

基于CNN-GRU的配电网中压馈线合环电流预测研究

罗勇, 荣娜*, 詹献文

贵州大学电气工程学院, 贵州 贵阳

收稿日期: 2022年6月22日; 录用日期: 2022年7月18日; 发布日期: 2022年7月25日

摘要

为提高传统配电网中压馈线合环电流估算或预测准确性和适应性, 本文提出了一种基于卷积神经网络(Convolutional Neural Network, CNN)和门控循环单元(gated recurrent unit, GRU)的配电网中压馈线合环电流预测方法。首先, 利用数据采集与监视控制系统获取历史负荷数据、电网结构参数以及运行方式等数据并进行预处理。其次, 将预处理后的海量数据按时间滑动窗口构造为连续的特征矩阵作为输入, 最后, 利用CNN-GRU混合模型建立输入特征与合环电流的映射关系, 生成基于CNN-GRU的中压馈线合环电流预测模型, 进而实现其回归预测。借助DigSILENT/PowerFactory和MATLAB 2020a软件, 案例分析在贵州某城市配电网中展开, 预想场景仿真和3组6条馈线合环试验结果初步表明所提的基于CNN-GRU的数据驱动方法能提升合环电流估算或预测的准确性和适用性, 与其他模型CNN、GRU相比 R^2 值分别由79.91%, 87.7%提高到99.68%, 验证了所提的模型具有较高的准确性和可行性, 相关结论与讨论对配电网智能化技术研发有一定参考价值。

关键词

CNN, GRU, 配电网, 中压馈线, 合环电流预测, DigSILENT

Research on Closed-Loop Current Prediction for Medium Voltage Feeder in Distribution Network Based on CNN-GRU

Yong Luo, Na Rong*, Xianwen Zhan

Department of Electrical Engineering, Guizhou University, Guiyang Guizhou

Received: Jun. 22nd, 2022; accepted: Jul. 18th, 2022; published: Jul. 25th, 2022

*通讯作者 Email: nrong@gzu.edu.cn

Abstract

In order to improve the accuracy and adaptability of estimating or predicting the closed-loop current of MV feeders in traditional distribution networks, this paper proposes a method of predicting the closed-loop current of MV feeders in distribution networks based on Convolutional Neural Network (CNN) and Gated Recurrent Unit (GRU). Firstly, the data acquisition and monitoring control system is used to obtain and pre-process the historical load data, grid structure parameters and operation modes. Secondly, the pre-processed massive data are constructed as continuous feature matrices according to the time-sliding window as input. Finally, the CNN-GRU hybrid model is used to establish the mapping relationship between the input features and the loop current to generate the CNN-GRU-based medium voltage feeder loop current prediction model, and then realize its regression prediction. With the help of DlgSILENT/PowerFactory and MATLAB 2020a software, the case study is carried out in a city distribution network in Guizhou Province. The simulation of the envisioned scenario and the results of three sets of six feeder loop closing tests initially show the effectiveness and adaptability of the proposed method, and the related conclusions and discussions are of reference value for the development of intelligent technologies for distribution networks.

Keywords

CNN, GRU, Distribution Network, Medium-Voltage Feeder, Closed-Loop Current Prediction, DlgSILENT

Copyright © 2022 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

为了减少用户停电时间,减轻直接或间接的社会经济损失[1],我国城镇区域绝大多数中压线路都采用了双端电源供电[2] [3] [4]。当某个母线、开关或馈线需要检修或者发生故障时,该母线、开关或馈线上的多电源供电的负荷通过中压馈线合环操作进行转移[5] [6] [7],将负荷转移到与之相连的其他母线或馈线上,从而实现不停电倒负荷操作[8] [9] [10]。然而,在执行中压馈线合环操作过程时,如果合环前合环点两端母线的电压大小、相位存在较大差异,往往会引发很大的合环电流,导致中压馈线保护动作。合环过程中,若发生短路故障,或危害操作人员的人身安全和影响电网的安全稳定运行。因此,面向智能电网建设,为减少客户平均停电时间,提升电力用户满意度,以“计划工作零停电和故障停电趋零”为目标,在配电网馈线转供电合环操作之前,对配电网馈线路合环电流进行估算或预测十分必要。

目前,实际配电网操作人主要依据经验[11] [12]决定何时和是否可以合环操作,这样会导致合环操作具有一定的盲目性,存在合环后过流跳闸导致操作不成功的情况,降低了配电系统的供电安全性和可靠性。近年来,国内外已有一些关于中压馈线合环电流估算或预测等安全性分析的研究报道,但存在以下局限性。其一,从研究应用对象的角度来看,受限现有配电网主要馈线路场景,文献[13]中研究应用对象主要考虑为无新能源发电接入的配电网馈线,文献[14]分析了中压配电网不同合环操作的特点以及对系统运行的影响,但都并未针对新型配电网中新能源发电接入的馈线进行分析,其二,从合环电流估算或预测的边界条件角度来看,文献[15] [16]中负荷水平往往采用当前时段负荷或最大负荷值,并未结合

馈线合环转供电计划的预期时段做负荷预测。其三,从合环电流估算或预测的数学模型或算法的角度来看,文献[17][18]中主要采用简化等值模型驱动的确定性评估方法,该类模型计算准确性较好,具有估算的便捷性,以及应用的可行性。然而,该类方法本质上属于一种确定性的模型驱动方法,对于中压馈线运行中的拓扑结构、负荷类型和大小、新能源发电接入类型和大小、运行方式等建模复杂性和边界条件随机性等的适应性较差。

