下:

$$\lambda_i^{l1} = \frac{\sum_{i \in \{N_i^1\}} P_i^{\text{load}}}{\sqrt{(\sum_{i \in \{N_i^1\}} P_i^{\text{load}})^2 + (\sum_{i \in \{N_i^1\}} Q_i^{\text{load}})^2}} \quad (10)$$

$$\lambda_i^{l2} = \begin{cases} \frac{\sum_{i \in \{N_i^2\}} P_i^{\text{load}}}{\sqrt{(\sum_{i \in \{N_i^2\}} P_i^{\text{load}})^2 + (\sum_{i \in \{N_i^2\}} Q_i^{\text{lim+}})^2}}, & \sum_{i \in \{N_i^2\}} Q_i^{\text{load}} \geq 0 \\ \frac{\sum_{i \in \{N_i^2\}} P_i^{\text{load}}}{\sqrt{(\sum_{i \in \{N_i^2\}} P_i^{\text{load}})^2 + (\sum_{i \in \{N_i^2\}} Q_i^{\text{lim-}})^2}}, & \text{其他} \end{cases} \quad (11)$$

系统的全局功率因数指标如下:

$$\lambda^{\varepsilon 1} = \frac{\sum_{i=1}^N P_i^{\text{load}}}{\sqrt{(\sum_{i=1}^N P_i^{\text{load}})^2 + (\sum_{i=1}^N Q_i^{\text{load}})^2}} \quad (12)$$

$$\lambda^{\varepsilon 2} = \begin{cases} \frac{\sum_{i=1}^N P_i^{\text{load}}}{\sqrt{(\sum_{i=1}^N P_i^{\text{load}})^2 + (\sum_{i=1}^N Q_i^{\text{lim1}})^2}}, & \sum_{i=1}^N Q_i^{\text{load}} \geq 0 \\ \frac{\sum_{i=1}^N P_i^{\text{load}}}{\sqrt{(\sum_{i=1}^N P_i^{\text{load}})^2 + (\sum_{i=1}^N Q_i^{\text{lim-}})^2}}, & \text{其他} \end{cases} \quad (13)$$

式中:  $Q_i^{\text{lim1}}$  和  $Q_i^{\text{lim-}}$  分别为节点无功出力的上下限;  $P_i^{\text{load}}$  和  $Q_i^{\text{load}}$  分别为节点有功和无功负荷;  $\{N_i\}$  为局部网络, 由节点和与该节点直接相连的节点所构成<sup>[27]</sup>;  $\{\lambda^{\varepsilon 1}, \lambda^{\varepsilon 2}, \lambda_i^{l1}, \lambda_i^{l2}\}$ ,  $i = 1, 2, \dots, N$ , 为电力系统功率因数水平指数集, 全面刻画了有功和无功的平衡信息。

在潮流数据训练过程中, 逐一扫描各节点, 提取其关键特征, 若各负荷点局部功率因数水平指数相近, 则全网潮流转移不明显, 相反相差较大时, 则可能出现有功和无功不平衡的现象。加入此特征增强了电网的表达力, 所训练的潮流数据更稳定, 提高了模型的泛化性能; 并且该特征反映了局部连接关系, 也侧面反映出电力系统拓扑结构变化情况。

由于在复杂电力系统中, 单纯通过人工智能法解决潮流问题, 不仅影响对电力系统配电网物理机制的理解, 还可

能会产生过拟合。通过在 BPNN 数据驱动中间接入某些物理信息作为正则化,将更多刻画电力系统特征向量加入训练,就能对模型产生较大改善,数据和物理模型共同驱动<sup>[28]</sup>得到的决策是更加稳定的。

### 1.4 模型的输入输出

本文采用 GA-ADAM 组合优化的 BPNN 结构对潮流数据进行拟合并进行潮流计算。潮流数据无论在时间、空间上都隐含一定规律,具有很强的时序及非线性特征。过程主要分为训练和计算<sup>[29]</sup>阶段。训练阶段,网络通过学习电网不同断面的潮流初始值、拓扑结构变化特征和功率因数指标构建数据驱动模型,将 3 个特征作为网络输入,节点电压幅值和相角作为输出,GA 算法及 ADAM 优化器对网络参数进行调整优化,得到最优模型;当拓扑改变时,重新训练并保存各拓扑场景下的网络模型;计算阶段,多节点并行运算,可直接根据拓扑变化进行快速潮流计算,如图 1 所示。




