

# 基于深度神经网络的数据驱动潮流计算异常误差改进策略

雷江龙, 余娟, 向明旭, 杨知方, 杨燕, 李文沅

(输配电装备及系统安全与新技术国家重点实验室(重庆大学), 重庆市 400044)

**摘要:** 在考虑不确定性的  $N-1$  安全校核、可靠性计算等需大规模重复潮流计算的场景中, 基于深度神经网络(DNN)的数据驱动方法存在部分潮流变量误差异常的问题, 影响潮流越限判别的准确率。对此, 首先通过理论推导, 分析DNN参数更新过程及数据标准化原理, 发现该问题的重要成因之一为: DNN仅根据标准化误差迭代训练模型, 未计及潮流变量的真实学习误差及工程实际的精度要求, 无法及时针对误差异常的潮流变量调整DNN参数。然后, 面向潮流计算提出基于动态学习权重的DNN自适应训练方法。该方法通过每轮迭代中验证集的真实学习误差、越限误判率及误差统计指标, 确定各潮流变量的学习权重, 有效降低数据驱动潮流计算的异常误差。最后, 在IEEE标准算例和Polish 2383节点系统上仿真验证了所提方法的有效性。

**关键词:** 数据驱动; 潮流计算; 深度神经网络(DNN); 异常误差分析; 学习权重

## 0 引言

潮流计算作为电力系统分析的必要工具, 广泛应用于运行优化、安全分析等场景, 其计算效率及精度影响着电力系统安全稳定运行<sup>[1]</sup>。近年来, 为应对风能、光能等新能源大规模并网所带来的强不确定性,  $N-1$ 安全校核<sup>[2]</sup>、概率潮流计算<sup>[3]</sup>和实时安全分析<sup>[4-5]</sup>等需要进行大规模重复潮流计算的场合将面临更高的计算效率和精度要求。非线性交流潮流模型的求解方法计算精度高, 但面对大规模重复潮流求解的计算需求时, 计算效率面临挑战<sup>[6]</sup>。线性化潮流模型可有效提高计算效率且不存在收敛问题, 但线性简化潮流模型牺牲了计算精度<sup>[7-9]</sup>。

随着数据驱动技术的不断发展, 已有研究提出采用神经网络(neural network, NN)提高大规模重复潮流计算的求解效率。NN通过对潮流数据特征的迭代学习, 实现大量系统状态至对应潮流结果的直接映射, 计算效率高且不存在收敛问题, 具体包括极限学习机<sup>[10]</sup>、反向传播神经网络<sup>[11]</sup>、径向基函数神经网络<sup>[12]</sup>、深度神经网络(deep neural network, DNN)<sup>[13-15]</sup>等。相较于浅层NN, DNN具有更强的特征提取和泛化能力<sup>[13]</sup>, 在电力系统研究中已受到

广泛关注。然而, 现有DNN训练方法存在误差异常问题: 即使模型整体精度已达标, 但仍有部分潮流变量的误差较大<sup>[13-15]</sup>。上述问题将影响 $N-1$ 安全校核等场景下潮流越限判别的准确率, 威胁电网安全稳定运行。而如何处理数据驱动潮流分析方法的异常误差问题现有文献鲜有涉及, 还有待进一步研究。

对此, 本文结合DNN参数更新过程及数据标准化原理, 对数据驱动潮流分析误差异常的成因进行了理论分析。为改善该问题, 本文在现有DNN训练框架的基础上, 面向潮流计算提出了一种基于动态学习权重的DNN自适应训练方法, 可引导DNN高精度学习误差异常的潮流变量, 提升潮流计算精度。本文主要贡献如下。

1) 根据DNN梯度更新理论及数据标准化原理, 理论分析部分潮流变量存在异常误差的原因。本文发现DNN训练需依据的标准化误差, 无法准确反映各潮流变量的真实学习误差和实际精度需求是导致潮流计算存在异常误差的重要原因之一。

2) 提出基于动态学习权重的DNN自适应训练方法。通过每轮迭代验证集的真实学习误差、越限误判率及误差评价标准, 动态设置各潮流变量的学习权重, 有效衡量训练中各潮流变量的真实学习效果, 并嵌入DNN引导各潮流变量的学习。

## 1 基于DNN的潮流计算模型

本文所构建的DNN潮流训练模型将考虑负

收稿日期: 2021-05-16; 修回日期: 2021-09-03。

上网日期: 2021-11-19。

国家自然科学基金资助项目(52077016); 重庆市自然科学基金资助项目(cstc2020jcyj-msxmX0315); 中央高校基本科研业务费专项资金资助项目(2020CDJ-LHZZ-079)。

荷、新能源出力不确定性以及支路或发电机故障引起的 $N-1$ 拓扑结构变化,但并未关注网架新增线路情况。若网架新增线路,需针对新场景重新训练DNN潮流模型,此时可基于迁移学习技术<sup>[16]</sup>进行快速训练。DNN输入特征向量 $X_i$ 包括节点注入功率和拓扑结构变化信息(其中,拓扑结构信息表征方法详见文献[15])。输出特征向量 $Y_i$ 包括节点电压幅值、电压相角、支路有功和无功功率。

DNN基本训练流程如图1所示。为消除不同类型潮流变量间(如电压幅值、相角、支路功率等)的量纲差别,保证DNN训练的收敛性,在对DNN进行训练前,需对样本数据(包括输入和输出)进行标准化预处理<sup>[17-18]</sup>。本文潮流数据中包含源荷及拓扑变化,宜采用 $z$ -score标准化方法<sup>[15]</sup>。以输出数据为例, $z$ -score标准化方法如式(1)所示。

$$Y_{mn} = \frac{Y_{i,mn} - \mu_{Y,n}}{\delta_{Y,n}} \quad (1)$$

式中: $Y_{i,mn}$ 为第 $m$ 个样本中第 $n$ 个潮流变量的待标准化数据; $Y_{mn}$ 为第 $m$ 个样本中第 $n$ 个潮流变量的标准化结果; $\mu_{Y,n}$ 为第 $n$ 个输出潮流变量的均值; $\delta_{Y,n}$ 为第 $n$ 个输出潮流变量的标准差。