随着大数据和人工智能技术的发展[19][20],卷积神经网络(Convolutional Neural Network, CNN)算法具有高效特征提取能力,门控循环单元(gated recurrent unit, GRU)具有专门处理时间序列问题的能力,在电力系统领域有了较为深入的研究和初步应用。为此,从数据驱动的角度[21][22],本文提出一种基于CNN-GRU的中压馈线合环电流预测方法,以贵州某市配电网典型中压馈线为例,DIgSILNET和MATLAB R2020a的仿真分析以及现场初步实测结果表明了所提方法的准确性、适用性和有效性。

2. 合环电流的特征分析与合环操作可行条件

2.1. 合环电流的特征分析

在构建合环电流预测模型之前,首先需要确定合环电流预测样本的特征和标签。合环电流特征指的是影响合环电流大小的电网特征,主要具有以下几个方面:从主网的角度来看,包括发电机的开机方式、电源的等值阻抗、系统的运行方式、新能源注入的大小以及位置等;从配电网的角度来看,包括各节点的电压幅值和相角、合环馈线的传输功率以及各负荷的有功功率和无功功率等;从合环操作角度看,包括合环操作位置、合环操作类型、合环操作时段以及线路切断情况等。本文考虑到合环操作后线路最大的合环电流可能是流过合环操联络开关处的电流 I_{loop} 以及合环线路两端线首的电流 I_A, I_B ,因此,将上述三个测量点的电流作为合环电流预测模型的样本标签。

考虑到影响合环电流大小的主要因素,本文选取的合环电流特征为:合环馈线两端电压幅值、电压相角、馈线阻抗、馈线传输功率、馈线拓扑变化情况、馈线负荷以及主网的运行方式等,合环电流可表达为:

$$I_{loop}(t) = f\{P(t), Q(t), U(t), H(t), I(t-1)\} \quad (1)$$

式中: $I_{loop}(t)$ 表示 t 时刻合环电流值; $P(t)$ 表示 t 时刻合环馈线负荷有功功率; $Q(t)$ 表示 t 时刻合环馈线无功功率; $U(t)$ 表示 t 时刻合环馈线两端母线电压幅值; $I(t-1)$ 表示馈线合环前时刻馈线初始电流; $H(t)$ 表示 t 时刻系统可测其他数据。

2.2. 合环操作可行条件

除了考虑合环稳态电流,一般在合环开关闭合后的半个周波内(即0.01 s),环路中将会出现较大的合环冲击电流,其最大有效值计算式如下:

$$I_M = KI_{loop} \quad (2)$$

式中: I_M 为合环线路最大冲击电流; I_{loop} 为合环线路稳态电流; K 为冲击系数,一般取1.62[23]。

中压馈线通常配备三段式电流保护来保护线路,由于冲击电流在合环后约半个周波出现,所以冲击电流主要对无时限电流速断保护(即电流保护I段)产生影响,而合环稳态电流将会对限时电流速断保护(即电流保护II段)和定时限过电流保护(即电流保护III段)产生影响,但为了能够最大限度的保护馈线线路,通常采用定时限过电流保护(即电流保护III段)来保护线路。

$$I_{act.I} = K'_{rel} I_{k.max} \quad (3)$$

$$I_{\text{act.III}} = \frac{1}{K_{\text{re}}} I_{\text{re}} = \frac{K_{\text{rel}} K_{\text{Ms}}}{K_{\text{re}}} I_{\text{L.max}} \quad (4)$$

式中： K'_{rel} 为可靠系数，取 1.2~1.3， $I_{\text{k.max}}$ 为最大运行方式下变电站母线上的三相短路电流， $I_{\text{act.I}}$ 为一段保护动作电流， K_{rel} 为可靠系数，取 1.25~1.5， K_{Ms} 为自起动系数，一般取 1.5~3， K_{re} 为电流继电器返回系数，取 0.95， $I_{\text{L.max}}$ 为正常运行时的最大负荷电流， I_{re} 为继电器动作电流， $I_{\text{act.III}}$ 为三段保护动作电流。当合环开关闭合后合环稳态电流不超过线路的最大允许载流量和定时限过电流保护整定值，合环冲击电流不超过无时限电流速断保护整定值即可判定为合环成功。