图 1 模型输入输出原理框图

## 2 模型优化算法原理

### 2.1 遗传算法

GA 是一种并行随机搜索最优化方法。对优化网络初始权重和阈值做出了突出的贡献。GA 的基本要素包括种群初始化、适应度函数,选择、交叉以及变异算子<sup>[30]</sup>。本文对 GA 基本要素的选取如表 1 所示。

表 1 GA 基本要素选取方式

个体编码	适应度函数	选择算子	交叉算子	变异算子
二进制	排序适应度	随机遍历	单点交叉	随机
二进制	分配函数	抽样 sus	算子	方法

本文个体编码由输入层、隐含层与输出层之间的两个连接权值、隐含层阈值、输出层阈值共四个部分组成,每个权值和阈值使用  $N$  位二进制编码,将所有权值和阈值的编码连接起来即为一个个体编码,从而形成确定的神经网络结构;通过选择、交叉和变异算子来确定最小适应度函数,并赋予权值和阈值一定的初值。

初值参数的选择决定着网络训练的效果和性能。GA 方法的引入防止了 BPNN 网络在训练时陷入局部最优<sup>[31]</sup>,也从一定程度上防止了梯度爆炸的情况。本文 GA 优化算

法参数设置:种群规模大小为 10;遗传代数数为 50;个体长度为 10;代沟为 0.95;交叉概率为 0.7;变异概率为 0.01。

### 2.2 ADAM 优化器

ADAM 优化器在 2014 年被提出,采用动量和自适应学习率来加快收敛速度。ADAM 通过将梯度的一阶矩估计与二阶矩估计为不同的系数设计新的自适应学习率<sup>[32]</sup>,求出更新步长后,可迅速达到优良结果。其初始化参数向量矩阵、一阶矩估计与二阶矩估计表示如下:

$$m_0 = v_0 = 0 \tag{14}$$

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) \frac{\partial J}{\partial w} \tag{15}$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) \left( \frac{\partial J}{\partial w} \right)^2 \tag{16}$$

式中:  $m_0$  和  $v_0$  分别为初始化参数向量矩阵;  $\beta_1$  和  $\beta_2$  分别为算法更新过程中的配置参数,本文取值为 0.9 和 0.999;  $J$  和  $w$  为算法更新过程中的误差和权重。

将一阶动量与二阶动量综合考虑并对权值和阈值进行更新如下:

$$\hat{m}_t = \frac{m_t}{(1 - \beta_1^t)} \tag{17}$$

$$\hat{v}_t = \frac{v_t}{(1 - \beta_2^t)} \tag{18}$$

$$w' = w - \eta \frac{\hat{m}_t}{\sqrt{\hat{v}_t} + \epsilon} \tag{19}$$

式中:  $\eta$  和  $\epsilon$  为配置参数,本文取值 0.01 和  $10 \times 10^{-8}$ ;  $w'$  为算法更新后权重。ADAM 算法使学习速率自适应于梯度变化,克服了单一学习率以及模型收敛问题。

### 2.3 BPNN

BPNN 的概念在 1986 年被提出,是以损失函数最小化为目标的一种双向传递多层神经网络,信号前向传播,误差反向传播,是目前应用于各领域最广泛的神经网络之一。在配电网中,由于潮流数据呈非线性、复杂性和不确定性, BPNN 能自行挖掘多个数据的潜在规律,实现高度非线性映射功能,具有一定的稳定性和容错性,因此在潮流计算中加入 BPNN 是必要的。

本文采用 BPNN 对模型进行训练,通过公式法结合试错法对比相对误差,确定常数  $a$ ,从而进一步确定隐含层节点数。公式如下:

$$M = \sqrt{I + O} + a \tag{20}$$

式中:  $I$  为输入层节点个数,  $O$  为输出层节点个数,  $a$  为 1~10 之间的整数,  $M$  为隐含层节点个数。

BPNN 的神经元之间采用全连接方式如图 2 所示。

图 2 中,  $x_1, x_2, \dots, x_n$  为输入变量,  $y_1, y_2, \dots, y_k$  为输出变量,  $u_j$  和  $y_q$  分别为隐藏层和输出层神经元的输出,  $f$  为激活函数的映射关系,  $v_{ij}$  为第  $i$  个输入变量与第  $j$  个隐藏层神经元的权重,  $\theta_j^u$  为隐藏层  $u$  第  $j$  个神经元的阈值,即偏置项。输入层及隐含层中值为 1 的神经元表示偏置的存在。