图1 DNN基本训练流程  
Fig. 1 Basic training process of DNN

DNN主要包括单个输入层、多个隐藏层和单个输出层,各层由若干神经元构成,仅层与层之间的神经元相互连接。多隐藏层的结构使得DNN相较于浅层网络具有更强的特征提取能力,适用于拟合具有强非线性的潮流方程。DNN模型由输入计算得到输出的前向传播过程如式(2)一式(3)所示。

$$\hat{Y} = f_L(\dots f_l(\dots f_2(X))) \quad (2)$$

$$\hat{Y}_l = f_l(X_l) = s(W_{l-1}X_l + b_l) \quad (3)$$

式中: $X$ 为标准化的DNN输入; $\hat{Y}$ 为标准化的DNN预测输出; $L$ 为DNN的总层数; $X_l$ 为第 $l(2 \leq l \leq L)$ 层的输入; $\hat{Y}_l$ 为第 $l$ 层的预测输出; $f_l(\cdot)$ 为第 $l$ 层的预测输出函数; $s(\cdot)$ 为神经元的激活函数,本文分别选择ReLU函数和线性函数作为隐藏层和输出层的激活函数; $W_{l-1}$ 为第 $l-1$ 层与第 $l$ 层之间的权重; $b_l$ 为第 $l$ 层的偏置。

训练后的DNN可根据潮流输入直接映射得到潮流计算结果。为得到实际潮流计算结果还需对DNN预测输出进行反标准化处理,如式(4)所示。

$$\hat{Y}_{i,mn} = \hat{Y}_{mn} \delta_{Y,n} + \mu_{Y,n} \quad (4)$$

式中: $\hat{Y}_{i,mn}$ 为第 $m$ 个样本中第 $n$ 个潮流变量输出预测值的反标准化结果,即为DNN所得潮流计算结果; $\hat{Y}_{mn}$ 为第 $m$ 个样本中第 $n$ 个潮流变量的DNN预测值。

最后,通过统计计算结果来评价模型性能。

## 2 异常误差问题描述及原因分析

本章将对现有数据驱动潮流计算方法面临的异常误差问题进行详细描述并分析其产生的原因。

### 2.1 问题描述

电力系统潮流计算不仅需要关注DNN整体精度,同时还要求各节点、支路的潮流变量具有较高的学习精度。因此,对比分析了各潮流变量的学习精度,发现现有DNN潮流计算模型存在如下问题:即使DNN整体精度已满足要求,但仍有部分潮流变量存在异常误差。基于现有训练方法<sup>[15]</sup>的DNN模型测试误差如表1所示;电压幅值和支路有功功率的统计误差如图2所示。由表1可知,DNN模型的整体精度较高,但不同类型潮流变量的学习精度存在较大差异。其中,电压幅值和支路有功功率的误差明显大于电压相角和支路无功功率。此外,尽管电压幅值和支路有功功率的整体精度较高,但如图2所示,部分潮流变量误差存在异常。例如,支路27的有功功率统计误差高达20.90%,且经测试证明,支路27处的异常误差将最终影响 $N-1$ 安全校验的准确率。

表1 IEEE 39节点系统的DNN模型误差  
Table 1 DNN model error of IEEE 39-bus system

电压幅值大于 0.000 5 p.u.的 概率/%	电压相角大 于0.01 rad的 概率/%	有功功率大于 3 MW的 概率/%	无功功率大于 3 Mvar的 概率/%
2.10	0.08	3.69	0.11

### 2.2 引起DNN潮流模型异常误差的原因分析

本节将对引起DNN潮流模型异常误差的原因进行分析。DNN训练的数学过程是:通过不断迭代训练来优化模型参数 $\rho$ ,从而降低DNN预测值 $\hat{Y}_{mn}$ 与样本真实值 $Y_{mn}$ 之间的偏差。该偏差的大小通常通过损失函数表征。本文选择均方差函数作为损失函数,其计算公式如式(5)所示。

$$J = \frac{1}{2M} \sum_{m=1}^M \sum_{n=1}^N (\hat{Y}_{mn} - Y_{mn})^2 = \frac{1}{2M} \|\hat{Y} - Y\|^2 \quad (5)$$

式中: $M$ 为训练样本数量; $N$ 为输出潮流变量的维数; $J$ 为损失函数; $Y$ 为标准化的DNN的预测输入。

式(5)所示损失函数中的误差项为标准化后的误差,而在评价DNN预测精度及应用DNN进行潮

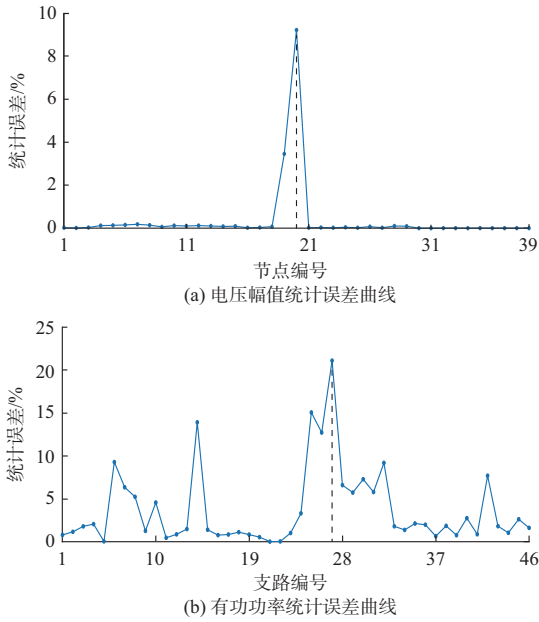


图2 潮流变量统计误差曲线  
Fig. 2 Statistical error curves of power flow variables

流计算时,所关注的则是各潮流变量的真实误差,即反标准化后的误差。本文以  $z$ -score 标准化方法为例进行分析,由式(1)的标准化公式,可将损失函数变换为以真实误差表示,如式(6)所示。

