

基于1D-CNN的含DG中压馈线合环电流预测方法

陈世威, 荣娜, 罗勇, 邹文斌

贵州大学电气工程学院, 贵州 贵阳

收稿日期: 2023年7月17日; 录用日期: 2023年9月6日; 发布日期: 2023年9月13日

摘要

“双碳”目标下分布式电源(distributed generator, DG)大量接入配电网, 使得传统基于物理建模的合环电流计算方法难以满足工程对计算准确性、适用性的要求。为充分挖掘合环电流输入特征的时空联系, 解决输入特征对合环电流的不稳定影响导致的预测精度下降问题, 提出了一种基于一维卷积(1D-CNN)的含DG配电网合环电流预测方法。首先, 结合实际配电网运行特点分析了合环电流输入特征构建, 提出了两种合环电流预测的输入特征选择; 其次, 基于DIgSILENT/PowerFactory搭建仿真模型形成样本集合; 最后, 分别对两种输入特征进行模型训练, 并对超参数寻优及预测流程等问题进行了分析, 从而建立1D-CNN合环电流预测模型。在贵州某地区实际中压配电系统开展仿真分析, 结果显示该模型在馈线a、b首端及合环处的电流测试集样本 I_a 、 I_b 、 I_c 上的平均绝对误差分别为0.0927%、0.2704%和0.4797%, 表明所提方法能准确且稳定预测合环电流。

关键词

分布式电源, 中压配电网, 合环电流, 特征分析, 1D-CNN, DIgSILENT

Loop Closing Current Prediction Method of Medium Voltage Feeder with DG Based on 1D-CNN

Shiwei Chen, Na Rong, Yong Luo, Wenbin Zou

Department of Electrical Engineering, Guizhou University, Guiyang Guizhou

Received: Jul. 17th, 2023; accepted: Sep. 6th, 2023; published: Sep. 13th, 2023

Abstract

A large number of distributed generators (DG) are connected to the distribution network under

the “dual-carbon” goal, which makes the traditional loop closing current calculation method based on physical modeling difficult to meet the requirements of engineering for calculation accuracy and applicability. In order to fully explore the spatio-temporal relation of input features of the loop closing current and solve the problem of prediction accuracy decline caused by the unstable influence of input features on the loop closing current, a method for predicting the loop closing current of distribution network with DG based on one-dimensional convolutional neural network (1D-CNN) is proposed. Firstly, the input characteristics of the loop closing current are analyzed in combination with the operational characteristics of the actual distribution network, and two kinds of input characteristics for loop closing current prediction are proposed; then, a simulation model is constructed based on DIgSILENT/PowerFactory to form the sample set; and finally, the model training of the two input features is performed separately, and hyperparameter optimization and prediction process are analyzed, so as to establish the 1D-CNN loop closing current prediction model. The simulation analysis then is carried out in the actual medium voltage distribution system in a region of Guizhou. The results show that the mean absolute errors of the model on the current samples I_a , I_b and I_c are 0.0927%, 0.2704% and 0.4797% respectively, indicating that the proposed method is capable of correctly and stably predicting the loop closing current.

Keywords

Distributed Generator, Medium Voltage Distribution Network, Loop Closing Current, Feature Analysis, 1D-CNN, DIgSILENT

Copyright © 2023 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

在“双碳”目标的推动下，新能源产业迅速发展[1][2]，大量接入配电网，其不确定性给新型电力系统的建设带来了重大影响[3][4]。为此，准确计算分布式电源接入配电网后的合环电流，对于推动新型电力系统的建设具有重要意义。

目前已有大量文献对合环运行进行了研究分析。文献[5]以馈线合环稳态电流和暂态电流为约束建立配电网转供优化模型；文献[6]提出了一种考虑多电压等级拓扑约束的合环转供优化模型；文献[7]提出了配电网中背靠背柔性直流的最优合环模型，并研究了潮流优化控制方法；文献[8]采用半不变量法计算合环电流的概率分布特性，并通过计算合环电流越限概率和程度评估合环操作的安全性；文献[9]提出一种通过求解闭区间内目标函数最大值的方法，推导出合环冲击电流计算数学模型；文献[10]基于馈线首末端微型同步相量测量装置(micro-synchronous phasor measurement units, μ PMU)的量测信息，提出一种负荷等值阻抗的合环转供电模型；但主要以物理建模的方法合环运行进行分析，目前仍缺乏人工智能对合环分析的研究。

近年来，人工智能技术的发展日新月异，卷积神经网络(convolution neural network, CNN)由于具有强大的建模和特征学习能力[11]，目前已成为各个领域中的研究热点[12][13][14]，相较于基于物理建模的方法速度更快，涉及的复杂机制更少[15]。鉴于机器学习强大的学习能力，已有部分学者将其应用到电力系统的短路电流计算中[16][17][18]，这给新型配电网的合环电流计算提供了新的思路。文献[19]基于极限梯度提升(extreme gradient boosting, XGBoost)算法得到影响配电网合环转供电的因素，并提出相应的调控措施；文献[20]基于神经网络提出了一种数据驱动的配电网合环判定方法；尽管现有研究已取得较好的

合环电流计算效果,但模型结构主要面向图像数据设计,缺乏针对电力系统量测数据的模型设计。

为此,本文提出一种基于 1D-CNN 的含 DG 中压配电网合环电流预测方法。首先,设计了一种包括输入层、三组一维卷积层和池化层、全连接层和输出层的 1D-CNN 结构;其次,分析推导了与合环电流相关的两种配电网特征;然后再利用 DiGSILENT/PowerFactory 建模仿真形成样本集分别进行模型训练。最后,通过贵州省某实际案例进行合环电流预测,并与其他算法进行比较,验证了所提方法的优越性。

2. 含 DG 的中压馈线合环模型

2.1. 中压配电网合环结构

分布式电源(DG)接入中压配电网合环的结构如图 1 所示,图中 B_1 、 B_2 分别为不同 110 kV 变电站 10 kV 馈线出口断路器,馈线 a 、 b 通过联络开关相连, U_{ai} 、 U_{bj} ($i=1,2,\dots,m,j=1,2,\dots,n$) 分别表示馈线 a 、 b 节点电压, S_{ai} 、 S_{bj} ($i=1,2,\dots,m,j=1,2,\dots,n$) 分别表示馈线 a 、 b 节点负荷, $S=P+jQ$, S_{DGi} ($i=1,2$) 为光伏电源注入容量。