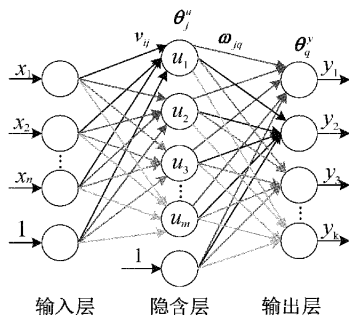


图 2 BPNN 模型

本文隐含层和输出层神经元传递函数分别采用 tansig 和 logsig 函数。隐藏层神经元和输出层神经元的输出表达式为：

$$u_j = f(\sum_{i=1}^n v_{ij}x_i + \theta_j^u), j = 1, 2, \dots, m \quad (21)$$

$$y_q = f(\sum_{j=1}^m w_{jq}u_j + \theta_q^y), q = 1, 2, \dots, k \quad (22)$$

式中： $\theta_q^y$  为输出  $y$  的第  $q$  个神经元的偏置项， $w_{jq}$  为第  $j$  个隐藏层神经元与第  $q$  个输出层神经元连接的权重。式(21)和(22)即为前向传播公式，在计算过程中，将这两个公式代入相对应的激活函数中即可得到输出值。输出层误差  $J$  的损失函数如下：

$$J = \sum_k (y^{(k)} - \hat{y}(k))^2 \quad (23)$$

式中： $y$  为经过神经网络预测值， $\hat{y}$  为输出的真实值。

若最终误差值未达到期望的误差范围内，则进行反向传播，不断更新权重和阈值，直到为期望输出值即可停止。在权重更新的过程中，本文使用自适应矩估计 ADAM 算法来更新权重。设置最大迭代次数 2 000，训练精度  $10^{-4}$ ，当随着迭代次数变化，训练精度基本保持不变时，通过停止准则提前终止训练，输出参数。网络层数及神经元数很大程度上影响神经网络的性能，通过程序不断调试，均方误差达到最小时确定网络参数，本文 BPNN 模型参数仿真结果如表 2 所示。

表 2 BPNN 参数仿真结果

参数	值
输入神经元个数	198
输出神经元个数	66
隐含层层数	3
隐含层各层神经元数	26-22-17
迭代次数	2 000
初始学习率	0.01
批处理	50

2.4 基于 GA-ADAM 优化的 BPNN

本文将 GA-ADAM 优化的 BPNN 网络应用于配电网潮流计算。具体算法结构流程如图 3 所示。

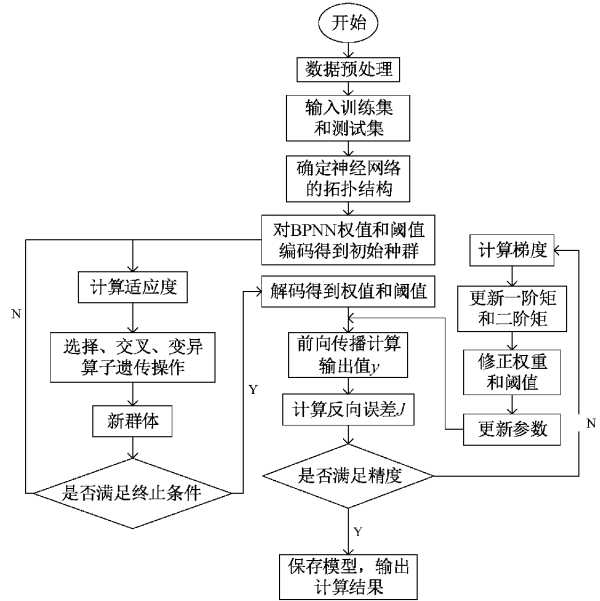


图 3 GA-ADAM-BPNN 网络流程图

图 3 中，适应度值为预测输出和期望输出的绝对差值。经调试，在遗传迭代数达到 50 次之后的适应度值处于基本平稳状态，为减少计算开销，图 3 中的终止条件设为遗传迭代次数 50。

3 算例分析

3.1 算例说明

本文所构建配电网结构是 IEEE-33 节点系统。仿真平台是一台配置为 Windows 10, 11th Gen Intel (R) Core (TM) i5-11400H @ 2.70 GHz 处理器，16.0 GB 内存，NVIDIA GeForce RTX 3050 Laptop GPU 笔记本电脑。仿真软件为 MATLAB 2020b，通过 MATPOWER V7.1 工具包作为仿真软件进行潮流计算。22 节点接入装机容量为 0.7 MW 的光伏，33 节点接入装机容量为 0.7 MW 的风电，该系统的拓扑结构如图 4 所示。