3. 基于 CNN-GRU 的馈线合环电流预测模型

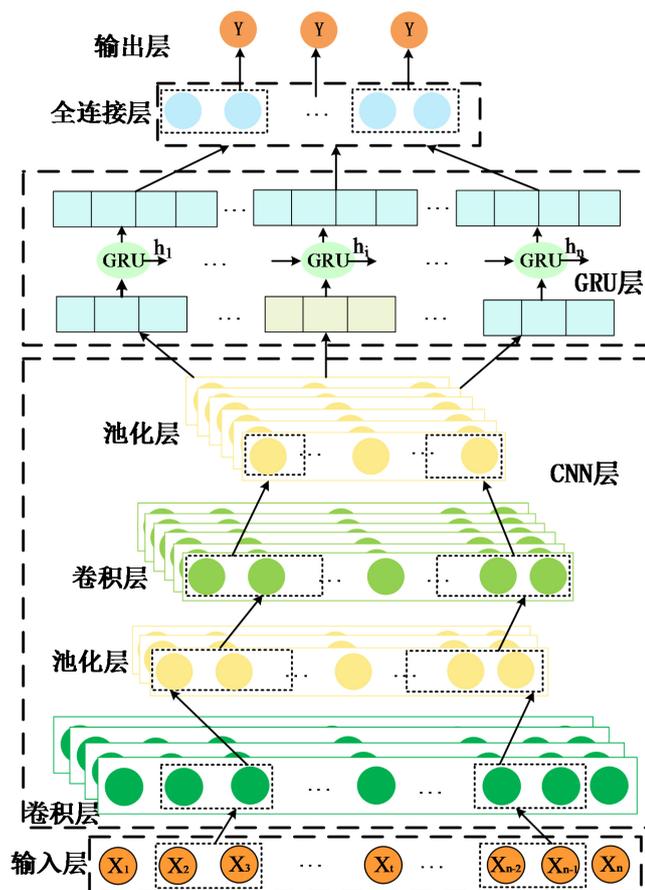


Figure 1. The structure of CNN-GRU
图 1. CNN-GRU 结构

由式(1)可以看出合环电流计算参数较多，在环网线路参数不足的情况下可由神经网络对线路潮流的历史数据进行训练，这样即可得到相应的映射关系预测得到馈线的合环电流。本质上，馈线合环电流是一类连续时序变量，其预测在机器学习领域属于一个回归问题。因此，可通过获取其直接或间接连接的网络潮流数据构造其预测输入模型。目前，关于利用机器学习和深度学习进行回归预测模型有长短期记忆网络(Long Short Term Memory Neural Networks, LSTM)、CNN、GRU 等。其中，CNN 是一种深层前馈网络，常用于处理多个阵列数据，例如时间序列、图像和音频频谱图等[24]。它的卷积层可对原始数据提取特征量，深度挖掘数据的内在联系，池化层能够降低网络复杂度、减少训练参数，从而实现输入数据

与输出之间的逻辑关系的高效提取。而 GRU 是 LSTM 网络的一种变种，是一种特殊类型的循环神经网络[25]。该算法通过在隐层结构中增加重置门和更新门，解决了传统循环神经网络(recurrent neural network, RNN)反向传播中梯度消失和梯度爆炸的问题，收敛速度更快。相比 LSTM 三个门结构参数更少，并缩短了模型的训练时间，GRU 神经元内部结构如附录图 A1 所示。数学描述式如附录式 A-1 所示。激活函数公式见 A-2, A-3。

基于 CNN 的高效特征提取能力，以及 GRU 在时序输入数据挖掘的性能优势，考虑合环电流的时序特性，借助现有的预测研究成果。本文构建了一种基于 CNN-GRU [26] [27]的合环电流预测模型，相较于其他预测模型，本模型具有较高的预测精度，且训练收敛速度较快。其模型结构如图 1 所示。

4. 方法流程和准确性评价指标

所提方法流程图如图 2 所示，包括离线训练和在线预测两个过程。在离线训练过程中，首先调度人员确定合环操作边界条件。根据边界条件的操作类型利用配电网的历史数据或软件仿真数据建立样本集，设计该 CNN-GRU 合环电流预测模型。其次，将获取的数据集以及样本标签值划分为训练集，验证集，测试集，利用 CNN 进行训练集中数据进行特征提取获取合环电流预测高维特征，再输入到 GRU 进行合环电流预测模型训练，迭代更新模型参数直至满足合环电流预测指标。最后，用验证集进行合环电流预测模型验证，设计出不同合环操作类型的 CNN-GRU 合环电流离线训练模型。在线应用过程中，首先通过 SCADA (Supervisory Control And Data Acquisition)系统在线采集合环操作线路附近主要支路潮流和母线电压等数据，并对拟合环馈线所在母线开展负荷和新能源发电出力预测。其次，利用前述离线训练好的模型对拟合环操作馈线进行某时刻或某时间区间内的合环电流预测。其具体步骤如下：

1) 合环边界条件确定：包括运行人员选择待合环的线路，合环操作类型，指定中压线路合环计划操作时间范围，确定期望时间段的高压和中压配电网运行方式；

2) 数据采集：在 SCADA 等系统中获取历史数据，涉及配电网调度部输电线路和变压器等电网结构参数和运行方式数据，发电和负荷水平数据、分布式能源出力、相关合环馈线电流历史数据等；

3) 数据预处理：对历史数据进行数据清洗，包括删除异常值，通过插值方法填充缺省值，并将数据进行归一化转换到 0~1 的范围区间，去除数据的单位限制，将其转化为无量纲的纯数值[28]；

4) 神经网络训练、生成：通过时间错位的方法处理清洗后的数据，形成训练数据，生成适应模型结构的输入格式，调节 CNN 网络的输入层，隐藏层，全连接层，以及卷积步长，卷积核等网络结构参数，以达到更优预测结果，根据合环操作类型设计相应的基于 CNN-GRU 的深度学习模型，实现合环电流预测模型的训练，生成其合环电流离线预测模型；

5) 合环电流在线预测：获取实时负荷数据，针对该计划操作时间范围开展负荷预测和分布式电源出力数据预测，利用步骤 4 训练好的离线预测模型开展阶段性合环电流预测以及不同位置合环电流预测结果，包括馈线 A 首端、馈线 B 首端以及合环开关三处稳态电流，即 I_A 、 I_B 和 I_{loop} ；

6) 输出结果与展示：先对预测结果反归一化，得到合环电流预测值，利用式(2)计算出馈线的最大冲击电流，根据式(4)和式(5)的判定条件对比合环馈线线路最大容许载流量，以及继电器动作值给出预计合环时段推荐。

此外，为测评合环电流预测的准确性，参考文献[29]，选择均方根误差(Root Mean Square, Error, RMSE)，平均绝对误差(Mean Absolute Error, MAE)，绝对百分误差(Mean Absolute Percentage, Error, MAPE)，以及决定性系数(Coefficient of determination, R2)等作为准确性指标。其中，R2 用于模型性能比较，该指标越接近 1 表明准确率越好。同时，为衡量合环电流某个时刻的预测准确率，选取绝对百分比误差(Absolute Percentage Error, APE)作为点预测准确性的评价指标。上述指标具体数学表达如附录公式 A-4 到 A-8。

