

基于卷积神经网络的 $N-2$ 线路开断潮流快速计算

刘学华¹, 孔霄迪²

(1. 国电南京自动化股份有限公司, 江苏 南京 210032;
2. 南京南瑞继保电气有限公司, 江苏 南京 211102)

摘要:交流潮流(AC)算法需迭代求解,难以满足实际电力系统在线安全校核的需求。文中基于卷积神经网络,提出一种电力系统线路开断潮流的快速计算方法。离线训练阶段,从线路开断前后工况与拓扑的变化中提取特征作为输入信号(原始特征图),经大量算例训练后,卷积神经网络构建了原始特征图与线路开断后潮流结果的非线性映射关系。在线应用时,直接生成原始特征图,并基于离线训练的卷积神经网络计算测试集的潮流结果。经 4 个 IEEE 典型系统的 $N-2$ 潮流仿真验证,文中方法具有良好的泛化能力。相比传统交流算法,文中方法将速度提高了接近 80 倍;相比传统人工神经网络模型,文中方法将精度提高近了 1 个数量级。

关键词:卷积神经网络; $N-2$ 潮流计算; 计算提速; 原始特征图; 人工智能

中图分类号:TM711;TM744

文献标志码:A

文章编号:2096-3203(2021)04-0095-06

0 引言

近年来,世界范围内发生了多起大停电事故,引起重大的社会经济损失^[1-2],2003 年满足“ $N-1$ 准则”的意大利全网在多个元件相继开断后发生大停电^[3]。为此,我国于 2019 年更新了电力系统安全稳定导则,在静态安全分析的“ $N-1$ 准则”基础上增补了“ $N-2$ 准则”的内涵^[4]。目前,在满足“ $N-1$ 准则”的基础上,部分经济发达地区已经实现了 $N-2$ 校核。然而,随着电网的大规模互联、新能源设备与不确定负荷的大量接入, $N-2$ 场景数呈爆炸式增长,传统的交流潮流(alternating current, AC)算法难以满足实际工程的在线潮流计算的需求,其中线路开断尤为突出,为此,有必要研究 $N-2$ 开断潮流的快速计算方法,当前研究主要分为 3 类。

其一,并行计算技术在潮流方程的应用包括直接法与迭代法^[5]。直接法基于矩阵分解与求逆,不存在收敛问题,但并行化程度较低,通信开支较大,难以应用于大规模系统。迭代法并行化简单,通信开支小,但收敛速度慢,且迭代次数随处理器数目增长而增加^[6]。

其二,为减少潮流计算量,有研究对 AC 算法进行简化,部分计及甚至完全忽略潮流方程的非线性。经典的直流潮流(direct current, DC)算法将非线性潮流方程转化为有功与相角的线性方程求解。然而,DC 算法的计算误差通常较大,分析精度尚不足以实现大系统的工程分析,且无法提供电压与无功信息^[7-8]。

收稿日期:2021-02-01;修回日期:2021-04-21

其三,大量基于人工智能(artificial intelligence, AI)的分类学习技术已应用于电力系统静态安全评估,包括支持向量机、人工神经网络(artificial neural network, ANN)、C4.5 等^[9-10]。基于大量训练的静态安全 AI 评估分类准确性高,但研究结果缺乏潮流数据,无法据此配置安全控制措施。对此,前馈神经网络、径向基函数等方法被应用于快速潮流计算^[11-12],然而其成果局限于新英格兰系统,在大系统的强壮性有待校核,相对传统 AC 算法其速度优势并不显著。近两年,卷积神经网络(convolutional neural network, CNN)已被应用于 $N-1$ 故障潮流计算^[13],相比传统 AC 算法,基于 CNN 的潮流计算速度显著提升,但关于 $N-2$ 开断的研究依然是空白。

文中基于系统拓扑与工况变化设计原始特征图,应用 CNN 求解全网潮流,避免了 AC 算法复杂的非线性代数方程组求解,实现了约 80 倍的计算速度提升。相比传统 ANN,CNN 显著减少训练参数,缓解过拟合问题,将计算精度提高了近 1 个数量级。