图 4 IEEE-33 系统拓扑图

为验证本文所提模型的有效性，建立了以下 5 种模型：  
 M1: 基于 DLPF 配电网潮流计算模型；  
 M2: 基于改进的前推回代法配电网潮流计算模型；  
 M3: 基于单纯 BPNN 配电网潮流计算模型；  
 M4: 基于 GA-BPNN 配电网潮流计算模型；  
 M5: 基于 GA-BPNN 拓扑结构变化的配电网潮流计算模型。

### 3.2 数据生成及处理

本文潮流数据集基于 IEEE-33 系统生成。数据均可通过软件 MATLAB 搭建电力系统仿真模型,从而进行潮流仿真和数据输出。在生成大量潮流样本过程中,以蒙特卡洛模拟法为基础,将任意收敛的潮流断面视为初始数据,在此基础上以各节点有功、无功功率、电压和相角来实现不同时间断面数据的获取。其中有功、无功功率由本身乘以系数来随机抽取,该系数满足均匀分布区间分别为 $[0.8 \sim 1.2]$ 和 $[0.15 \sim 0.25]$ 。

将整个潮流数据集划分为 4 : 1 的训练集和测试集。由于各潮流变量在数值方面有着显著的差异,因此在训练之前需将潮流数据统一为标么值,其中功率的基准值为  $S_B=10 \text{ MV}\cdot\text{A}$ ,电压的基准值  $U_B=12.66 \text{ kV}$ 。

### 3.3 模型性能评估指标

基于本文模型,将测试的潮流计算输出值和真实潮流输出的偏差来评价模型的预期特性。在评价准则中引入均方误差(mean square error, MSE)、均方根误差(root mean square error, RMSE)、平均绝对误差(mean absolute error, MAE)以及平均绝对百分比误差(mean absolute percent error, MAPE),公式如下:

$$MSE = \frac{\sum_{i=1}^m (y_{ii} - y_{fi})^2}{m} \quad (24)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^m (y_{ii} - y_{fi})^2}{m}} \quad (25)$$

$$MAE = \frac{1}{m} \sum_{i=1}^m |y_{ii} - y_{fi}| \quad (26)$$

$$MAPE = \frac{1}{m} \sum_{i=1}^m \left| \frac{y_{ii} - y_{fi}}{y_{ii}} \right| \times 100\% \quad (27)$$

式中:  $m$  为样本个数;  $y_{ii}$  为潮流输出的真实值;  $y_{fi}$  为潮流输出的预测值。

### 3.4 算例结果与分析

本文主要是针对 IEEE-33 系统对配电网进行单独训练,对训练后回归模型的计算精度进行分析。随着遗传代数不断增加,GA 对初始权重和阈值进行最优选取进化过程中误差的变化如图 5 所示。

由图 5 分析,随着遗传代数增加,网络模型误差形成明显的波动下降趋势,最终达到良好的误差效果。

通过本文模型来进行潮流数据的训练和计算,各节点电压幅值和相角训练误差如图 6 和 7。从大体趋势来看,经过潮流数据的训练取得了良好的效果,误差点线图在 0 附近小幅度波动,表现出稳定的状态。

电压分布如图 8。将 BPNN 与 GA 优化后的 BPNN 相比较,能够很直观看出本文所用 GA-BPNN 网络模型的电压分布曲线更加接近于实际值,将 GA 加入 BPNN 模型中训练,有效改善模型性能,凸显 GA 的优势。通过对 1 000