$$J = \frac{1}{2M} \sum_{m=1}^M \sum_{n=1}^N \left( \frac{\hat{Y}_{f, mn} - \mu_{Y, n}}{\delta_{Y, n}} - \frac{Y_{mn} - \mu_{Y, n}}{\delta_{Y, n}} \right)^2 = \frac{1}{2M} \sum_{m=1}^M \sum_{n=1}^N \left( \frac{\hat{Y}_{f, mn} - Y_{f, mn}}{\delta_{Y, n}} \right)^2 \quad (6)$$

由式(5)和式(6)可知,标准化前后的训练误差通过各潮流变量的标准差相互关联。但由于各潮流变量的标准差大小存在差异,各潮流变量误差在标准化前后的相对大小并不一致,将导致DNN在训练过程中无法准确获悉潮流变量的真实误差,影响DNN对各潮流变量的学习效果。下面将进行详细阐述。

DNN通过反向传播过程更新参数,本文采用RMSProp算法训练DNN<sup>[19]</sup>,并据此说明异常误差产生的原因,DNN模型参数的更新过程具体如下。

$$d\rho^{(t)} = \frac{\partial J}{\partial \rho^{(t)}} \quad (7)$$

$$v^{(t+1)} = \gamma v^{(t)} - (1 - \gamma)(d\rho^{(t)})^2 \quad (8)$$

$$\rho^{(t+1)} = \rho^{(t)} - \frac{\lambda}{\sqrt{v^{(t+1)} + \epsilon}} d\rho^{(t)} \quad (9)$$

式中: $\rho^{(t)}$ 为第 $t+1$ 轮迭代时待更新的模型参数; $\rho^{(t+1)}$ 为更新后的模型参数; $d\rho^{(t)}$ 为第 $t$ 轮迭代时模型参数的梯度; $v^{(t+1)}$ 为第 $t+1$ 轮迭代时的累积动量; $\gamma$

为动量衰减率; $\lambda$ 为学习率; $\epsilon$ 为取值非常小的常数。

由式(7)~式(9)可知,DNN参数梯度的大小和方向将直接影响DNN参数更新量,进而决定着DNN对各潮流变量学习效果的差异性。同时由式(8)和式(9)可知,当前迭代计算得到的梯度还会通过累积动量影响后续的迭代更新过程。本文所选激活函数为ReLU和线性激活函数,对于某一次迭代而言,其模型任意一层参数的梯度计算如式(10)~式(13)所示。

$$d\hat{Y}_{l,i} = \hat{Y}_{l,i} - Y_{l,i} = \frac{\hat{Y}_{l,i} - Y_{l,i}}{\delta_{Y,i}} \quad l=L \quad (10)$$

$$d\hat{Y}_{l,i} = \sum_{j=1}^{n_{l+1}} d\hat{Y}_{l+1,j} W_{l+1,ij} \quad 2 \leq l \leq L-1 \quad (11)$$

$$dW_{l,ij} = d\hat{Y}_{l,i} \hat{Y}_{l-1,j} \quad (12)$$

$$db_{l,i} = d\hat{Y}_{l,i} \quad (13)$$

式中: $\hat{Y}_{l,i}$ 为第 $l$ 层第 $i$ 个神经元的预测输出; $\hat{Y}_{l,i}$ 和 $Y_{l,i}$ 分别为第 $l$ 层第 $i$ 个神经元预测输出和真实值的反标准化结果; $d\hat{Y}_{l,i}$ 为损失函数对第 $l$ 层第 $i$ 个神经元输出的梯度; $dW_{l,ij}$ 为第 $l$ 层第 $i$ 个神经元与相邻层第 $j$ 个神经元之间权重 $W_{l+1,ij}$ 的梯度; $Y_{l,j}$ 为第 $l$ 层第 $j$ 个神经元的输出; $db_{l,i}$ 为第 $l$ 层第 $i$ 个神经元偏置 $b_{l,i}$ 的梯度; $\delta_{Y,i}$ 为标准差; $n_l$ 为第 $l$ 层神经元个数。

由式(10)~式(13)可知,DNN参数梯度将由式(10)和式(11)所示DNN各层输出的梯度决定,其与标准化训练误差 $\hat{Y}_{l,i} - Y_{l,i}$ 和真实训练误差 $\hat{Y}_{l,i} - Y_{l,i}$ 均呈正相关,与潮流变量的标准差 $\delta_{Y,i}$ 呈负相关。因此,当标准差 $\delta_{Y,i}$ 较大时,潮流变量真实训练误差对梯度的影响将较小。相反,对于标准差 $\delta_{Y,i}$ 较小的潮流变量,其真实训练误差对梯度的影响将更为显著。

综上所述,DNN在训练过程中无法计及真实学习误差以及精度需求,导致其无法获悉各潮流变量的真实学习效果,使得训练中所重视的潮流变量(标准化误差较大的潮流变量)可能的实际学习效果较好,反而忽视实际学习效果较差的潮流变量,最终影响DNN对各潮流变量的学习效果。由于各标准化方法处理数据思路类似,都需选择基准值缩放数据,故选择其他标准化方法也将存在上述问题。