1 CNN 原理

CNN 是一种数据处理的深度学习模型,能由低至高自适应地学习特征的层次结构,常用于处理具有网格属性的数据,譬如图像、语音等^[14-15]。该模型包括卷积层、池化层与全连接层,结构如图 1 所示。其中,实线箭头描述了 CNN 的训练与应用过程,虚线箭头指向的损失函数计算仅在 CNN 的训练阶段,用于优化网络参数。卷积层与池化层通常用于进一步从原始特征图中提取信息;全连接层建立特征与目标信息的映射关系并预测输出。

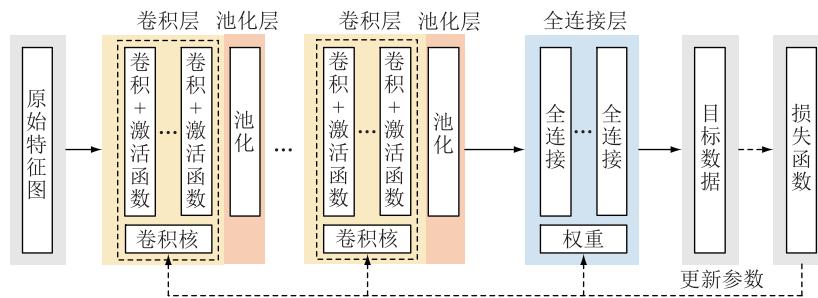


图 1 CNN 结构
Fig.1 Structure of CNN

卷积层利用卷积核进一步提取输入数据的特征,这是 CNN 区别于其他神经网络的关键。相比传统 ANN,卷积计算的引入使 CNN 具有权值共享与连接稀疏两大特性^[16-17]。相比传统的全连接方式,卷积计算显著减少了训练参数,降低了离线训练的计算量,有效缓解了过拟合问题,提高了神经网络的泛化能力。

卷积层的存在使得原始特征图中数据之间可以分组聚合,以电力系统潮流计算为例,传统 ANN 方法将全部节点信息混合输入,无法实现信息与节点的关联;CNN 方法能够按节点对原始特征图求卷积,通过权值共享与稀疏连接避免了大量无关参数参与训练带来的过拟合问题。

2 基于 CNN 的故障潮流计算

对于 n 节点系统,其任意节点 i 的潮流方程如式(1)所示。

$$\begin{cases} P_i - V_i \sum_{j=1}^n V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) = 0 \\ Q_i - V_i \sum_{j=1}^n V_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}) = 0 \end{cases} \quad (1)$$

式中: V_i, θ_i 分别为节点 i 的电压幅值与相角; P_i, Q_i 分别为节点 i 的注入有功与无功功率; G_{ii}, B_{ii} 分别为节点 i 的自电导与自电纳。当 i 与 j 不等时, G_{ij}, B_{ij} 分别为节点 i 与节点 j 的互电导与互电纳。式(1)求解的电压幅值与相角即文中所指潮流结果,支路潮流可据电压幅值与相角进一步求解。

基于 CNN 的线路开断潮流计算包含离线训练与在线应用 2 个阶段,如图 2 所示。

在线应用时,对测试集中的具体算例输入原始特征图,根据离线训练的 CNN 模型,计算故障潮流。离线训练阶段主要包括以下 4 个模块:

(1) 采集故障与工况信息。针对训练样本算例,采集信息包括初始拓扑的网络参数(电导与电纳)、被开断支路编号、发电机出力与负载。此外,还需基于离线仿真(一般采用 AC 算法)计算故障后

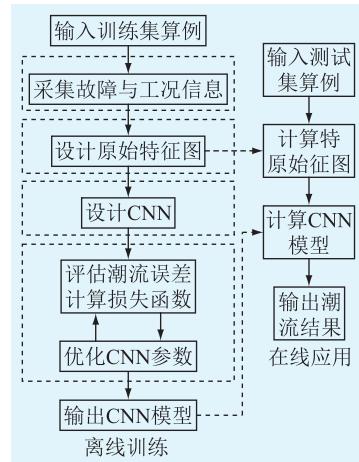


图 2 基于 CNN 的故障潮流计算流程
Fig.2 Flow chart of post-contingency load flow calculation based on CNN

潮流电压幅值 V_{AC} 与相角 θ_{AC} ,以评估基于 CNN 的潮流结果误差,计算损失函数。

(2) 设计原始特征图。不同于传统 ANN 方法,CNN 通常以图像类数据为输入信息。采集故障与工况信息后,可将各节点信息构成一张原始特征图,设计过程详见第 3 章。