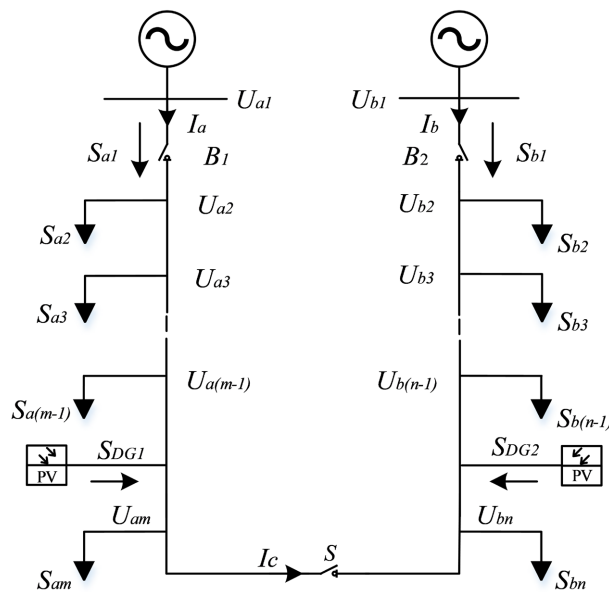


Figure 1. The structure diagram of loop closing with photovoltaic power supply
图 1. 含光伏电源的合环结构图

正常运行时, B_1 、 B_2 均处于关合状态,联络开关 S 处于断开状态,两条 10 kV 馈线分别由各自上级变电站带电开环运行。当其中一条馈线需要进行故障处理或负荷转移等操作时,可通过合环操作将发生故障或负荷较重的线路转移至另一条线路,即可达到减少停电次数或不停电的效果,保障了用户的用电需求,提高了供电的可靠性。

分布式电源的接入势必会对电网潮流造成一定的影响,例如潮流反向等,中压配电网合环线路中功率、电压的波动将直接影响合环操作是否成功。稳态环流主要由循环功率引起的环流和负荷电流组成。若 $U_{a1} > U_{b1}$, 则当联络开关 S 闭合后两侧 10 kV 馈线上级电源送出功率分别为:

$$S_{a1} = \frac{\sum_{i=2}^{m+n} Z_{i,i+1}^* (S_{ai} - S_{DGi})}{Z_{\Sigma}^*} + \frac{(U_{a1}^* - U_{b1}^*) U_N}{Z_{\Sigma}^*} \quad (1)$$

$$S_{b1} = \frac{\sum_{i=2}^{m+n} Z_{i,i+1}^* (S_{bi} - S_{DGi})}{Z_{\Sigma}^*} - \frac{\left(U_{a1}^* - U_{b1}^* \right) U_N}{Z_{\Sigma}^*} \quad (2)$$

其中： m 、 n 分别代表馈线 a 、 b 上负荷节点数量， $Z_{i,i+1}$ 表示馈线 a 、 b 上节点之间的阻抗，对其求和则代表第 i 个负荷节点到另一侧电源点的阻抗， $S_{DGi} = 0$ 时表示第 i 个节点没有分布式光伏接入， Z_{Σ} 为环网内所有阻抗之和， U_N 为额定电压，* 为共轭。

2.2. 输入特征选择

通常，对于电力系统中某确定的配电网，潮流变化与配电网的结构之间存在一定的规律，利用配电网中信息采集系统(SCADA)采集的部分节点的注入功率、电压幅值等信息，通过求解潮流方程，可以确定配电网当前的运行方式，潮流方程如下：

$$\begin{cases} P_i = U_i \sum_{j=1}^N U_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) \\ Q_i = U_i \sum_{j=1}^N U_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}) \end{cases} \quad (3)$$

式中： P_i 、 Q_i 分别代表节点 i 的注入有功功率和无功功率， U_i 为节点电压幅值； N 代表配电网馈线节点总数； G_{ij} 、 B_{ij} 分别为节点 i 与节点 j 之间的互电导和互电纳； θ_{ij} 为节点 i 与节点 j 之间的电压相角差。

目前配电网中还未完全配备微型同步相量测量装置等监控量测设备，但一般可以通过安装的电流互感器的和电压互感器获得支路电流及节点电压有效值，这些数据同样也能反映当前配电网的运行方式。实际工程中，对于某一特定的配电网，馈线结构的变化类型往往有限的，因此可以通过深度学习等方法来拟合配电网的量测数据与合环稳态电流之间的关系。

对此，针对配电网实际量测条件，本文考虑装配 μ PMU 与否的理想条件下和实际量测条件下两种情况，收集中压配电网运行特征信息并结合联络开关位置，作为样本输入特征。训练数据集的样本标签为对应输入特征的馈线首端电流及合环处稳态电流，通过 DIgSILENT/PowerFactory 对实际配电网进行建模仿真记录获得。对于配备 μ PMU 与否的配电网应有不同的合环电流预测模型输入特征 F_1 和 F_2 ， F_1 和 F_2 的推导分别如式(4)和式(5)所示：

$$F_1 = \left\{ |U_{a1}|, \dots, |U_{ai}|, \dots, |U_{bj}|, \theta_{a1}, \dots, \theta_{ai}, \dots, \theta_{bj}, P_{a1}, \dots, P_{ai}, \dots, P_{bj}, \right. \\ \left. Q_{a1}, \dots, Q_{ai}, \dots, Q_{bj}, L_{ij}, p_{la}, p_{lb}, S_{dg1}, S_{dg2}, \dots, S_{dgi} \right\} \quad (4)$$

$$F_2 = \left\{ I_{a1}, \dots, I_{ai}, \dots, I_{bj}, U_{a1}, \dots, U_{ai}, \dots, U_{bj}, L_{ij}, p_{la}, p_{lb}, S_{dg1}, S_{dg2}, \dots, S_{dgi} \right\} \quad (5)$$