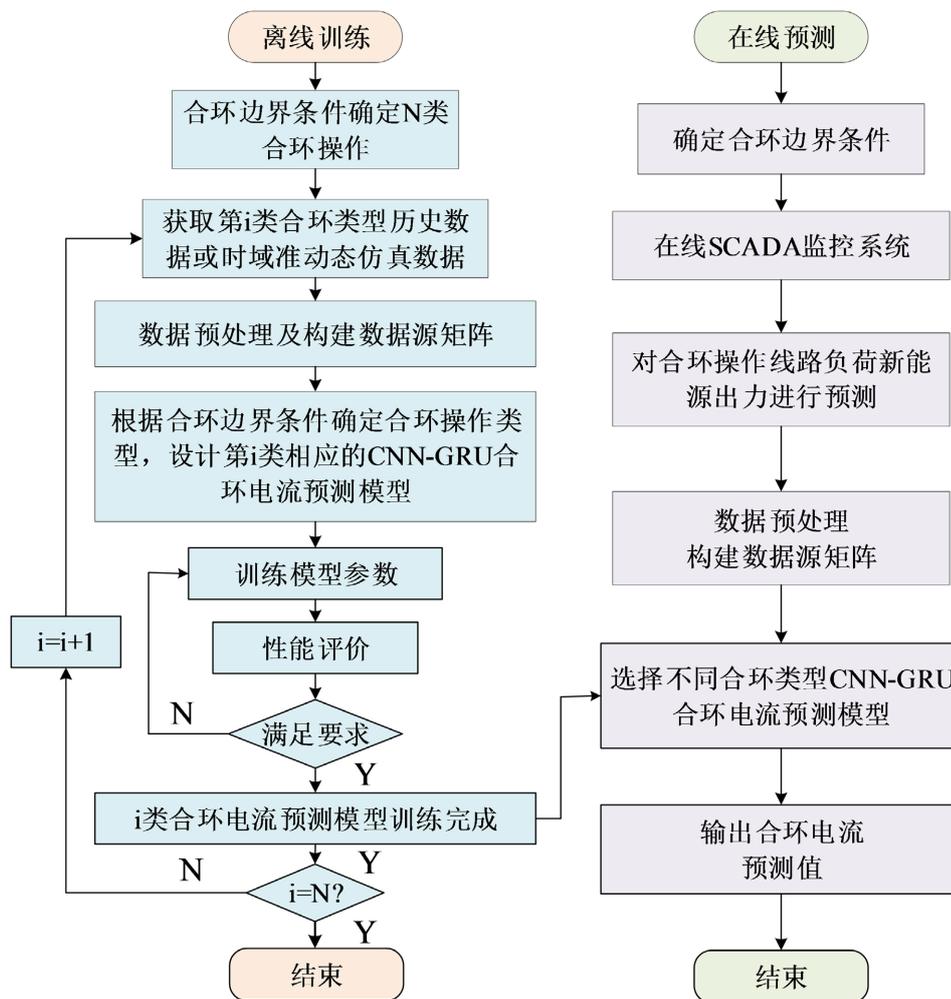


Figure 2. The flow chart of the proposed methodology
图 2. 所提方法流程图

5. 案例分析

5.1. 数据处理与样本生成

为测试所提方法的有效性,以贵州某城市配电网中压馈线合环试验为例,利用 DIgSILENT 建立了一个包括 3 组来自不同变电站的 6 条 10 kV 馈线及其上级电网简化系统模型。该模型包括 4 座 500 kV 变电站, 16 座 220 kV 变电站。根据前期 10 kV 馈线详细建模和简化建模研究,本文中 10 kV 馈线采用三段负荷等值建模[17],负荷按照馈线总长度的百分之三十,百分之五十,百分之八十处进行三段等值,其地理接线示意图如附录图 A3 所示。图中该组合环馈线分别来自 110 kV 变电站 ZCB 和 SFB。为了获取不同运行方式下合环电流预测所需的输入数据样本,可参考文献[30]借助 DIgSILENT 软件来模拟 SCADA 系统中各节点年度历史负荷数据。通过 DIgSILENT 模拟 11 种不同的年负荷分布(G0, G1, G2, G3, G4, G5, G6, H0, L0, L1, L2)。每种负荷曲线的建模方法相同,分为 4 个季节,每个季节由工作日和非工作日组成,非工作日又分为周六和周日,因此每个季节的负荷均由三个日负荷分布构成,如冬季中的周一到周五的日负荷分布均为工作日-冬,周六的日负荷分布为周六-冬,周日的日负荷分布为周日-冬。四个不同季节时间分配定义如表 1 所示。

Table 1. Definition of seasons
表 1. 季节的定义

季节名称	起始日	起始月	结束日	结束月
冬季	1	十一月	20	三月
春季	21	三月	14	五月
夏季	15	五月	14	九月
秋季	15	九月	31	十月

本文采集了合环馈线相关母线的历史负荷数据，以及主要邻近变电站接入的光伏发电数据。其余负荷数据生成均采用本文模拟的 11 种负荷，如附录图 A2。采集的负荷数据进行了缺省值填充和归一化，从而得到时间间隔为 15 分钟的年负荷分布曲线。这样，可得到全部负荷数据与光伏发电数据。其中，一个典型母线负荷和一个典型光伏出力曲线如图 3，图 4。