(3) 设计 CNN。CNN 包括卷积层、池化层与全连接层。考虑到式(1)中潮流结果与各节点属性强相关且文中特征图的计算量较小,不再采用池化层进一步缩减特征图信息。综上,文中 CNN 的设计涉及卷积层(卷积核尺寸、个数,卷积层数)及全连接层(全连接层数)。

(4) 基于损失函数优化 CNN 参数。损失函数用于明确离线训练参数的优化方向。在优化 CNN 网络的卷积核参数与全连接的权重参数时,文中考虑以潮流计算误差最小为训练目标,而潮流计算误差包括电压误差 e_V 与相角误差 e_θ 两方面。记 CNN 的故障潮流计算电压幅值、相角分别为 V_{CNN} 与 θ_{CNN} ,以模块(1)中离线仿真 AC 算法的电压幅值、电压相角结果 V_{AC} 与 θ_{AC} 为参考,分别按式(2)与式(3)定义 e_V 与 e_θ :

$$e_V = \frac{1}{n} \sum_{i=1}^n |V_{\text{CNN},i} - V_{\text{AC},i}| \quad (2)$$

$$e_\theta = \frac{1}{n} \sum_{i=1}^n |\theta_{\text{CNN},i} - \theta_{\text{AC},i}| \quad (3)$$

基于 e_V 与 e_θ 描述损失函数,如式(4)所示。

$$L = \sqrt{\alpha_V e_V^2 + \alpha_\theta e_\theta^2} \quad (4)$$

式中: α_V, α_θ 分别为电压误差与相角误差的惩罚因子,默认取 1。在迭代周期内,根据最小损失函数对应的 CNN 参数输出离线训练的 CNN 模型。

3 原始特征图的设计

电力系统潮流计算中,每一节点均具有其对应的拓扑或工况属性,且属性数目常大于 1。传统神经网络以向量为输入信号,丢失了节点与属性的对应关系,而在 CNN 的计算中,原始特征图保留了这种对应关系,且图中的节点属性可采用通道描述。结合卷积本身具有权值共享与连接稀疏的特点,基于 CNN 的潮流计算结果往往相对 ANN 精度较高且泛化性能较好。

为了控制计算规模,文中设计了 3 通道的原始特征图,考虑到各算例的基本相同,取故障前后节点参数的变化量为各通道属性。由式(1)可知,节点电压和相角(V_i, θ_i)仅与注入功率(P_i, Q_i)和导纳(G_{ij}, B_{ij})有关。考虑到在交流高压电网中,输电线路的电抗要比电阻大得多,电导远小于电纳,文中忽略电纳矩阵中非主对角元与电导矩阵的影响,将 n 个节点的自电纳变化量构成 $n \times 1$ 阶向量作为通道 1 输入,记为 ΔB ,该通道特征描述拓扑结构对潮流结果的影响。另外,将 n 个节点的注入有功功率的变化量形成 $n \times 1$ 阶向量,记为 ΔP ;注入无功功率的变化量形成 $n \times 1$ 阶向量,记为 ΔQ ,分别作为特征图通道 2 与通道 3 输入 CNN。相应地,将 $n \times 1$ 阶节点电压幅值向量 V 与 $n \times 1$ 阶节点电压相角向量 θ 作为输出信号。

为进一步提高 CNN 的训练效果,采用 min-max

标准化方法对原始特征图中信息进行归一化处理,将其线性映射到 [0,1] 之间,如式(5)所示。

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (5)$$

式中: x^* 为归一化后的特征数值; x 为原始特征数值; x_{\min}, x_{\max} 分别为特征最小、最大值。

上述原始特征图的数据量是节点数的 3 倍,给卷积神经网络带来的训练负担小,对大规模系统的潮流计算具有实用性。

4 CNN 的设计

文中 CNN 由 2 个卷积层与 1 个全连接层构成,如图 3 所示。

4.1 卷积层

基于第 3 章的原始特征图,文中采用 2 个卷积层从原始特征图中进一步提取信息。每个卷积层由多个卷积核构成。对每一层而言,卷积核越多,其特征图越多,更多信息被挖掘,同时计算量也越大。对卷积层 1,取尺寸为 $3 \times 3 \times 1 \times 6$ 的卷积核;对卷积层 2,取 $3 \times 3 \times 6 \times 12$ 的卷积核。其中,卷积核 4 个参数分别为长、宽、深度与个数。此外,采用零填充以保证输入特征图的高度与宽度。