其中： $|U|$ 、 θ 分别表示电压幅值、电压相位， P 、 Q 分别表示有功负荷、无功负荷， I 、 U 分别表示支路电流、电压有效值； L_{ij} 为馈线 a 上第 i 个节点与馈线 b 上第 j 个节点联络形成的合环线路； p_{la} 、 p_{lb} 分别为合环线路位置距离馈线 a 、 b 首端母线节点位置的百分比，且满足 $p_l \in [0, 100\%)$ ，当 $p_l = 0$ 时认为合环节点处于馈线首端。

3. 基于 1D-CNN 的含 DG 中压馈线合环电流预测方法

CNN 的结构主要由输入层、卷积层、激活层、池化层、全连接层和输出层构成。其中，卷积层和池化层主要用于分析数据样本的特征，然后通过全连接层输出预测结果。根据数据的维度，可分为一维、二维和三维卷积神经网络，由于配电网的馈线合环电流预测使用的数据是一维电力系统量测数据，因此一维卷积神经网络更适合计算合环电流。

1D-CNN 与传统机器学习算法的主要区别在于特征提取，传统的机器学习算法往往需要研究人员根据自己的经验投入大量精力构建特征向量模型，以提取有用的特征。相比之下，1D-CNN 网络以更加智能的方式提取特征，可以通过多层非线性变换从数据中学习特征。1D-CNN 虽然特征复杂，但可以提高训练的准确性，其结构也具有更强的表达和学习能力。

3.1. 卷积层

卷积层作为 1D-CNN 的核心，其功能为从输入层或低层特征图(Feature Map)中提取特征。特征提取操作是通过其结构中的一些过滤器在卷积层上完成的。卷积层拥有很多参数，即卷积核。每个卷积核都有其可接受的字段，并对应于输入的完整深度。在进行计算时，卷积层利用卷积核对输入特征进行扫描，然后对感受野内的输入特征进行矩阵乘法和偏置向量相加[21]，如下所示：

$$y_j^l = \sum_{i=1}^M x_i^{l-1} \cdot \omega_{ij}^l + b_j^l \quad (6)$$

其中， y_j^l 表示卷积层 j 中第 l 个滤波器的输出， ω_{ij}^l 表示第 i 个输入和第 j 个输出映射之间的第 l 层中神经元的权重，实际上就是卷积核， b_j^l 为偏置向量，符号 \cdot 表示卷积运算。

卷积运算后，每个卷积输出值需要通过激活函数进行非线性变换激活 1D-CNN 的隐藏层，得到新的特征。考虑到本文中 1D-CNN 应用的功能被设置为电流预测，因此每层上的卷积运算选择修正线性单元(Rectified Linear Unit, ReLU)激活函数执行得到特征图，如下所示：

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

3.2. 池化层

在通过卷积核学习后，卷积层提取的特征形成了一个新的特征图，但是这些特征图携带了大量的特征，阻碍了计算操作。为了保持明显特征的同时减少冗余特征，使用池化层降低数据维度，减少网络参数的数量，并加快计算速度[22]。池化操作通常分为平均池化和最大池化两种类型，鉴于最大池化应用广泛，本文也使用了最大池化。池化操作计算如下：

$$y_j^l = f\left(\sum_{i=1}^M \text{down}(x_i^{l-1}) + b_j^l\right) \quad (8)$$

式中 down 表示最大池化操作。

3.3. 全连接层

全连接层是具有互连神经元的前馈神经网络。全连接层的输入为卷积层和池化层接收提取的特征。然后，为了在 1D-CNN 的最后一层对它们进行分类，在全连接层中计算特征的权重和偏差。根据式(9)，在每个全连接层中，每个神经元捕获输入值并将其转换为一个输出值：

$$y = f\left(\sum_{i=1}^n k_i x_i - b\right) \quad (9)$$

其中， y 为输出值， x_i 为第 $i-1$ 层的全连接输入， k_i 表示神经元对输入值的敏感度， b 表示偏置向量。

4. 方法步骤

4.1. 数据归一化

为了降低输入特征维度和量纲对训练模型的影响，通常对输入数据进行归一化预处理。归一化通过

将有量纲的数据转换为无量纲数据来简化计算，其目的是将数据的统计分布特征一般化，使它们具有可比性的同时仍然保持相对关系。

通常，将大量特征数据输入到神经网络中会使得梯度更新变大，从而降低神经网络的学习速度，甚至可能会导致计算不收敛。此外，神经网络可能会忽略非归一化数据的分布特征，从而降低对其他数据的泛化能力。因此，采用“Min-Max normalization”计算方法将输入数据归一化转换到[0, 1]区间的无量纲数据，加快模型的训练过程，避免出现泛化问题。归一化计算方法如下所示：

$$x_{\text{norm}} = \frac{x_i - x_{\text{min}}}{x_{\text{max}} - x_{\text{min}}} \tag{10}$$

式中： x_{norm} 表示归一化输出值， x_i 表示原始待处理数据， x_{min} 和 x_{max} 分别表示待处理数据中的最大值和最小值。

4.2. 模型超参数寻优

超参数寻优是机器学习中的重要一环，对模型训练的性能有着重要影响。为了避免模型训练过程中出现过拟合问题，将数据集分为训练集和测试集。其中，训练集用于计算梯度并更新权重和偏置向量，测试集用于评估模型的泛化性能。K折交叉验证是最常用的性能评估方法，如图2所示。