将上述负荷和发电数据等导入 DlgSILENT 构建的配电网简化系统模型中，借助其准动态仿真模块，获取各运行方式下样本数据。共计获取不同运行方式下 35,040 个随机样本以及相同的标签，其中输入特征包括上级电网等值负荷有功功率，无功功率，母线电压幅值，馈线有功负荷，馈线无功负荷，等 86 个潮流数据，标签为合环联络开关处，两馈线首端处电流。训练测试样本按照 8:2 划分，即构造 28,032 个随机样本作为离线训练集，其中 7001 个形成在线测试样本。相关算法程序在 MATLAB 2020a 中编写和执行。

5.2. 模型参数确定

为了得到包括模型最大迭代步长，初始化学学习率，最小迷你批处理，模型卷积层数，以及 GRU 回归层数等最优模型参数，通过多次训练，观察其预测指标，不断迭代，最终确定其结构参数，详细参数见表 2。

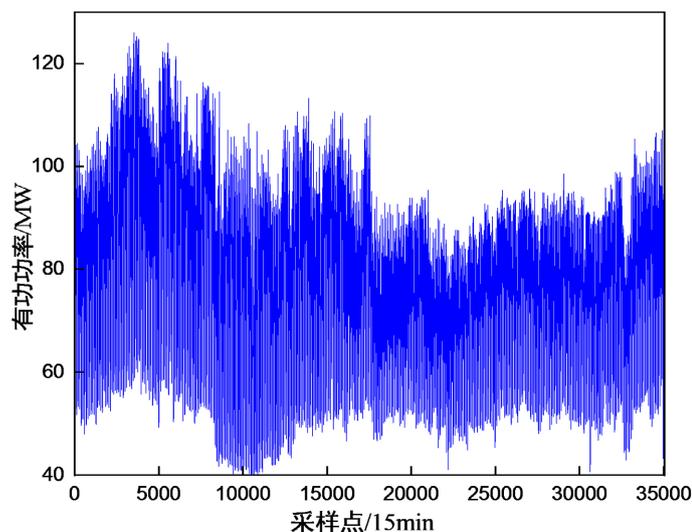


Figure 3. Load curve of a bus
图 3. 某母线有功负荷曲线

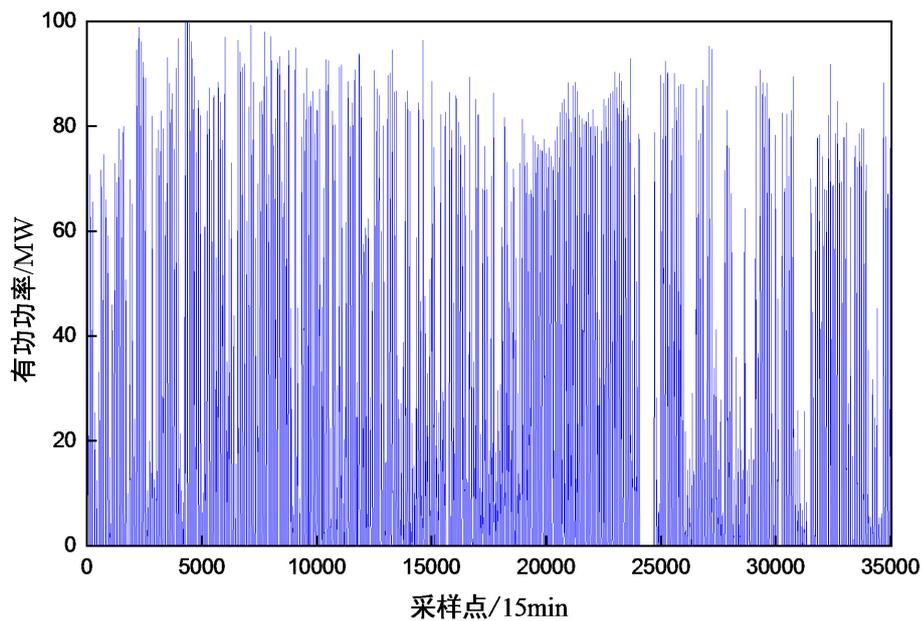


Figure 4. Active power of a photovoltaic station

图 4. 某光伏发电功率曲线

Table 2. The parameters of the CNN-GRU model

表 2. CNN-GRU 模型结构参数表

名称	尺寸	步长
输入层	86*1*1	/
卷积层 1	3*1	2*1
平均池化层 1	2*1	2*1
卷积层 2	3*2	2*1
平均池化层 2	2*1	2*1
卷积层 3	3*1	2*1
平均池化层 3	2*1	2*1
GRU1	128	/
GRU2	64	/
全连接层 1	128	/
全连接层 1	64	/
全连接层 1	3	/
回归输出层	3*1	/

当进行合环电流预测输出时，合环联络开关 I_{loop} 处的学习效果远不及 IA 以及 IB 处，这意味着只要保证 I_{loop} 处预测误差满足要求即可。其原因或在于输入特征采集了 IA 与 IB 合环之前的电流分布规律加大了模型的学习速率， I_{loop} 处于合环末端，导致学习效果较低。因此，本文通过控制变量法，设置不同迭代步长，以及不同批处理下观察 I_{loop} 处合环电流预测误差对比结果，最终确定预测模型网络结构参数。相关实验对比见表 3。

Table 3. The prediction errors about I_{loop} under different conditions
表 3. 不同参数下合环电流 I_{loop} 预测误差表

批处理	迭代	MAE/%	MAPE/%	R ² /%	RMSE
12	5	0.70	13.62	87.70	0.0127
24	5	0.79	16.51	86.93	0.0131
32	5	0.77	14.47	87.06	0.013
64	5	0.98	19.93	80.76	0.0159
64	10	0.93	16.55	85.60	0.0138
64	15	0.84	16.16	84.49	0.0143
64	20	0.68	13.48	89.79	0.0116
128	15	0.652	11.32	88.63	0.0236
128	20	0.14	3.64	90.20	0.036
128	25	0.17	3.30	99.68	0.002
128	30	0.25	4.6	92.36	0.004