### 3 基于动态学习权重的DNN自适应训练方法

本文在现有DNN训练框架中引入潮流变量动态学习权重,从而合理引导DNN模型参数的更新过程,改善部分潮流变量误差异常的问题。



### 3.1 内嵌学习权重的DNN自适应训练框架

本文通过在损失函数中嵌入各潮流变量的学习权重指导DNN训练过程。在嵌入学习权重后,损失函数由式(5)变为式(14):

$$J' = \frac{1}{2M} \sum_{m=1}^M \sum_{n=1}^N k_n (\hat{Y}_{mn} - Y_{mn})^2 \quad (14)$$

式中: $J'$ 为更新后的损失函数; $k_n$ 为第 $n$ 个潮流变量的学习权重。

嵌入的学习权重将作用于DNN模型参数的更新过程,指导DNN的训练,梯度计算过程中的式(10)将变为式(15):

$$d\hat{Y}_{L,n}^{(t)} = k_n^{(t)} (\hat{Y}_n^{(t)} - Y_n) \quad (15)$$

式中: $d\hat{Y}_{L,n}^{(t)}$ 为作用学习权重后第 $t$ 轮迭代时损失函数对第 $n$ 个潮流输出变量的梯度; $\hat{Y}_n^{(t)}$ 为第 $t$ 轮迭代时DNN的第 $n$ 个潮流变量的预测输出; $Y_n$ 为第 $n$ 个潮流变量的真实值; $k_n^{(t)}$ 为第 $t$ 轮迭代时第 $n$ 个潮流变量的学习权重。

由式(15)及式(8)和式(9)可以看出,所嵌入的学习权重能通过损失函数直接影响模型参数的更新过程。学习权重较大的潮流变量对模型参数更新的影响程度将变大;对于权重很小或者为零的潮流变量,其对参数更新的影响程度将随之减小。学习权重将指导DNN对误差异常潮流变量的学习,从而取得更好的训练效果。而其中的关键在于如何设置学习权重,使其能有效反映DNN训练过程中各潮流变量的真实学习效果。

### 3.2 学习权重动态设置方法

如2.2节所述,各潮流变量标准差的不同是引起本文所述问题的主要原因。因此,较为直观的权重设置方法是根据各潮流变量的标准差设置学习权重。但由于各潮流变量的标准差是固定的,而在训练中各潮流变量学习误差的相对大小关系是变化的,仅使用标准差将无法动态追踪潮流变量的学习误差变化情况,存在一定局限性。对此,本文基于验证集学习情况,提出了一种学习权重动态设置方法,具体介绍如下。

由于不同类型潮流变量的真实误差在量纲上存在较大差异,故本文需针对不同潮流变量类型分别设置学习权重。验证集不同于训练集,可反映DNN对未知样本的学习效果。为避免模型出现过拟合,本文通过验证集的真实学习误差来表征每轮迭代DNN模型对各潮流变量的真实学习效果,并据此为各潮流变量动态设置误差相关学习权重。此外,早停法<sup>[20]</sup>的应用可进一步防止过拟合现象。以电压幅值为例,由验证集误差确定各节点电压幅值的误差

相关学习权重的具体过程见式(16)和式(17)。

$$E_{V,c}^{(t)} = \sum_{r=1}^R |e_{V,rc}^{(t)}| \quad (16)$$

$$U_{V,c}^{(t)} = \frac{E_{V,c}^{(t)} - E_{\min}}{E_{\max} - E_{\min}} \quad (17)$$

式中: $e_{V,rc}^{(t)}$ 为第 $t$ 轮迭代时第 $r$ 个样本节点 $c$ 处的误差,其中 $c=1, 2, \dots, N_b, N_b$ 为节点数; $R$ 为验证集样本数; $E_{V,c}^{(t)}$ 为第 $t$ 轮迭代时节点 $c$ 处电压幅值的平均绝对误差; $E_{\max}$ 和 $E_{\min}$ 分别为第 $t$ 轮迭代时各节点电压幅值平均绝对误差的最大值和最小值; $U_{V,c}^{(t)}$ 为第 $t$ 轮迭代时节点 $c$ 处电压幅值的误差相关学习权重。

潮流变量整体误差较小不一定代表其越限误判率较小。所以,在 $N-1$ 安全校核等需要考虑越限判别情况的场景下,DNN除绝对学习误差外,还需关注越限判别准确率。因此,本文进一步根据验证集中各潮流变量的越限误判情况为其设置越限相关学习权重,使得训练过程关注误判严重的潮流变量,如式(18)所示。

$$B_{V,c}^{(t)} = \frac{A_{V,c}^{(t)} - A_{\min}}{A_{\max} - A_{\min}} \quad (18)$$

式中: $A_{V,c}^{(t)}$ 为第 $t$ 轮迭代时节点 $c$ 处电压幅值越限误判的样本总数; $A_{\max}$ 和 $A_{\min}$ 分别为第 $t$ 轮迭代时各节点电压幅值越限误判样本数的最大值和最小值; $B_{V,c}^{(t)}$ 为第 $t$ 轮迭代时节点 $c$ 处电压幅值的越限相关学习权重。

将误差相关学习权重和越限相关学习权重进行组合,构成最终学习权重,如式(19)和式(20)所示。

$$k_{V,c}^{(t)} = \alpha_1 U_{V,c}^{(t)} + \alpha_2 B_{V,c}^{(t)} \quad (19)$$

$$\mathbf{k}_V^{(t)} = [k_{V,1}^{(t)}, k_{V,2}^{(t)}, \dots, k_{V,N_b}^{(t)}] \quad (20)$$

式中: $\mathbf{k}_V^{(t)}$ 为第 $t$ 轮迭代时电压幅值组合学习权重; $\alpha_1$ 和 $\alpha_2$ 为组合系数,本文均设为1。同理可得电压相角、支路有功和无功功率对应的组合学习权重。