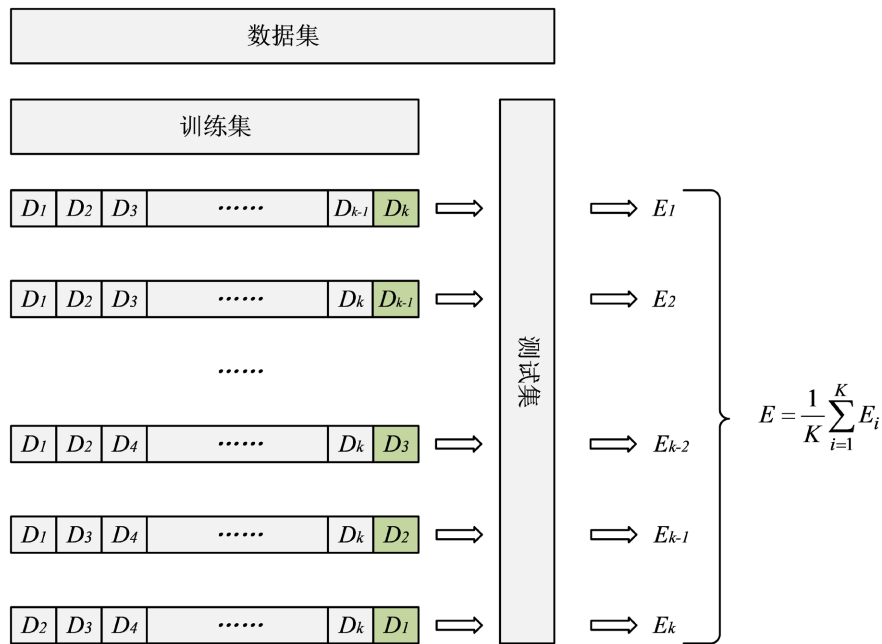


Figure 2. The schematic diagram of K-fold cross-validation
图2. K折交叉验证示意图

首先，将数据集样本分成k个大小相同、互不相交的子集；接着，遍历这k个子集，每次用k-1个子集作为训练集训练模型，将剩下的一个子集作为测试集进行模型测试和评估；最后，将k次测试的误差取平均值作为最终的评估指标。

4.3. 1D-CNN 模型预测流程

含DG的配电网合环电流预测模型主要包括构建训练数据集、离线训练和在线应用3个部分。流程

图如图 3 所示。具体流程如下：

步骤一：通过 DigSILENT/PowerFactory 建立所需的配电网模型；

步骤二：对网络模型中馈线负荷基于时间的参数特性进行定义，基于配电网 SCADA 系统获取历史断面量测数据创建负荷状态，设置配电网的运行方式；

步骤三：进行准动态仿真，记录输入特征和对应馈线首端及合环处电流稳态值，构建训练数据集；

步骤四：通过随机搜索与 K 折交叉验证法进行超参数寻优，生成 1D-CNN 合环电流预测模型；

步骤五：将输入特征输入到训练好的模型中，即可得到当前配电网拓扑结构合环电流预测值。

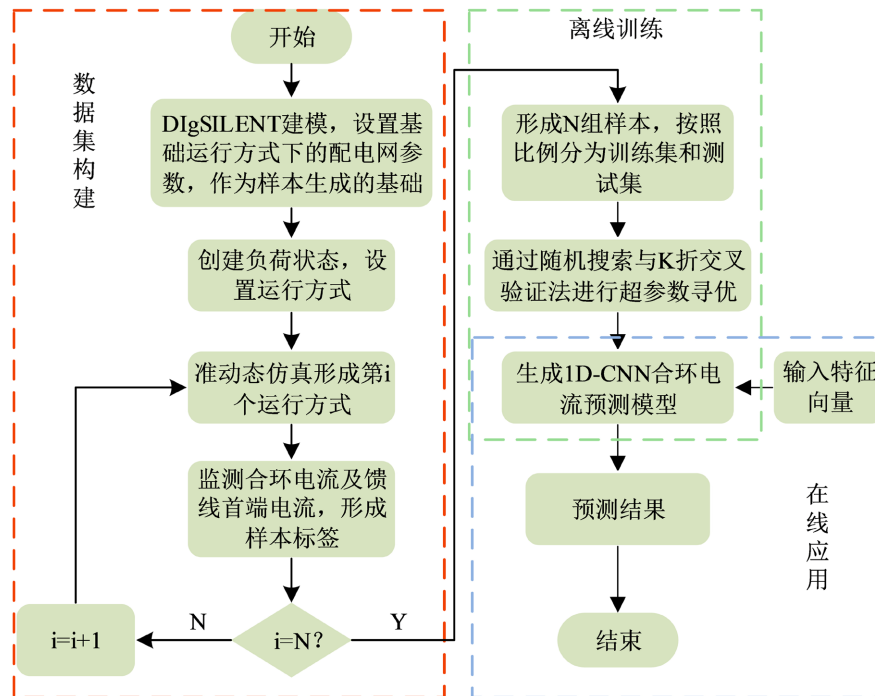


Figure 3. The flowchart of loop closing current prediction

图 3. 合环电流预测流程图

4.4. 模型评价指标

一般通过真实值与预测值之间的差异来评估模型的准确性。为了综合评估所提模型的性能，本文采用了两种不同的评估指标，即平均绝对百分比误差 MAPE (Mean Absolute Percentage Error) 和平均绝对误差 MAE (Mean Absolute Error)。

MAPE 为相对误差 RE (Relative Error) 的期望值，表示预测值与实际值之间的相对百分比误差。MAE 为绝对误差 AE (Absolute Error) 的期望值，表示预测值与实际值之间绝对差的平均值，用于衡量所提出方法的平均误差大小。相关定义如下：

$$AE = y_i - \hat{y}_i \quad (11)$$

$$RE = \frac{y_i - \hat{y}_i}{y_i} \times 100\% \quad (12)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (13)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |(y_i - \hat{y}_i)| \tag{14}$$

式中： y_i 为实际值， \hat{y}_i 为预测值， n 表示样本总数。这些指标的值越小，则代表模型性能越好。

5. 算例分析

5.1. 算例情况说明

为进一步验证所提方法的有效性，以贵州省某市实际配电网作为算例进行分析，并将预测结果与 DIgSILENT/PowerFactory 的仿真结果进行对比，来自不同 110 kV 变电站两侧馈线负荷分布及合环点如图 4、图 5 所示。馈线 a 侧变压器容量为 50 MVA，短路损耗为 161.20 kW，短路电压为 16.63%；馈线 b 侧变压器容量为 50 MVA，短路损耗为 176.22 kW，短路电压为 17.10%。