由表 3 可见，当迭代步长次数 25 次，批处理为 128 时，R2 值达到 99.68%，其他预测预测误差相对较小，故本文预测模型设置迭代步长为 25，批处理大小为 128。初始学习率为 0.002，L2 正则化系数为 0.0002。

5.3. 仿真结果分析

为表明所提模型的准确性，本文通过仿真实验，利用 GRU, CNN 与所提模型进行了预测结果比较。三种模型利用相同的训练集样本进行训练，利用相同的测试集对同一组馈线合环电流进行预测。三种模型采用了相同的输入数据，其中 CNN, GRU 网络隐含层层数及每一隐含层的神经元数量和所提 CNN-GRU 网络相同。本次测试选择在线预测测试集中的样本集，即在测量间隔为 15 分钟的情况下，预测样本为 96 个。

图 5~7 分别为各模型下 IA, IB 和 I_{loop} 的预测结果。同时，相关预测偏差汇总于表 4。利用(2)综合分析三处测量点合环冲击电流，结果与本文式(3)，式(4)对比，合环操作后，馈线 B 首端电流 IB 明显比合环之前降低，处于安全范围内。但是馈线 A 首端电流 IA 以及联络开关处合环电流 I_{loop} 均在部分时段明显

超过保护值。因此,上述时段该组馈线不宜进行合环操作,进而建议上述馈线应结合负荷预测在负荷低谷时段进行合环转供电操作。

由表 4 可见,对于 IA 和 IB,三种模型预测结果与仿真实验的实际值偏差均不大,准确性均较好。但对于 I_{loop} , CNN、GRU 以及 CNN-GRU 模型的 R2 值分别为 79.91%, 87.7%, 99.68%, 表明了所提模型的有效性和较好的准确性。