前述针对不同类型潮流变量分别设置了相应的学习权重。然而,现有DNN训练方法还存在某些类型潮流变量的整体误差统计指标偏大的问题。对此,本文进一步提出基于学习权重调整系数的误差均衡策略。其主要思想是通过给不同类型潮流变量的学习权重增加合适的调整系数,从而以适当牺牲误差较小潮流变量类型的学习精度为代价,提升误差较大潮流变量类型的学习精度。添加调整系数后的学习权重 $\bar{k}^{(t)}$ 的表达式如式(21)所示。

$$\bar{k}^{(t)} = \{ \beta_V \mathbf{k}_V^{(t)}, \beta_\theta \mathbf{k}_\theta^{(t)}, \beta_P \mathbf{k}_P^{(t)}, \beta_Q \mathbf{k}_Q^{(t)} \} \quad (21)$$

式中: $\beta_V, \beta_\theta, \beta_P, \beta_Q$ 分别为电压幅值、电压相角、支路有功和无功功率的权重调整系数; $\mathbf{k}_V^{(t)}, \mathbf{k}_\theta^{(t)}, \mathbf{k}_P^{(t)}, \mathbf{k}_Q^{(t)}$ 分别为对应的组合学习权重。调整系数根据每轮迭代中

各潮流变量的误差评价指标进行确定。

### 3.3 内嵌学习权重的DNN模型训练流程

本文所提基于动态学习权重的DNN自适应训练流程如图3所示。

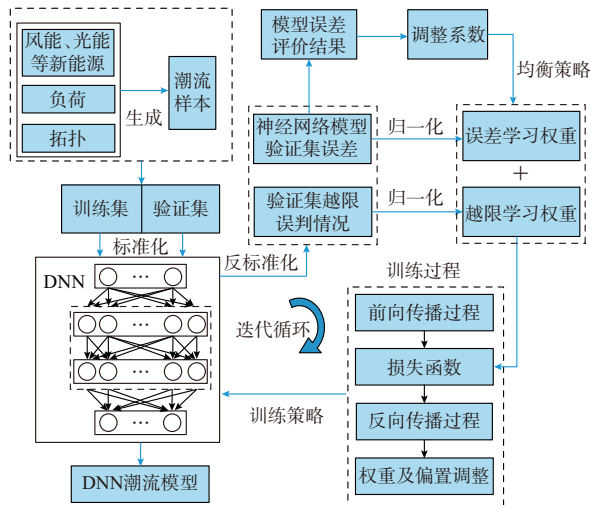


图3 内嵌学习权重的DNN自适应训练流程  
Fig.3 DNN adaptive training process with embedded learning weights

## 4 算例分析

本文在IEEE 39、IEEE 118和Polish 2383节点系统上仿真验证所提方法的有效性。

### 4.1 算例说明

本文在IEEE 39节点系统的节点23、24及25上分别接入容量为260 MW的风电场，在节点17、18及19上分别接入容量为200 MW的光伏发电站，新能源渗透率为20%。对于IEEE 118节点系统，容量为330 MW的风电场和容量为250 MW的光伏发电站分别接到10个不同的节点上，新能源渗透率达30%。风速和太阳辐射强度的分布、参数及风光转换模型参见文献[21-22]。假定负荷波动服从正态分布，其均值参考IEEE标准算例，标准差为均值的10%。本文所用潮流训练样本考虑 $N-1$ 支路故障及 $N-1$ 发电机组故障<sup>[22]</sup>。

本文将在不同算例中对比如下方法，以验证本文所提方法的有效性。

M0: 基于牛顿-拉夫逊算法的交流潮流计算，结果作为参考值。

M1: 基于DNN的潮流计算，采用常规DNN训练方法<sup>[14]</sup>。

M2: 在M1基础上，按潮流变量类型将标准差归一化至 $[0, 1]$ ，并将其设为学习权重。

M3: 在M1基础上，引入本文所提的误差相关学习权重。

M4: 在M3基础上，进一步引入本文所提的超限相关学习权重及调整系数。

M5: 在M1基础上，按不同潮流变量类型进行标准化预处理，标准差选为同类型潮流变量标准差的均值。

M6: 直流潮流模型。

为避免超参数不同带来的影响，在进行对比时，不同方法均采用相同的超参数设置。对于IEEE 39节点系统，DNN模型共有4层隐藏层，每层有350个神经元；对于IEEE 118节点系统，DNN模型共有4层隐藏层，每层有500个神经元。各算例训练集样本数均为80 000，验证集和测试集样本数量均为10 000，迭代次数为1 000；初始学习率设置为0.001，每轮迭代以95%衰减直至0.000 01。

本文使用如下指标来对比不同方法的训练精度。电压幅值、电压相角、支路有功和无功功率的绝对误差超过阈值的比例分别表示为 $P_V$ 、 $P_\theta$ 、 $P_P$ 和 $P_Q$ ，其具体设置见表1。本文算例均在AMD Ryzen 5 3600X 3.8 GHz 6核CPU，32 GB RAM硬件环境下完成。

### 4.2 算例验证及分析

#### 4.2.1 不同潮流变量学习精度对比


本节将验证所提训练方法在改善部分潮流变量存在异常误差问题方面的有效性。不同方法下各潮流变量的最大统计误差如表2所示。由表2可见，方法M1中电压幅值和支路有功功率的最大统计误差存在异常，难以满足计算需求。而所提方法M3、M4可显著提升各潮流变量中的最大统计误差。相较于M3，M4通过误差均衡策略，以略微牺牲原本误差较小潮流变量（电压相角和支路无功功率）的学习精度为代价，进一步降低了电压幅值和支路有功功率的最大统计误差。而M2、M5在支路有功功率上各潮流变量的最大统计误差存在明显的激增。

为进一步说明所提方法的有效性，图4展示了方法M1至M5在测试集上电压幅值和支路有功功率的统计误差。由图4可知，M3、M4相较于M1在误差异常潮流变量处的精度均存在不同程度提升。其中，支路27有功功率的统计误差由20.90%（M1）分别降低至6.81%（M3）和1.27%（M4）。M2、M5相较于M1而言，其在绝大部分潮流变量上的精度都有不同程度下降，甚至在支路有功功率上产生了新的异常误差，其中M2的最大统计误差高达94.93%。