Figure 4. Load distribution of 10 kV feeder line a

图 4. 10 kV 馈线 a 的负荷分布




Figure 5. Load distribution of 10 kV feeder line b

图 5. 10 kV 馈线 b 的负荷分布

为保证模型训练的准确性，运用 DIgSILENT/PowerFactory 中的“准动态仿真”功能模块获取大量样本数据，“准动态仿真”利用了基于时间的参数特征，可以完成一系列时间间隔内的潮流计算，用户可以灵活选择仿真周期和步长。由于负荷随时间变化，而光伏出力也随日照辐射量变化，建模仿真时假设馈线上所有负荷拥有相同的分布特性，但巅峰负荷不同。基于该市 2020 年 3 月~2021 年 3 月的历史负荷数据，在配电网仿真平台 DIgSILENT/PowerFactory 中建立模型并进行准动态仿真，获得电网不同运行方式下的数据集。图 5、图 6 中网络模型参数设置见附录 A 表 A1，巅峰负荷设置见附录 A 表 A2，分布式光伏电源容量为 2 MW，该光伏电源的出力特性见附录 A 图 A1，馈线节点负荷特性分别见附录 A 图 A2、图 A3。

根据光照变化, 光伏电源每一个小时采集一次数据, 馈线上相应的节点负荷变化也每一个小时采集一次数据, 本算例以馈线 a 、 b 首端及合环节点处的电流作为监测对象, 通过准动态仿真共获得 8784 组样本。将样本按照 8:2 的比例分为训练集和测试集, 即 7027 组作为训练集, 1757 组作为测试集。根据式(4)可得 208 个输入特征, 根据式(5)则有 106 个输入特征。

为保障模型的有效性和鲁棒性, 本文采用效率更高的随机搜索与 10 折交叉验证法进行超参数寻优, 包括神经网络的卷积层数、卷积核的数量和大小、学习率等, 本文以 MAPE 的平均值作为评价标准, 验证超参数寻优结果, 1D-CNN 模型参数寻优结果为: 卷积层数为 3 层, 每个卷积层步长设置为 1, 卷积填充层数为 1, 池化层大小为 2, 每个池化层的步长设置为 2×1 , 激活函数为 ReLU。具体结果如表 1 所示。

Table 1. The parameters of CNN structure

表 1. CNN 结构参数

超参数	类型	值
综合参数	批处理	64
	激活函数	ReLU
	学习率	0.0001
	损失函数	MAPE
1D-CNN	卷积层数	3
		32
	卷积核数量	32
		64
	卷积核大小	3×1

5.2. 模型性能比较

为验证所提方法的准确性, 选用式(4)作为输入特征, 使用其他机器学习算法如极限梯度提升、深度神经网络(deep neural networks, DNN)与之进行对比, 基于相同的训练集样本建模, 采用相同的测试样本集进行测试, 实现含 DG 的中压配电网合环电流预测。各个算法对馈线 a 、 b 首端电流 I_a 、 I_b 和联络开关处合环电流 I_c 的预测值与实际值之间的平均误差如表 2 所示, 表中加粗数值表示算法在训练集和测试集上的最佳表现。

由表 2 可知, 1D-CNN 在对于 I_a 、 I_b 测试集上 MAPE 和 MAE 值的表现相较于 XGBoost 和 DNN 更加出色, 在 I_a 的测试集上其 MAPE 值分别降低了 62.8%和 85.1%, MAE 值分别降低了 59.4%和 78.2%; 在 I_b 的测试集上其 MAPE 值分别降低了 17.2%和 44.3%, MAE 值分别降低了 5.6%和 37.0%; 而对于 I_c 的测试集来说, 其 MAPE 值较 XGBoost 算法和 DNN 算法分别降低了 24.6%和 69.8%, MAE 值则是分别降低了 23.4%和 69.5%。由此可见, 1D-CNN 在馈线首端及合环处电流的测试集上都有较好的准确度提升, 而合环处电流的预测误差相较于馈线首端更大, 这是由于输入特征只采集了馈线 a 、 b 合环前的特征, 导致馈线末端合环后电流的学习效果相对较差。

选取 2020 年夏季某日合环操作时从配电网信息采集系统获取数据, 考虑实际量测情况, 输入特征选择式(5), 将实际数据输入 1D-CNN 模型进行验证, 同时与 XGBoost 和 DNN 的结果进行比较, 如表 3 所示。

Table 2. Prediction result comparison of different models
表 2. 不同算法预测结果对比

样本	算法	MAPE/%		MAE/A	
		训练集	测试集	训练集	测试集
I_a	XGBoost	0.1693	0.2492	0.2678	0.9657
	DNN	0.3604	0.6211	0.7830	1.8004
	1D-CNN	0.0235	0.0927	0.0712	0.3918
I_b	XGBoost	0.1815	0.3267	0.1880	0.4737
	DNN	0.1478	0.4853	0.1545	0.7104
	1D-CNN	0.1420	0.2704	0.1499	0.4473
I_c	XGBoost	0.1663	0.6359	0.2108	1.1284
	DNN	0.8534	1.5868	1.0902	2.8378
	1D-CNN	0.2374	0.4797	0.3056	0.8646

Table 3. Prediction result comparison of loop closing current
表 3. 合环电流预测结果对比

样本	实际值	算法	预测值	MAE/A	MAPE/%
I_a	299.85	XGBoost	303.83	3.98	1.3273
		DNN	296.08	3.77	1.2573
		1D-CNN	302.11	2.26	0.7537
I_b	103.56	XGBoost	100.71	2.85	2.7520
		DNN	99.36	4.20	4.0556
		1D-CNN	104.97	1.41	1.3615

由表 3 可知, 从实际量测结果和评价指标来看, 三种预测模型都有不错的表现, 但 1D-CNN 的预测效果相较于 XGBoost 和 DNN 效果更佳; 通过分析模型结构可知, 1D-CNN 结合了稀疏连接和权重共享的特点, 卷积层提取特征后, 数据会被输入到池化层进行处理, 池化层会过滤掉无关变量, 从而降低模型的计算复杂度, 减少计算量, 提高模型拟合速率和预测准确率。相比之下, XGBoost 和 DNN 则对数据本身进行处理, 容易因计算量过大而导致模型过拟合的问题。