记 H_k 为 CNN 任一层的特征图,文中 k 取 0,1,2,3。特殊地,当 k 取 0 时, H_0 为原始特征图,即第 3 章设计的特征图。对于每一层特征图,其上一层特征图经卷积运算后,采用非线性函数(称为激活函数)计算本层特征图。 H_k 的卷积运算如式(6)所示^[18]。

$$H_k = h(H_{k-1} \otimes W_k + b_k) \quad (6)$$

式中: W_k 为第 k 层卷积核的权值矩阵; \otimes 为卷积运算符; b_k 为第 k 层的偏置向量; h 为激活函数。主流函数包括 Sigmoid、tanh 与 ReLU 等,考虑到 ReLU 函数在加速权值梯度下降收敛与计算量上的优势,文中取 ReLU 为激活函数,其定义如式(7)所示。

$$h(x) = \begin{cases} 0 & x \leq 0 \\ x & x > 0 \end{cases} \quad (7)$$

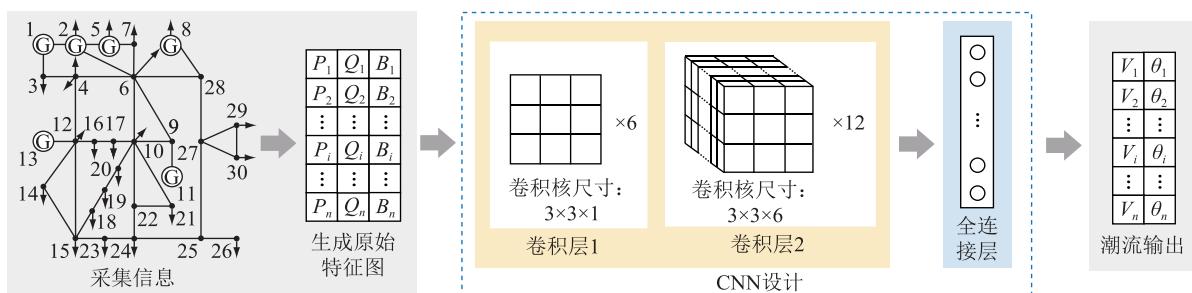


图 3 CNN 的设计示意
Fig.3 Schematic diagram of design of CNN

4.2 全连接层

全连接层本质为矩阵乘法,相当于特征图的空间变换,提取并整合多层卷积的计算结果。另一方面,全连接层可用于维度变换,尤其是对多层卷积后的高维数据降维,并保留其中有效信息。

全连接层按式(8)计算,上一层特征图经加权求和后,通过激活函数得到输出结果。

$$\mathbf{H}_k = h(\mathbf{H}_{k-1}\mathbf{w}_k + \mathbf{b}_k) \quad (8)$$

式中: \mathbf{w}_k 为第 k 层权值向量; \mathbf{H}_k 为输出的潮流结果。此处, h 仍取ReLU函数。

5 算例分析

文中基于Matlab仿真平台,在IEEE 30, IEEE 39, IEEE 57, IEEE 118四个标准系统中对比验证了文中方法的有效性,标准系统数据可参考MATPOWER手册^[19]。为保证样本的随机性,采用蒙特卡洛法抽取N-2故障样本,以保证每个样本中有任意2条支路退出运行。此外,样本算例中负荷与发电机出力的随机性也通过蒙特卡洛抽样实现。其中,各负荷变化范围为标准工况的50%~150%,各机组出力变化范围为标准工况的80%~120%。

5.1 评估指标

5.1.1 精度评估指标

为便于直接与传统ANN的潮流结果对比,文中以AC算法的电压幅值与相角结果为基准值,使用算例集各节点电压与相角的平均误差评估开断潮流的分析精度。对于含 N 个样本的算例集,分别按式(9)与式(10)定义平均电压误差 E_V 与相角误差 E_θ ,二者数值越小,潮流结果精度越高。