经由分析发现，M5对同一类型潮流变量选取相同的标准差，虽然可保证标准化前后各潮流变量的误差相对大小关系不变，但其也使得标准差更大的潮流变量在标准化后数值相对更大，而标准差更

表2 不同方法下各变量最大统计误差  
Table 2 Maximum statistical error of variables with different methods

方法	IEEE 39节点系统				IEEE 118节点系统				Polish 2383节点系统			
	$P_V/\%$	$P_\theta/\%$	$P_P/\%$	$P_Q/\%$	$P_V/\%$	$P_\theta/\%$	$P_P/\%$	$P_Q/\%$	$P_V/\%$	$P_\theta/\%$	$P_P/\%$	$P_Q/\%$
M1	9.23	1.07	20.90	0.83	5.65	1.48	14.44	2.92	18.94	15.43	52.00	7.71
M2	6.24	0.37	94.93	77.78	11.47	1.15	22.60	9.94				
M3	2.92	0.26	6.86	0.39	5.12	1.36	6.57	1.65	7.85	6.75	5.57	1.55
M4	1.49	0.11	6.81	0.65	3.19	1.41	6.56	1.68	6.43	1.57	4.24	1.81
M5	1.62	0.34	30.11	0.83	13.10	2.00	14.83	1.10				



(a) 电压幅值统计误差曲线



(b) 有功功率统计误差曲线

图4 不同方法在电压幅值和支路有功功率上的统计误差  
Fig. 4 Statistical error of different methods on voltage amplitude and active power of branch

大并不能代表其真实学习误差越大。因此, M5等价于以标准差的相对大小引导DNN学习,其结果同M2相似,均无法保证DNN的训练效果。

#### 4.2.2 DNN模型整体性能对比

本节将进一步验证所提方法在提升DNN模型整体性能方面的有效性。不同方法下的DNN模型整体测试误差如表3所示。由表3可知,相较于M1而言,所提方法M3、M4可有效提升各类型潮流变

量的学习精度。其中, IEEE 39节点系统中支路有功功率的误差评价指标由3.69%(M1)分别降低至1.97%(M3)和1.42%(M4)。而M2、M5在部分潮流变量整体精度上相较于M1也存在明显下降。

不同方法训练集电压幅值和支路有功功率的均方误差曲线见图5。其中,为使损失函数的变化情况更易观测,对曲线进行了截断。由图5可见,方法M2由于无法准确追踪各潮流变量误差的相对变化情况,相较于M1在误差下降速度和最终均方误差值上未有优势,且在部分算例中还出现训练误差上升的情况,由于早停法作用提前终止了训练(如图5(b)所示); M3、M4相较M1而言具有更快的误差下降速度,且在训练终止时,具有更低的均方误差值。

综上所述,本文所提方法不仅能够提升DNN模型整体性能,更重要的是还能够有效改善误差异常变量的精度。

#### 4.2.3 所提方法的适用性验证

为验证所提方法在大规模系统的适用性,本节在Polish 2383节点系统的实际算例中进行了仿真测试。本算例考虑 $N-1$ 支路故障, DNN模型共包含3个隐藏层,每层有1500个神经元,不同方法下各潮流变量最大统计误差及DNN模型误差分别如表2和表3所示,其中上节仿真已验证M2、M5的局限性,此处不再比较。仿真表明本文所提方法在实际规模的测试系统中具有较好适用性。

为验证超参数寻优对异常误差及所提方法有效性的影响,本算例将贝叶斯优化方法<sup>[23]</sup>搜索最佳超参数后训练所得模型与经验设置训练所得模型进行

表3 不同方法下DNN模型误差  
Table 3 Error of DNN with different methods

方法	IEEE 39节点系统				IEEE 118节点系统				Polish 2383节点系统			
	$P_V/\%$	$P_\theta/\%$	$P_P/\%$	$P_Q/\%$	$P_V/\%$	$P_\theta/\%$	$P_P/\%$	$P_Q/\%$	$P_V/\%$	$P_\theta/\%$	$P_P/\%$	$P_Q/\%$
M1	2.10	0.08	3.69	0.11	1.98	0.61	1.33	0.07	1.87	0.43	2.49	0.14
M2	6.98	0.05	11.59	1.84	2.20	0.46	1.26	0.08				
M3	1.41	0.04	1.97	0.07	1.30	0.50	0.79	0.06	1.33	0.32	1.53	0.10
M4	1.00	0.03	1.41	0.09	1.06	0.54	0.79	0.07	1.25	0.35	1.42	0.12
M5	3.83	0.10	8.68	0.18	2.98	0.68	1.75	0.06				



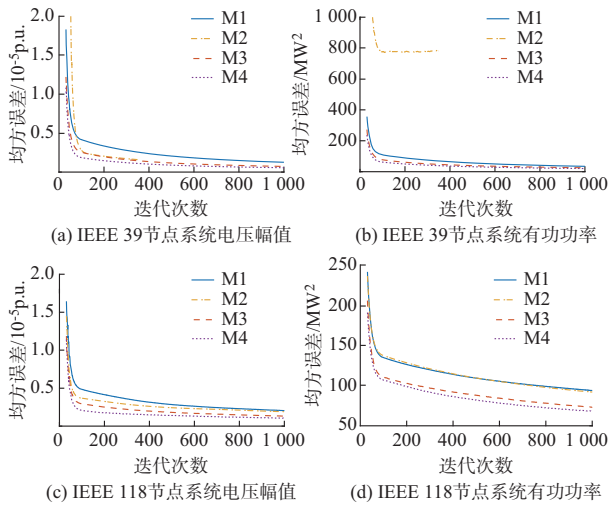


图5 均方误差曲线  
Fig. 5 Curves of mean squared error

对比测试。图6展示了测试集上支路有功功率的统计误差。由图6可知,通过合理的超参数设置能够提升训练效果,但其最大统计误差仍较高。而本文所提方法在不同超参数下都可降低潮流变量的最大统计误差,有效改善了误差异常的问题。