5.3. 样本数量分析

在 5 折交叉验证法的验证下, 不同样本数量下选用式(4)和式(5)作为输入特征时的效果图分别如图 6(a)、图 6(b)所示。

对比两种输入特征下的预测误差可知, 选用式(4)或式(5)作为输入特征, 合环电流的准确预测都依赖

于大量的样本数量，随着样本数量的增加，合环电流预测的 MAE 值和 MAPE 值都呈现出不同程度的下降趋势。尽管选用式(5)作为输入特征时，其 MAE 值和 MAPE 值都要高于式(4)，但其误差也在工程允许误差范围之内。因此，在 μ PMU 尚未普及时，可选用式(5)作为合环电流预测的输入特征，该方法预测误差较小，适用于配电网的合环电流预测。

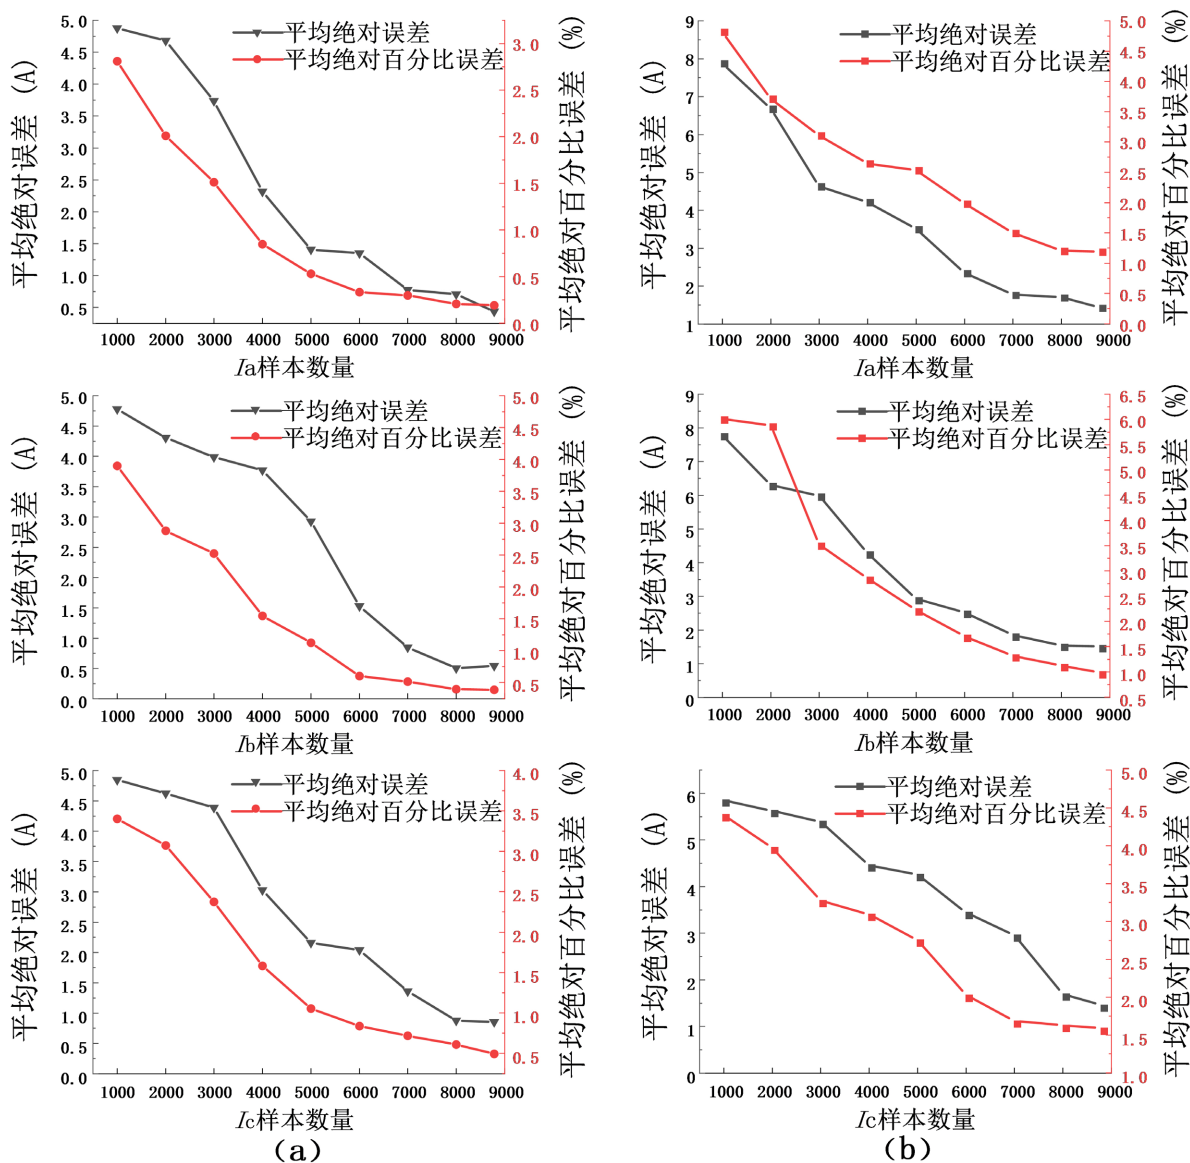


Figure 6. Error results under different numbers of data sets

图 6. 不同样本数量下误差结果

6. 结论

本文提出了一种含 DG 的新型配电网下合环电流的预测方法，基于一维卷积神经网络的结构原理，设计了适用于中压配电网合环电流预测的 1D-CNN 结构，解决了传统合环电流计算速度与准确性之间的矛盾。通过贵州省某地实际案例进行了仿真研究分析。同时与其他相关算法进行了性能对比，得到的主要结论如下：