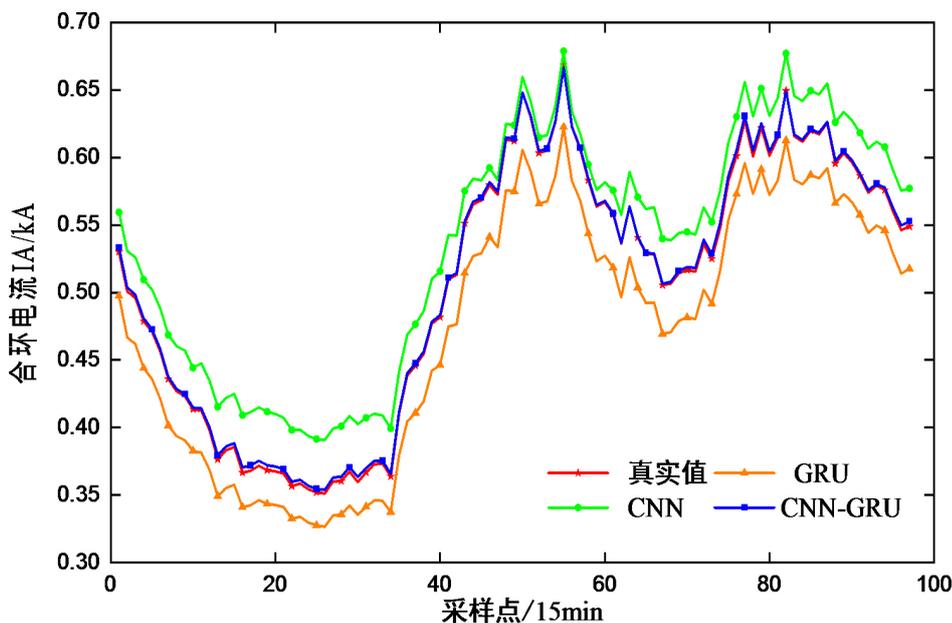


Figure 5. Prediction results from different models about IA

图 5. 不同模型的 IA 预测结果

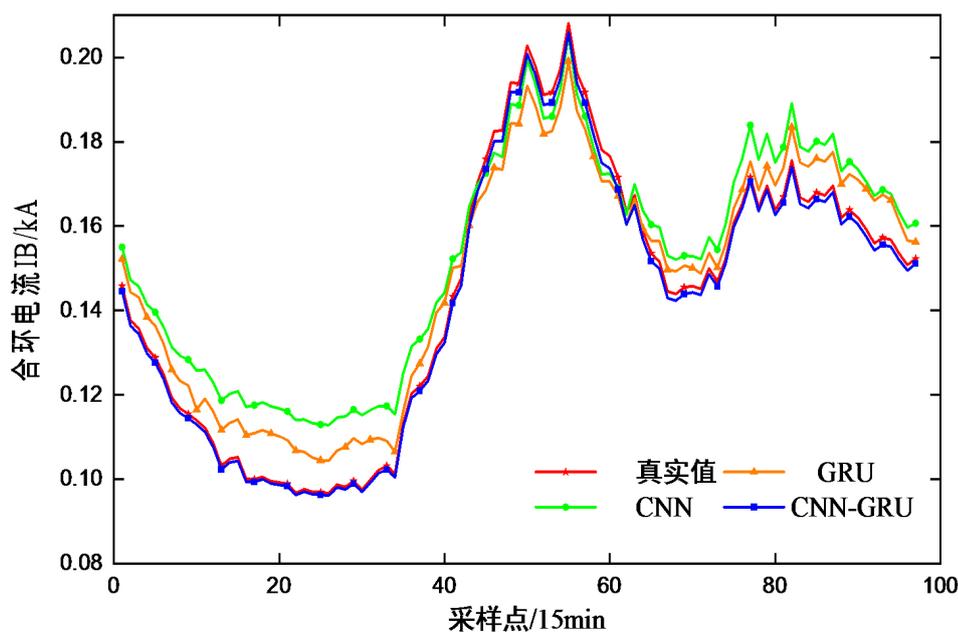


Figure 6. Prediction results from different models about IB

图 6. 不同模型的 IB 预测结果

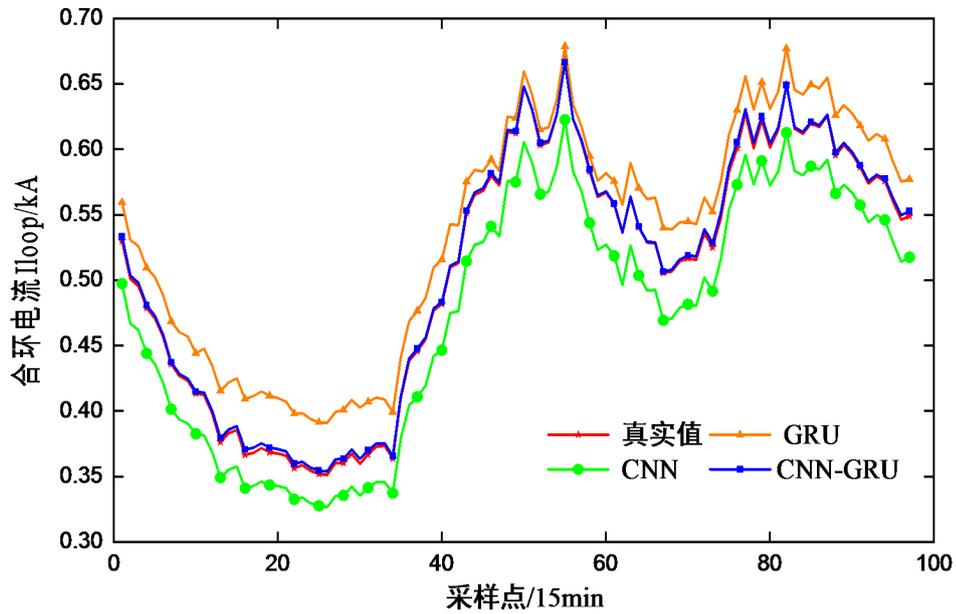


Figure 7. Prediction results from different models about I_{loop}
 图 7. 不同模型的 I_{loop} 预测结果

Table 4. Prediction errors of different models
 表 4. 不同模型预测偏差

测量点	模型	偏差指标			
		MAE/%	MAEP/%	R ² /%	RMSE
IA	CNN	0.92	0.89	99.30	0.0122
	GRU	0.98	1.62	99.12	0.1366
	CNN-GRU	0.29	0.48	99.93	0.0038
IB	CNN	0.89	3.4	99.31	0.0123
	GRU	0.81	3.22	99.36	0.0119
	CNN-GRU	0.19	1.03	99.97	0.0022
I_{loop}	CNN	1.37	28.46	79.91	0.0163
	GRU	0.7	13.6	87.7	0.0127
	CNN-GRU	0.17	3.3	99.68	0.002

5.4. 实测结果分析

为进一步测试所提模型的有效性和适应性，利用所提 CNN-GRU 模型开展了贵州某城市配电网不同变电站 3 组 6 条馈线的合环电流预测。结合前述方法，获得离线训练模型后，通过 SCADA 系统获取相关母线电压，线路潮流，拟合环馈线首端有功功率，无功功率等数据，并导入训练好的模型，进行合环

电流预测。需要说明的是，这 3 组 6 条馈线合环试验时，暂仅采集了馈线首端电流 IA, IB, 未同步采集到联络开关处合环电流 I_{loop} , 故仅给出三组馈线 IA, IB 预测值与实测值对比, 见表 5。

Table 5. Comparison between predicted and experimental values of loop current

表 5. 合环电流预测值与实测值对比

合环馈线	测量点	试验值/A	预测值/A	APE/%
ZDX	IA	198	190.38	3.8
FHX	IB	110	100.73	8.4
ZTH	IA	240	225.06	6.2
FPX	IB	39	41.6	6.2
ZXH	IA	280	288.39	2.9
FYX	IB	102	92.84	8.9

由表 5 可见, 这 3 组 6 条馈线合环电流预测值的绝对百分比误差均在 10% 以内, 初步表明了所提模型的有效性和适应性。可为配电网调度人员开展中压馈线合环操作提供辅助决策信息。

此外, 值得说明的是, 所提方法的耗时主要在模型训练过程, 合环电流预测过程需要的时间较少, 如: 前述模型平均训练时间为 22.23 s, 平均预测时间为 0.049 s。

6. 结论

本文提出一种基于 CNN-GRU 的配电网中压馈线合环电流预测方法。借助 MATLAB 2020a 和 DIgSILENT, 以一个贵州某城市配电网为例, 仿真和实测结果初步表明了所提方法的有效性, 此外有以下结论和认识:

- 1) 不同边界条件下的仿真测试结果表明, 相较于 GRU, CNN, 所提 CNN-GRU 模型有较好的准确性。
- 2) 贵州某城市配电网 3 组 6 条中压馈线合环试验结果与预测结果的 APE 均小于 10%, 表明了所提模型的有效性和较好的适应性。
- 3) CNN-GRU、迁移学习等, 或对于未来大规模分布式电源接入的新型配电网中压馈线合环电流预测等有较好的应用前景。