图6 支路有功功率统计误差  
Fig. 6 Statistical error of active power of branches

#### 4.2.4 考虑不确定性的N-1安全校核性能对比

本节将验证所提方法在工业界的实用价值。为应对日益增长的不确定性对电力系统运行的影响,电力系统N-1安全校核除了考虑线路故障场景外,还需要考虑新能源出力等不确定性的影响,将导致安全校核的计算量激增<sup>[24]</sup>。本节将以 Polish 2383节点系统为例,验证所提方法在N-1安全校核场景中的有效性。本算例考虑8个风电场、光伏电站等新能源场站,每个场站考虑2个不确定性场景,则需计算741 376个待校核样本。表4展示了不同方法下支路有功功率安全校核误差及计算时间。

如表4所示,M0、M6均需依次计算所有待校核样本,其计算时间达小时级。相比之下,基于DNN潮流模型的M1、M3、M4在安全校核计算速度上存在大幅提升,且具有较高安全校核精度。本文所提

表4 安全校核误差及计算时间  
Table 4 Safety check error and calculation time

方法	越限漏判率/%	计算时间/s
M0		65 682.9
M1	0.25	315.4
M3	0.04	315.1
M4	0.01	318.6
M6	1.40	7 743.7

方法M3、M4相较于M1可有效改善潮流变量误差异常的情况,从而可进一步提升校核精度。由于DNN模型仍存在计算误差,故其不可避免存在较小的误差,但通过采用松弛越限阈值筛选出更多样本的方法<sup>[25]</sup>,可进一步提升校核精度。

## 5 结语

近年来,基于DNN的数据驱动潮流计算方法得到广泛关注。然而,在现有DNN训练方法下,即使模型整体精度已达标,但仍有部分潮流变量存在异常误差。对此,本文基于DNN梯度更新理论及数据标准化原理,对上述问题的成因进行了理论推导分析。为改善该问题,本文面向潮流计算进一步提出了基于动态学习权重的DNN自适应训练方法。该方法通过在DNN训练过程中嵌入可反映潮流变量真实学习效果的学习权重,指导DNN重点学习误差异常的潮流变量。仿真结果表明,所提方法可有效提升误差异常潮流变量的学习精度以及DNN模型的整体性能,并有助于提升潮流越限判别精度及计算时间。为实现快速准确的大规模潮流重复求解提供了技术支撑。

本文所做的异常误差原因分析关注于数据处理对训练过程造成的影响,而数据特性及模型结构差异等其他因素的影响机理还有待进一步研究。

## 参考文献

[1] 杨耿杰,郭谋发.电力系统分析[M].2版.北京:中国电力出版社,2013.  
YANG Gengjie, GUO Moufa. Power system analysis[M]. 2nd ed. Beijing: China Electric Power Press, 2013.

[2] 汪洋,夏清,康重庆.考虑电网N-1闭环安全校核的最优安全发电计划[J].中国电机工程学报,2011,31(10):39-45.  
WANG Yang, XIA Qing, KANG Chongqing. Optimal security constrained generation scheduling considering closed-loop N-1 security correction[J]. Proceedings of the CSEE, 2011, 31(10): 39-45.

[3] 苏晨博,刘崇茹,李至峪,等.基于贝叶斯理论的考虑多维风速之间相关性的概率潮流计算[J].电力系统自动化,2021,45(3): 157-165.  
SU Chenbo, LIU Chongru, LI Zhiyu, et al. Bayesian theory