1) 针对仿真案例, 1D-CNN 对合环馈线组不同馈线的首端电流及联络节点合环电流都有不错的拟合效果, 相较于其他方法具有较高的预测精度, 例如采用 1D-CNN 模型测试 I_a 的训练集时, 其 MAPE 值和 MAE 值相较于表现同样优秀的 XGboost 方法分别降低了 62.8%和 59.4%, 验证了所提方法在准确度上的提升;

2) 针对实际案例, 在缺乏量测装置的条件下所提模型依然能够采用简化模型作为输入特征并进行合环电流预测, 即便结果的准确性相较于配置有 μ PMU 的条件下有所下降, 但 MAPE 值和 MAE 值仍然在可接受的范围, 可满足在线应用的要求。

基金项目

黔科合基础-ZK [2021]一般 277; 贵州省科技支撑计划项目([2023] 290)。

参考文献

- [1] 欧阳金鑫, 陈纪宇, 袁毅峰, 等. 考虑合环电压波动抑制的配电网故障恢复协同控制方法[J/OL]. 电力系统自动化, 2023: 1-11. <http://kns.cnki.net/kcms/detail/32.1180.TP.20230221.1131.002.html>
- [2] 唐巍, 张起铭, 张璐, 等. 新型配电系统多层级交直流互联理念、关键技术与发展方向[J/OL]. 电力系统自动化, 2023: 1-16. <http://kns.cnki.net/kcms/detail/32.1180.TP.20230217.1019.002.html>
- [3] 王乃进, 韩松, 罗远国. 利用日最小负荷置信区间的光伏发电准入容量确定[J]. 电力系统及其自动化学报, 2020, 32(2): 54-60.
- [4] 姚宏民, 秦文萍, 景祥, 等. 基于可能性理论的低电压配电网分布式光伏承载能力评估方法[J/OL]. 高电压技术, 2023: 1-11. <https://doi.org/10.13336/j.1003-6520.hve.20221722>
- [5] 周念成, 谷飞强, 雷超, 等. 考虑合环电流约束的主动配电网转供优化模型[J]. 电工技术学报, 2020, 35(15): 3281-3291.
- [6] 周念成, 莫复雪, 肖舒严, 等. 计及多电压等级配电网拓扑约束的协调转供优化[J]. 中国电机工程学报, 2021, 41(9): 3106-3120.
- [7] 葛乐, 陆文涛, 袁晓冬, 等. 背靠背柔性直流互联的有源配电网合环优化运行[J]. 电力系统自动化, 2017, 41(6): 135-141.
- [8] 周自强, 张焰, 郭强, 等. 基于概率潮流的 10 kV 配电网合环操作安全性评估[J]. 电网技术, 2019, 43(4): 1421-1429.
- [9] 吴艳娟, 王皓月, 杨理. 配电网合环冲击电流精确算法[J]. 电力系统及其自动化学报, 2020, 32(4): 123-129.
- [10] 赖胜杰, 夏成军, 纪焕聪, 等. 计及负荷等值阻抗的配电网合环转供电分析模型[J]. 电工技术学报, 2022, 37(11): 2859-2868.
- [11] 何成兵, 王润泽, 张霄翔. 基于改进一维卷积神经网络的汽轮发电机组轴系扭振模态参数辨识[J]. 中国电机工程学报, 2020, 40(S1): 195-203.
- [12] 毛钧毅, 韩松, 李洪乾. 适用于电网异常负荷动态判别的 CNN 阈值模型[J]. 计算机工程, 2020, 46(6): 308-313.
- [13] Zhan, X.W., Han, S., Rong, N., et al. (2022) A Two-Stage Transient Stability Prediction Method Using Convolutional Residual Memory Network and Gated Recurrent Unit. *International Journal of Electrical Power and Energy Systems*, 138, Article ID: 107973. <https://doi.org/10.1016/j.ijepes.2022.107973>
- [14] Gu, J., Wang, Z., Kuen, J., et al. (2018) Recent Advances in Convolutional Neural Networks. *Pattern Recognition*, 77, 354-377. <https://doi.org/10.1016/j.patcog.2017.10.013>
- [15] Qu, J., Liu, F., Ma, Y., et al. (2019) A Neural-Network-Based Method for RUL Prediction and SOH Monitoring of Lithium-Ion Battery. *IEEE Access*, 7, 87178-87191. <https://doi.org/10.1109/ACCESS.2019.2925468>
- [16] 黄旭, 何洪英, 罗滇生, 等. 一种新的短路电流预测方法[J]. 电力系统及其自动化学报, 2017, 29(1): 24-29.
- [17] 郑翔, 王慧芳, 姜宽, 等. 机理与数据融合驱动的含 IIDG 配电网短路电流计算方法[J]. 电力自动化设备, 2021, 41(1): 41-48.
- [18] 叶睿恺, 王慧芳, 张森, 等. 数据驱动的含 IIDG 配电网短路电流计算多输出模型[J]. 电力自动化设备, 2022, 42(9): 119-125+132.
- [19] 纪焕聪, 夏成军, 赖胜杰, 等. 基于改进极限梯度提升算法的配电网合环转供电影响因素评估[J/OL]. 南方电网

-
- 技术, 2023: 1-8. <http://kns.cnki.net/kcms/detail/44.1643.TK.20230309.1022.004.html>
- [20] 安义, 陈琛, 范瑞祥, 等. 数据驱动的配电网合环条件判定方法[J]. 水电能源科学, 2019, 37(12): 152-156.
- [21] Lecun, Y., Bengio, Y. and Hinton, G. (2015) Deep Learning. *Nature*, **521**, 436-444. <https://doi.org/10.1038/nature14539>
- [22] Moradzadeh, A., Mohammadi-Ivatloo, B., Abapour, M., *et al.* (2021) A Practical Solution Based on Convolutional Neural Network for Non-Intrusive Load Monitoring. *Journal of Ambient Intelligence and Humanized Computing*, **12**, 9775-9789. <https://doi.org/10.1007/s12652-020-02720-6>