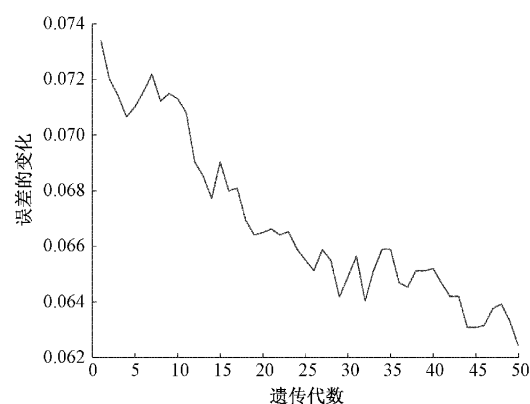


图 5 GA 的进化过程




图 6 IEEE-33 系统的电压幅值结果对比图




图 7 IEEE-33 系统的电压相角结果对比图

个潮流样本进行训练,BPNN 模型训练样本的总误差为 0.965,GA-BPNN 模型训练样本总误差为 0.861,下降了 10.78%,效果得到了明显的改善。经 IEEE-33 系统潮流计算结果,BPNN 和 GA-BPNN 模型电压幅值总误差分别为 0.077 和 0.048,误差值降低 37.66%;其 RMSE 分别为  $19.82 \times 10^{-3}$  和  $1.81 \times 10^{-3}$ ,突出展现了 GA 的优化起到了良好作用。如图 9 为电压相角分布图,由图明显可以看出优化后的网络所计算的结果更加精确。BPNN 模型电压相角的 RMSE 为 0.071,GA-BPNN 模型下的电压相角为 0.029,直接下降了 59.15%。

不同模型下,如改进的前推回代法、DLF 法、BPNN 法和 GA-BPNN 法,在 IEEE-33 系统上电压幅值和相角的分布情况分别如图 10 和 11,呈现潮流数据以及误差分布




图 8 IEEE-33 系统的电压幅值分布图




图 9 IEEE-33 系统的电压相角分布图




图 10 IEEE-33 系统的电压幅值潮流计算结果




图 11 IEEE-33 系统的电压相角潮流计算结果

情况。每条曲线呈现走势一致的趋势，但相比较误差有所差别，误差面积大小如背后阴影面积所示。

各曲线数值以最大误差、MAE 和 MAPE 作为衡量准

确性指标，如表 3 所示为各方法进行潮流计算的误差结果。经数据分析，以电压幅值为例，改进的前推回代法最大误差最小为 0.002 01，但 MAE 值最大为 0.011 7，反映出数据普遍偏离真实值，效果不佳；GA-BPNN 模型最大误差仅有 0.003 93，MAE 仅有 0.001 46，MAPE 仅有 0.146 51；BPNN 模型各项指标只有 0.004 63、0.002 34 和 0.234 39；DLPF 模型各项指标只有 0.009 68、0.002 和 0.2，GA-BPNN 模型取得了好的效果。

表 3 基于数据驱动各模型的潮流计算误差结果

测试算例	模型	最大误差		MAE		MAPE	
		V	$\theta$	V	$\theta$	V	$\theta$
IEEE-33 配电系统	DLPF	0.009 68	0.096 42	0.002 000 0	0.028	0.200 00	2.8
	改进的前推回代	0.002 01	—	0.011 700 0	—	1.170 00	—
	BPNN	0.004 63	0.152 07	0.002 343 9	0.058	0.234 39	5.8
	GA-BPNN	0.003 93	0.063 78	0.001 465 1	0.023	0.146 51	2.3
拓扑变化	SVR	0.010 31	—	0.002 442 4	—	0.244 24	—
IEEE-33 配电系统	GA-BPNN	0.005 13	—	0.001 003 9	—	0.100 39	—

如图 4 所示，包含虚线部分所构成的网络重构图有 33 个节点，37 条支路，其中 5 条为联络支路。在 IEEE-33 系统网络重构配电网中，有功损耗减少约 50%，最小电压节点位置发生转移，电网潮流分布改变。在电网拓扑结构发生变化时，本文模型针对于潮流计算依然适用。以实际的电网重构潮流与 GA-BPNN 及 SVR 模型结构网络重构潮流对比，如图 12 所示。首先，相较于配电网重构前，重构后的电压幅值有所提升<sup>[33]</sup>，潮流分布部分发生变化和转移；其次，在重构配电网结构不变情况下，引用 SVR 模型

计算潮流并对比，其分布趋势与实际潮流大体一致，如表 3 所示，经数据分析，最大误差为 0.010 31，MAE 为 0.002 44；最后，以 GA-BPNN 模型对拓扑变化的配电网进行潮流计算，计算的电压幅值与实际值分布趋势相符，最大误差仅为 0.005 13，相较于 SVR 模型更平稳，MAE 仅为 0.001，体现了本文模型在拓扑结构变化时的潮流计算中仍然适用，并且训练效果优于 SVR 模型，展现了良好的鲁棒性与泛化性能。