$$E_V = \frac{1}{N} \sum_1^N e_V \quad (9)$$

$$E_\theta = \frac{1}{N} \sum_1^N e_\theta \quad (10)$$

5.1.2 速度评估指标

(1) 计算时间。以秒为单位,考核方法的总计算时间 T 。 T 越小,潮流计算速度越快。

(2) 加速比。以AC算法的总计算时间 T_{AC} 为参考,定义加速比 R ,如式(11)所示。 R 越大,潮流计算相对AC算法的速度优势越明显。

$$R = \frac{T_{AC}}{T} \quad (11)$$

5.2 精度分析

5.2.1 训练样本占比的影响

训练样本占总样本的比例会影响CNN的强壮性,与测试集的平均误差直接相关。记 N 个算例中

训练样本数为 N_{train} ,定义训练样本数占比 σ 为:

$$\sigma = \frac{N_{train}}{N} \times 100\% \quad (12)$$

随机抽取IEEE 30节点系统10 000个N-2算例,设置不同 σ 分别训练CNN,统计训练集与测试集的潮流误差,如表1所示。

表1 不同 σ 下的潮流误差

Table 1 Load flow error with different σ

$\sigma/\%$	训练集		测试集	
	$E_V \times 10^{-3}/$ p.u.	$E_\theta \times 10^{-3}/$ rad	$E_V \times 10^{-3}/$ p.u.	$E_\theta \times 10^{-3}/$ rad
20	0.88	4.60	1.04	5.51
40	0.68	4.19	0.74	4.58
60	0.56	4.16	0.63	4.40
80	0.56	3.79	0.60	4.14

随着 σ 上升,训练集与测试集中的 E_V 与 E_θ 均不断减小,测试集与训练集的计算精度愈加相近。理论上,训练集数量趋于无限时,误差可接近0。然而,将所有N-2故障算例纳入训练集既不可行,也没有意义。考虑到表1中 σ 取60%与80%时,测试集与训练集的结果已非常接近,故余下仿真中 σ 取75%。

5.2.2 训练时长的影响

CNN的充分训练能够构建原始特征图到潮流结果的非线性映射,然而,单次训练基于线性方程求解,实际训练常以多次反复迭代的形式来拟合。一般而言,随着迭代次数增加,相应的训练时间延长,CNN的分析精度提高。当迭代次数增大到一定程度时,训练时长对CNN性能的提升效果反而下降,极端情况下甚至可能出现“过拟合”。以5.2.1节中开断计算场景为例,设置 $\sigma=75\%$,以IEEE 30节点系统为例,取迭代次数1~5 000(单次迭代的训练时间约3.8 s)训练CNN。训练时长对测试集分析精度的影响如表2所示。

表2 不同训练时间下的潮流误差

Table 2 Load flow error under different training time

迭代次数	$E_V \times 10^{-3}/$ p.u.	$E_\theta \times 10^{-3}/$ rad
1	18.00	4.26
10	8.91	2.48
100	6.71	0.82
1 000	4.02	0.61
5 000	4.08	0.63

由表2可见,随着迭代次数从1增加到100,测试集的相角与电压误差几乎降低80%;将迭代次数进一步增加到1 000,误差仅下降30%;继续增加迭

代次数到 5 000,误差反而略有增大,可能出现“过拟合”。为此,文中算例的训练过程统一采用 500 次迭代。

5.2.3 不同系统的影响

为校核文中方法在不同系统中的鲁棒性,在 IEEE 30,IEEE 39,IEEE 57,IEEE 118 节点系统中各取 5 000 个算例,以 75% 算例为训练集,余下为测试集。选择经典的 ANN 方法为比较对象,设置其网络宽度为 10,深度为 1,其输入信号、训练集、测试集均与文中 CNN 方法相同。

表 3 对比了 CNN 与 ANN 在不同系统中开断潮流的分析精度。相比 ANN 方法,文中设计的 CNN 分析框架使电压误差至少降低为原误差的三分之一,相角误差降低近 1 个数量级。且在不同系统中,文中方法将电压平均误差控制在 0.01 内,相角误差控制在 0.03 内,具有鲁棒性。

表 3 不同系统中的潮流精度

Table 3 Load flow accuracy in different systems

系统	文中方法		ANN 方法	
	$E_V \times 10^{-3}$ /p.u.	$E_\theta \times 10^{-3}$ /rad	$E_V \times 10^{-3}$ /p.u.	$E_\theta \times 10^{-3}$ /rad
IEEE 30 节点	0.61	4.02	4.59	80.98
IEEE 39 节点	9.01	29.19	22.35	352.21
IEEE 57 节点	7.96	16.67	31.85	139.94
IEEE 118 节点	9.35	26.32	35.64	258.95