附录 A

Table A1. The line parameters of feeder *a*表 A1. 馈线 *a* 线路参数

类型	编号	型号	长度(m)	类型	编号	型号	长度(m)
	$L_a(1, 2)$	YJV22-300	200		$L_b(1, 2)$	YJV22-300	450
	$L_a(2, 3)$	YJV22-300	185		$L_b(2, 3)$	YJV22-3 × 300	126
	$L_a(3, 4)$	YJV22-300	20		$L_b(3, 4)$	YJV22-300	10
	$L_a(4, 5)$	YJV22-300	15		$L_b(4, 5)$	YJV22-3 × 300	126
	$L_a(5, 6)$	YJV22-300	10		$L_b(5, 6)$	YJV22-3 × 300	126
	$L_a(6, 7)$	YJV22-300	40		$L_b(6, 7)$	YJV22-3 × 300	126
	$L_a(7, 8)$	YJV22-300	100		$L_b(7, 8)$	YJV22-120	8
	$L_a(8, 9)$	YJV22-120	350		$L_b(2, 9)$	YJV22-300	100
	$L_a(9, 10)$	YJV22-300	100		$L_b(3, 10)$	YJV22-120	150
	$L_a(10, 11)$	YJV22-300	10		$L_b(3, 14)$	YJV22-120	100
	$L_a(11, 12)$	YJV22-120	100		$L_b(14, 17)$	YJV22-300	100
	$L_a(12, 13)$	YJV22-120	100		$L_b(14, 18)$	YJV22-300	200
馈线 <i>a</i>	$L_a(2, 14)$	YJV22-120	100	馈线 <i>b</i>	$L_b(18, 19)$	YJV22-120	100
	$L_a(6, 15)$	YJV22-120	15		$L_b(18, 20)$	YJV22-120	100
	$L_a(8, 16)$	YJV22-120	100		$L_b(20, 24)$	YJV22-120	110
	$L_a(9, 17)$	YJV22-3 × 300	136		$L_b(20, 21)$	YJV22-120	100
	$L_a(10, 19)$	YJV22-3 × 300	126		$L_b(21, 25)$	YJV22-120	100
	$L_a(19, 24)$	YJV22-120	8		$L_b(21, 22)$	YJV22-120	10
	$L_a(19, 20)$	YJV22-3 × 300	126		$L_b(22, 26)$	YJV22-120	15
	$L_a(20, 21)$	YJV22-120	15		$L_b(22, 23)$	YJV22-120	20
	$L_a(21, 22)$	YJV22-120	15		$L_b(4, 11)$	YJV22-3 × 300	126
	$L_a(22, 23)$	YJV22-120	126		$L_b(5, 12)$	YJV22-120	10
	$L_a(11, 18)$	YJV22-120	100		$L_b(5, 15)$	YJV22-120	100
	$L_a(11, 25)$	YJV22-120	100		$L_b(6, 13)$	YJV22-120	100
					$L_b(7, 16)$	YJV22-120	100

Table A2. The peak load of feeder node
表 A2. 馈线节点巅峰负荷

类型	节点	最大负荷 P_{\max} (MW)	类型	节点	最大负荷 P_{\max} (MW)
	2	0.13230		2	0.17182
	3	0.09180		3	0.19138
	4	0.09750		4	0.19529
	5	0.08748		5	0.18429
	6	0.11502		6	0.17011
	7	0.11340		7	0.17769
	8	0.10962		8	0.16865
	9	0.10854		9	0.18013
	10	0.10638		10	0.18527
	11	0.15552		11	0.18820
	12	0.13554		12	0.15276
	13	0.13338		13	0.18038
馈线 <i>a</i>	14	0.12366	馈线 <i>b</i>	14	0.15911
	15	0.07992		15	0.17256
	16	0.09288		16	0.16718
	17	0.10584		17	0.18307
	18	0.12582		18	0.14860
	19	0.09072		19	0.15276
	20	0.08370		20	0.14201
	21	0.07074		21	0.14445
	22	0.09774		22	0.14005
	23	0.13834		23	0.13247
	24	0.12832		24	0.14005
	25	0.08513		25	0.14005
				26	0.13810




Figure A1. The output characteristic curve of photovoltaic power
图 A1. 光伏电源出力特性




Figure A2. The load distribution characteristic curve and power factor of feeder *a*
图 A2. 馈线 *a* 负荷分布特性曲线及功率因素

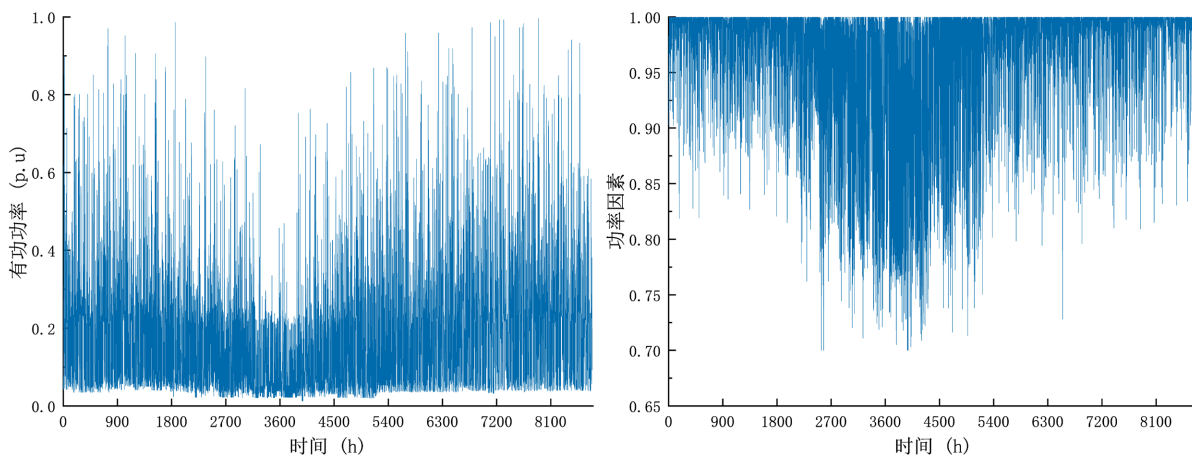


Figure A3. The load distribution characteristic curve and power factor of feeder *b*
图 A3. 馈线 *b* 负荷分布特性曲线及功率因素