- based calculation of probabilistic power flow considering correlation between multi-dimensional wind speed [J]. Automation of Electric Power Systems, 2021, 45(3): 157-165.
- [4] 孙树明,谢昶,吕颖,等. 电力系统在线安全稳定分析应用模式[J]. 电网技术, 2015, 39(10): 2875-2881.  
SUN Shuming, XIE Chang, LÜ Ying, et al. Power system online security and stability analysis application modes[J]. Power System Technology, 2015, 39(10): 2875-2881.
- [5] 郭健,周京阳,李强,等. 高性能在线分析计算现状与协同计算关键技术[J]. 电力系统自动化, 2018, 42(3): 149-159.  
GUO Jian, ZHOU Jingyang, LI Qiang, et al. Current status of high-performance on-line analysis computation and key technologies for cooperating computation [J]. Automation of Electric Power Systems, 2018, 42(3): 149-159.
- [6] 唐灿,董树锋,任雪桂,等. 用于迭代法潮流计算的改进 Jacobi 预处理方法[J]. 电力系统自动化, 2018, 42(12): 81-86.  
TANG Can, DONG Shufeng, REN Xuegui, et al. Improved Jacobi pre-treatment method for solving iterative power flow calculation[J]. Automation of Electric Power Systems, 2018, 42(12): 81-86.
- [7] STOTT B, JARDIM J, ALSAC O. DC power flow revisited [J]. IEEE Transactions on Power Systems, 2009, 24(3): 1290-1300.
- [8] 卫志农,张青松,赵静波,等. 电力系统线性化模型研究综述与改进[J]. 电网技术, 2017, 41(9): 2919-2927.  
WEI Zhinong, ZHANG Qingsong, ZHAO Jingbo, et al. Review and improvement of power system linearization models [J]. Power System Technology, 2017, 41(9): 2919-2927.
- [9] 樊哲新,杨知方,冯楠,等. 潮流方程线性化误差分析及最优状态空间选取[J]. 电力系统自动化, 2020, 44(1): 109-117.  
FAN Zhixin, YANG Zhifang, FENG Nan, et al. Error analysis and optimal state space selection of linear power flow equation [J]. Automation of Electric Power Systems, 2020, 44(1): 109-117.
- [10] IMEN L, DJAMEL L. Power flow variation based on extreme learning machine algorithm in power system [J]. International Journal of Power Electronics and Drive Systems (IJPEDS), 2019, 10(3): 1244.
- [11] MA L X, ZHANG X J. Study on high capability intelligent algorithm in load flow of power system [C]// 2008 International Conference on Neural Networks and Signal Processing, June 7-11, 2008, Nanjing, China.
- [12] BAGHAE H R, MIRSALEM M, B GHAREHPETIAN G. Power calculation using RBF neural networks to improve power sharing of hierarchical control scheme in multi-DER microgrids [J]. IEEE Journal of Emerging and Selected Topics in Power Electronics, 2016, 4(4): 1217-1225.
- [13] YANG Y, YANG Z F, YU J, et al. Fast calculation of probabilistic power flow: a model-based deep learning approach [J]. IEEE Transactions on Smart Grid, 2020, 11(3): 2235-2244.
- [14] WANG L, ZHOU Q, JIN S S. Physics-guided deep learning for power system state estimation [J]. Journal of Modern Power Systems and Clean Energy, 2020, 8(4): 607-615.
- [15] 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.
- [16] PAN S J, YANG Q. A survey on transfer learning [J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(10): 1345-1359.
- [17] YANN L, LEON B, GENEVIEVE B O, et al. Neural networks: tricks of the trade [M]. Berlin, Germany: Heidelberg: Springer, 1998.
- [18] AL-FAIZ M Z, IBRAHIM A A, HADI S M. The effect of z-score standardization (normalization) on binary input due the speed of learning in back-propagation neural network [J]. Iraqi Journal of Information & Communications Technology, 2019, 1(3): 42-48.
- [19] RUDER S. An overview of gradient descent optimization algorithms [EB/OL]. [2021-05-10]. <http://sebastianruder.com/optimizing-gradient-descent>.
- [20] RASKUTTI G, WAINWRIGHT M J, YU B. Early stopping for non-parametric regression: an optimal data-dependent stopping rule [C]// 2011 49th Annual Allerton Conference on Communication, Control, and Computing (Allerton), September 28-30, 2011, Monticello, USA.
- [21] LI Y M, LI W Y, YAN W, et al. Probabilistic optimal power flow considering correlations of wind speeds following different distributions [J]. IEEE Transactions on Power Systems, 2014, 29(4): 1847-1854.
- [22] SARKAR S, AJJARAPU V. MW resource assessment model for a hybrid energy conversion system with wind and solar resources [J]. IEEE Transactions on Sustainable Energy, 2011, 2(4): 383-391.
- [23] SNOEK J, LAROCHELLE H, ADAMS R P. Practical Bayesian optimization of machine learning algorithms [EB/OL]. [2021-05-01]. <https://arxiv.org/pdf/1206.2944.pdf>.
- [24] DU Y, LI F X, LI J, et al. Achieving 100x acceleration for  $N-1$  contingency screening with uncertain scenarios using deep convolutional neural network [J]. IEEE Transactions on Power Systems, 2019, 34(4): 3303-3305.
- [25] 李峰,李虎成,於益军,等. 基于并行计算和数据复用的快速静态安全校核技术[J]. 电力系统自动化, 2013, 37(14): 75-80.  
LI Feng, LI Hucheng, YU Yijun, et al. Fast computing technologies for static security checking based on parallel computation and data reuse [J]. Automation of Electric Power Systems, 2013, 37(14): 75-80.

雷江龙(1995—),男,硕士研究生,主要研究方向:电力系统分析、深度学习。E-mail:543306156@qq.com

余娟(1980—),女,通信作者,博士,教授,主要研究方向:电力与能源经济优化运行、风险评估、深度学习。E-mail:148454745@qq.com

向明旭(1994—),男,博士研究生,主要研究方向:电力系统运行优化与分析、深度学习。E-mail:467972447@qq.com

(编辑 鲁尔姣)



## Improvement Strategy for Abnormal Error of Data-driven Power Flow Calculation Based on Deep Neural Network

LEI Jianglong, YU Juan, XIANG Mingxu, YANG Zhifang, YANG Yan, LI Wenyuan

(State Key Laboratory of Power Transmission Equipment & System Security and New Technology  
(Chongqing University), Chongqing 400044, China)

**Abstract:** In the scenarios requiring large-scale repetitive power flow calculations, such as  $N-1$  safety checks and reliability calculations considering uncertainty, the data-driven method based on deep neural network (DNN) has the abnormal error problem of some power flow variables, which affects the accuracy of the over-limit judgment of the power flow. To this end, through the theoretical derivation, the update process of DNN parameters and the principle of data standardization are analyzed. It is found that one of the important causes of this problem is that the DNN only trains the model iteratively based on standardized errors, and does not take into account the true learning error of the power flow variables and the actual accuracy requirements of the project. And it is impossible to adjust the DNN parameters in time for the power flow variables with abnormal errors. Then, a DNN adaptive training method based on dynamic learning weights is proposed for power flow calculation. This method determines the learning weight of each power flow variable through the true learning error, over-limit misjudgment rate and error statistical indicators of the verification set in each iteration, which effectively reduces the abnormal error of the data-driven power flow calculation. Finally, simulations on IEEE standard examples and Polish 2383-node system verify the effectiveness of the proposed method.

This work is supported by National Natural Science Foundation of China (No. 52077016), Natural Science Foundation of Chongqing (No. cstc2020jcyj-msxmX0315) and Fundamental Research Funds for the Central Universities (No. 2020CDJ-LHZZ-079).

**Key words:** data-driven; power flow calculation; deep neural network (DNN); abnormal error analysis; learning weight