在计算时长方面，基于本文 IEEE-33 测试算例，比较




图12 重构IEEE-33系统电压幅值潮流计算结果

了N-R法与本文方法单个时间断面的潮流计算的时间<sup>[34]</sup>,如表4所示。

表4 计算时间比较

潮流计算方法	潮流计算时间/s
N-R法	0.07
GA-ADAM优化的BPNN法	0.02

## 4 结 论

本文提出了基于GA-ADAM优化算法的BPNN数据驱动潮流非线性回归方法,不依赖于电网线路参数,通过电网潮流的量测数据,实现数据驱动配电网潮流计算的快速性和准确性分析。主要结论如下:

首次将GA-ADAM优化的BPNN模型用于潮流计算,所建立的非线性潮流回归模型,能有效应用于大规模潮流数据集多输入多输出的训练,潮流回归模型准确度高,在线潮流计算速度快。

所提出的特征融合包含潮流初值、拓扑结构和功率因数指标进行训练,更加丰富刻画了电网特征,且增强了拓扑变化的适应性。

所提出的GA-ADAM优化算法,解决了潮流回归模型训练时,初值陷入局部最优和更新权重带来的收敛性问题。

所采用的离线训练和在线应用机制,无需考虑潮流计算数值迭代问题,有效提高了潮流计算的速度。

本文潮流计算方法和结果可以为电力系统其他研究提供参考。在“人工智能”时代,未来将进一步加强数据驱动潮流计算回归模型的构建,挖掘电网更多特征参数之间的关系,并考虑三相不对称等的情况,以更好适应新能源电力系统带来的挑战。

## 参考文献

[1] 黎博,陈民铀,钟海旺,等. 高比例可再生能源新型电力系统长期规划综述[J]. 中国电机工程学报,2023,43(2):555-581.

[2] 杨燕,杨知方,余娟,等. 基于深度学习的含不确定性N-1安全校核方法[J]. 中国电机工程学报,2021,41(8):2716-2725.

[3] 康重庆,姚良忠. 高比例可再生能源电力系统的关键科学问题与理论研究框架[J]. 电力系统自动化,2017,41(9):2-11.

[4] 蒋斌,吴健,冯亮,等. 含分布式发电的有源配电网电压稳态指标计算研究[J]. 电子测量与仪器学报,2017,31(6):885-891.

[5] 陈芷欣,丁家满. 基于概率盒理论的源荷不确定性最优潮流[J]. 电子测量技术,2021,44(7):61-68.

[6] KANG C, WANG Y, XUE Y, et al. Big data analytics in china's electric power industry: Modern information, communication technologies, and millions of smart meters[J]. IEEE Power and Energy Magazine,2018,16(3):54-65.

[7] 曹昆,李国昌,王艳松,等. 基于大数据和随机矩阵理论的变电站状态评估[J]. 中国测试,2020,46(8):149-157.

[8] 张捷,徐焰,张学飞. 一种改进前推回代法的配电网潮流计算[J]. 四川电力技术,2020,43(3):85-90.

[9] 刁守斌,于涛,王健建,等. 基于保留非线性算法的直流配电网潮流计算[J]. 电气工程学报,2020,15(4):75-84.

[10] LIU Y, WANG Y, ZHANG N, et al. A data-driven approach to linearize power flow equations considering measurement noise[J]. IEEE Transactions on Smart Grid,2019,11(3):2576-2587.

[11] 邓红雷,张莉彬,唐崇旺,等. 一种含分布式电源的配电网三相潮流混合计算方法[J]. 电力系统保护与控制,2020,48(14):10-17.

[12] 刘洪,赵晨晓,葛少云,等. 基于精细化热网模型电热综合能源系统时序潮流计算[J]. 电力系统自动化,2021,45(4):63-72.

[13] 刘羽霄,张宁,康重庆. 数据驱动的电力网络分析与优化研究综述[J]. 电力系统自动化,2018,42(6):157-167.

[14] LI G, ZHANG Y X. Data-driven power flow calculation method: A lifting dimension linear regression approach[J]. IEEE Transactions on Power Systems,2022,37:1798-1808.

[15] YI T, CHEN Y Y. Linearizing power flow model: A hybrid physical model-driven and data-driven approach[J]. IEEE Transactions on Power Systems,2020,35:2475-2478.

[16] 凌佳杰,耿光超,江全元. 基于变分子量算法的电力系统潮流计算[J]. 中国电机工程学报,2023,43(1):28-37.