5.3 速度分析

表 4 对比了文中方法与 AC 算法在 5.2.3 节中测试集的计算速度。相比传统 AC 算法,文中方法将 1 500 个算例的计算时间控制在 0.5 s 以内,可满足实际系统的在线分析需求。相比传统 AC 算法,文中方法在 4 个典型系统中使速度提高约 80 倍,且加速比随系统规模增大而增大。因此,系统规模越大,文中方法的提速效果越明显。

表 4 不同系统中的潮流速度

Table 4 Load flow speed in different systems

系统	T/s		R
	文中方法	AC 算法	
IEEE 30 节点	0.26	20.35	78
IEEE 39 节点	0.26	20.57	79
IEEE 57 节点	0.31	24.80	80
IEEE 118 节点	0.49	39.94	82

值得一提的是,AC 算法在 IEEE 典型系统中的迭代一般不超过 10 次,而在实际大系统中的潮流迭代一般超过 10 次。随系统规模的扩大,AC 算法计算量显著增长,文中方法的速度优势越显著。

6 结语

针对现有潮流计算方法难以实现 N-2 线路开断故障在线计算的问题,文中基于 CNN 提出了一种电力系统开断潮流的快速计算方法。文中方法以故障前后工况与拓扑的变化信息构建原始特征图,设计卷积神经网络建立原始特征图与故障后节点电压、相角的非线性的映射关系。相对经典的 AC 算法,CNN 方法避免了复杂模型的反复迭代求解,使潮流计算速度提高约 80 倍。相比传统的 ANN 模型,CNN 方法使电压与相角误差降低约 1 个数量级。另外,多个 IEEE 系统的仿真结果验证了 CNN 方法的强壮性。

AI 方法引入电力系统静态安全分析已经二十余载,至今仍有一些问题亟待解决,包括训练集与测试集的数量问题;将潮流计算过程与静态安全评估、控制相结合,基于 CNN 进一步实现有功与无功潮流的计算;高阶故障开断潮流的快速可靠计算等。

参考文献:

- [1] 印永华,郭剑波,赵建军,等. 美加“8.14”大停电事故初步分析以及应吸取的教训[J]. 电网技术,2003,27(10):8-11,16.
YIN Yonghua, GUO Jianbo, ZHAO Jianjun, et al. Preliminary analysis of large scale blackout in interconnected North America power grid on August 14 and lessons to be drawn[J]. Power System Technology, 2003, 27 (10) :8-11, 16.
- [2] 黄道姗. 电网薄弱环节分类识别技术研究[J]. 电力工程技术,2017,36(4):91-97.
HUANG Daoshan. Classification and identification of power grid weak links[J]. Electric Power Engineering Technology, 2017, 36(4) :91-97.
- [3] LIU Y, XUE Y S. Cascading outage analyses by integrating distribution factor method with AC power flow[J]. IEEE Access, 2019, 7:180887-180897.
- [4] 电力系统安全稳定导则:GB 38755—2019[S]. 北京:中国标准出版社,2019.
Code on security and stability for power system: GB 38755—2019[S]. Beijing: Standards Press of China, 2019.
- [5] LI X, LI F X, YUAN H Y, et al. GPU-based fast decoupled power flow with preconditioned iterative solver and inexact Newton method[J]. 2017 IEEE Power & Energy Society General Meeting, 2017:1.
- [6] 吉兴全,王成山. 电力系统并行计算方法比较研究[J]. 电网技术,2003,27(4):22-26.
JI Xingquan, WANG Chengshan. A comparative study on parallel processing applied in power system[J]. Power System Technology, 2003, 27 (4) :22-26.
- [7] LU S, ZHOU N, KUMAR N P, et al. Improved DC power flow method based on empirical knowledge of the system[C]//IEEE PES T&D 2010. New Orleans, LA, USA. IEEE, 2010:1-6.