[17] 赵为光,钟懿文,徐欢欢,等. 贝叶斯数据驱动的精确解耦线性潮流模型[J]. 黑龙江科技大学学报,2023,33(2):250-258,265.

[18] LIU Y, ZHANG N, WANG Y, et al. Data-driven



- power flow linearization: A regression approach[J]. IEEE Transactions on Smart Grid, 2019, 10(3): 2569-2580.
- [19] LIU Y, LI Z, ZHOU Y. Data-driven-aided linear three-phase power flow model for distribution power systems[J]. IEEE Transactions on Power Systems, 2022, 37(4): 2783-2795.
- [20] VEERAPANDIYAN V, NOOR I A W. A novel RK4-hopfield neural network for power flow analysis of power system[J]. Appl. Soft Comput, 2020, 93: 106346, DOI:10.1016/j.asoc.2020.106346.
- [21] HU X Y, HU H J. Physics-guided deep neural networks for power flow analysis [J]. IEEE Transactions on Power Systems, 2020, 36: 2082-2092.
- [22] 王甜婧, 汤涌, 郭强, 等. 基于知识经验和深度强化学习的大电网潮流计算收敛自动调整方法[J]. 中国电机工程学报, 2020, 40(8): 2396-2406.
- [23] 刘学华, 孔霄迪. 基于卷积神经网络的 N-2 线路开断潮流快速计算[J]. 电力工程技术, 2021, 40(4): 95-100.
- [24] YU J, WENG Y, RAJAGOPAL R. Robust mapping rule estimation for power flow analysis in distribution grids[J]. 2017 North American Power Symposium(NAPS), 2017: 1-6, DOI: 10.1109/NAPS.2017.8107397.
- [25] 杨浩, 朱宇迪, 刘铖, 等. 基于 MLSSVR 数据驱动的潮流非线性回归及其灵敏度解析[J]. 中国电机工程学报, 2022, 42(21): 7706-7719.
- [26] XIANG M X, YU J, YANG Z F, et al. Probabilistic power flow with topology changes based on deep neural network[J]. International Journal of Electrical Power & Energy Systems, 2020, 117: 105650, DOI: 10.1016/j.ijepes.2019.105650.
- [27] 马丁, 沈沉, 陈颖, 等. 深度学习应用于潮流计算判敛问题的可行性研究[J]. 南方电网技术, 2020, 14(2): 46-54.
- [28] 李峰, 王琦, 胡健雄, 等. 数据与知识联合驱动方法研究进展及其在电力系统中应用展望[J]. 中国电机工程学报, 2021, 41(13): 4377-4390.
- [29] CHEN J, LI W, WU W, et al. Robust data-driven linearization for distribution three-phase power flow[J]. IEEE 4th Conference on Energy Internet and Energy System Integration (EI2), 2020: 1527-1532, DOI: 10.1109/EI250167.2020.9347375.
- [30] 贾玉婷, 王泰华, 李忠林. 基于模式聚类的多种群模糊遗传算法的研究[J]. 国外电子测量技术, 2019, 38(3): 8-13.
- [31] 吴凯枫, 张立新, 阚希, 等. 基于改进 GA-BP 神经网络的压力传感器校准方法[J]. 国外电子测量技术, 2023, 42(2): 38-44.
- [32] 谭祥帅, 白世雄, 李昭, 等. 基于 ADAM-BPNN 模型单汽泵故障联动控制技术研究应用[J]. 中国电机工程学报, 2023, 43(3): 1095-1106.
- [33] ELRAZKY R R, HIEBA A A, DAOUD A A. Study network reconfiguration using optimization techniques to improve voltage stability, 2021 international telecommunications conference (ITC-Egypt) [J]. Alexandria, Egypt, 2021: 1-4, DOI: 10.1109/ITC-Egypt52936.2021.9513917.
- [34] 董昱, 董存, 于若英, 等. 基于线性潮流的电力系统长时间尺度快速时序仿真方法[J]. 电力建设, 2022, 43(2): 126-134.

### 作者简介

刘会家, 副教授, 主要研究方向为高压电力设备在线监测、配电网规划与运行。

E-mail: 1760163894@qq.com

冯铃, 硕士, 主要研究方向为电力系统配电网潮流计算。

E-mail: 272317554@qq.com

艾璨, 硕士, 主要研究方向为配电网自动化、配电网可靠性。

E-mail: 513122748@qq.com