- [8] NAGENDRA RAO P S, PRAKASA RAO K S, NANDA J. An exact fast load flow method including second order terms in rectangular coordinates [J]. IEEE Transactions on Power Apparatus and Systems, 1982, PAS-101(9):3261-3268.
- [9] 朱志慧, 李雷, 种冬梅. 改进的 BT-SVM 应用于电力系统 SSA [J]. 计算机技术与发展, 2012, 22(9):157-160, 165.
ZHU Zhihui, LI Lei, CHONG Dongmei. Improved binary tree support vector machine and its application to power system static security assessment [J]. Computer Technology and Development, 2012, 22(9):157-160, 165.
- [10] SAEH I S, MUSTAFA M W, MOHAMMED Y S, et al. Static security classification and evaluation classifier design in electric power grid with presence of PV power plants using C-4.5 [J]. Renewable and Sustainable Energy Reviews, 2016, 56: 283-290.
- [11] PAUCAR V L, RIDER M J. Artificial neural networks for solving the power flow problem in electric power systems [J]. Electric Power Systems Research, 2002, 62(2):139-144.
- [12] KARAMI A, MOHAMMADI M S. Radial basis function neural network for power system load-flow [J]. International Journal of Electrical Power & Energy Systems, 2008, 30(1):60-66.
- [13] 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.
YANG Yan, YANG Zhifang, YU Juan, et al. Fast analysis of $N-1$ contingency screening with uncertainty scenarios based on deep learning [J]. Proceedings of the CSEE, 2021, 41(8): 2716-2725.
- [14] 黄玉蕾, 罗晓霞, 刘笃仁. MFSC 系数特征局部有限权重共享 CNN 语音识别 [J]. 控制工程, 2017, 24(7):1507-1513.
- HUANG Yulei, LUO Xiaoxia, LIU Duren. Local finite weight sharing of MFSC coefficients based CNN speech recognition [J]. Control Engineering of China, 2017, 24(7):1507-1513.
- [15] 曲景影, 孙显, 高鑫. 基于 CNN 模型的高分辨率遥感图像目标识别 [J]. 国外电子测量技术, 2016, 35(8):45-50.
QU Jingying, SUN Xian, GAO Xin. Remote sensing image target recognition based on CNN [J]. Foreign Electronic Measurement Technology, 2016, 35(8):45-50.
- [16] GARLAND J, GREGG D. Low complexity multiply accumulate unit for weight-sharing convolutional neural networks [J]. IEEE Computer Architecture Letters, 2017, 16(2):132-135.
- [17] ZHANG S Z, WANG J J, TAO X Y, et al. Constructing deep sparse coding network for image classification [J]. Pattern Recognition, 2017, 64:130-140.
- [18] 李彦冬, 郝宗波, 雷航. 卷积神经网络研究综述 [J]. 计算机应用, 2016, 36(9):2508-2515, 2565.
LI Yandong, HAO Zongbo, LEI Hang. Survey of convolutional neural network [J]. Journal of Computer Applications, 2016, 36(9):2508-2515, 2565.
- [19] ZIMMERMAN R D, MURILLO-SANCHEZ C E. Matpower user's manual version 7.0 [EB/OL]. [2021-05-30]. <https://matpower.org/docs/MATPOWER-manual-7.0.pdf>, 2019.

作者简介:



刘学华

刘学华(1966),男,学士,工程师,从事电力系统保护与控制相关工作(E-mail: xuehua-liu@sac-china.com);

孔霄迪(1967),女,学士,高级工程师,从事电力系统保护与控制相关工作。

Fast load flow calculation of $N-2$ contingency based on convolutional neural network

LIU Xuehua¹, KONG Xiaodi²

(1. Guodian Nanjing Automation Co., Ltd., Nanjing 210032, China;

2. NR Electric Co., Ltd., Nanjing 211102, China)

Abstract: The AC algorithm solves the power flow equations by iterations, which is computationally infeasible to the online security analysis of power systems. A fast load flow calculation method is proposed based on a convolutional neural network (CNN). As to the offline training stage, the proposed method extracts inputs (initial feature maps) based on the changes in operating conditions and topologies. In abundant training samples, the CNN and maps the nonlinear relationship between the extracted feature maps and the targeted load flow results. When it comes to the online applications, the proposed method directly calculates the feature map and delivers the load flow results based on the CNN trained offline. As is indicated in the $N-2$ load flow simulations of four typical IEEE systems, the generalization capability is guaranteed. Compared with the AC algorithm, the proposed method accelerates the power flow computation by eighty times. The accuracy is enhanced by nearly one order of magnitude, compared with that of the traditional artificial neural network (ANN).

Keywords: convolutional neural network; $N-2$ load flow calculation; calculation acceleration; initial feature maps; artificial intelligence

(编辑 钱悦)