基金项目

贵州省优秀青年科技人才项目资助(黔科合平台人才[2021] 5645), This work was supported by the Program for Excellent Young Scientific and Technological Talents in Guizhou Province under Grant No. 20215645; 贵州省普通高等高校科技拔尖人才支持计划资助(2018036), Sponsored by Program for Top Science & Technology Talents in Universities of Guizhou Province (2018036); 贵州省科学技术基金(黔科合基础[2021] 277), Guizhou Province Science and Technology Fund ([2021] 277)。

参考文献

- [1] 黄滔滔, 荣娜. 基于 DIgSILENT 的光储联合系统作为地区电网黑启动电源可行性研究[J]. 电网与清洁能源,

- 2022, 38(2): 94-101.
- [2] 宋伟, 韩学军, 刘同, 等. 配网合环干扰下的过电压计算模型设计与实现[J]. 电网与清洁能源, 2020, 36(8): 21-27.
- [3] 王金芹, 贺柱, 张建华, 陈凯. 多配电网线路并发合环电压差计算方法研究[J]. 电网与清洁能源, 2020, 36(4):8-13.
- [4] 罗玉飞, 黄滔滔. 基于 DigSILENT 的中压配电网合环电流计算与仿真分析[J]. 电网与清洁能源, 2021, 37(6): 51-59.
- [5] 刘健, 张志华, 张小庆. 配电网故障处理若干问题探讨[J]. 电力系统保护与控制, 2017, 45(20): 1-6.
- [6] 田春笋, 殷奕恒, 关朝杰, 等. 基于供电分区的中高压配电网综合评价策略[J]. 电力系统保护与控制, 2018, 46(21): 152-159.
- [7] 潘龙, 裴付中, 杨历伟, 等. 配电网合环信号相角差的评估方法研究与仿真[J]. 电网与清洁能源, 2018, 34(9): 14-18.
- [8] 苗培青, 于耿曦, 纪双全, 等. 不同量测数据情形的配电网合环操作计算及应用[J]. 电力系统保护与控制, 2015, 43(1): 137-144.
- [9] 肖白, 赵龙安, 张宇, 等. 城市中压配电网合环操作分析与决策[J]. 电力系统保护与控制, 2014, 42(16): 133-138.
- [10] 张开宇, 冯煜尧, 余颖辉, 等. 中压配电网合环电流计算方法研究[J]. 电力系统保护与控制, 2020, 48(1):142-149.
- [11] 李文云, 曹敏, 李坤, 等. 考虑合环调电约束的配电网快速重构方法[J]. 电力系统保护与控制, 2019, 47(16): 159-165.
- [12] 任嘉鑫. 基于在线自组织同步 MAS 的主动配电网合环控制方法[D]: [硕士学位论文]. 武汉: 华中科技大学, 2019.
- [13] 朱雨晨, 赵冬梅, 刘世良, 等. 基于机电暂态-电磁暂态混合仿真的电网合环分析计算系统[J]. 电力系统保护与控制, 2012, 40(23): 73-79.
- [14] Hu, Y., Shao, X., Xie, C., *et al.* (2019) The Feasibility Research on Distribution Network Loop Closing Operation Based on Hybrid Grounding Model of Arc Suppression Coil and Low Resistance. 2019 *IEEE 3rd International Electrical and Energy Conference (CIEEC)*, Beijing, 7-9 September 2019, 1440-1443. <https://doi.org/10.1109/CIEEC47146.2019.CIEEC-2019524>
- [15] Chen, T.H., Huang, W.T., Gu, J.C., *et al.* (2004) Feasibility Study of Upgrading Primary Feeders from Radial and Open-Loop to Normally Closed-Loop Arrangement. *IEEE Transactions on Power Systems*, **19**, 1308-1316. <https://doi.org/10.1109/TPWRS.2004.831263>
- [16] 韩学军, 赵少峰, 赵慧磊, 刘同和, 王晓华. 冗余电压数据干扰下的配网合环潮流计算方法改进研究[J]. 电网与清洁能源, 2018, 34(7): 1-6.
- [17] 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.
- [18] 胡晓松, 张殷, 谢光彬, 等. 含 PV 节点的配电网合环潮流算法[J]. 电力系统保护与控制, 2015, 43(24): 8-13.
- [19] 陈庆超, 韩松, 毛钧毅. 采用多层次特征融合 SPP-net 的暂态稳定多任务预测[J]. 控制与决策, 2022, 37(5): 1279-1288.
- [20] 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 & Energy Systems*, **138**, Article ID: 107973. <https://doi.org/10.1016/j.ijepes.2022.107973>
- [21] 杨杰, 郭逸豪, 郭创新, 等. 考虑模型与数据双重驱动的电力信息物理系统动态安全防护研究综述[J]. 电力系统保护与控制, 2022, 50(7): 176-187.
- [22] 徐鑫裕, 边晓燕, 张骞, 等. 基于数据驱动的双馈风电场经 VSC-HVDC 并网次同步振荡影响因素分析[J]. 电力系统保护与控制, 2021, 49(21): 80-87.
- [23] 刘健, 孙泉, 张小庆, 等. 配电网合环分析与合环条件判断[J]. 电力系统自动化, 2014, 38(11): 130-135.
- [24] 赵凌云, 刘友波, 沈晓东, 等. 基于 CEEMDAN 和改进时间卷积网络的短期风电功率预测模型[J]. 电力系统保护与控制, 2022, 50(1): 42-50.
- [25] 杨威, 蒲彩霞, 杨坤, 等. 基于 CNN-GRU 组合神经网络的变压器短期故障预测方法[J]. 电力系统保护与控制, 2022, 50(6): 107-116.
- [26] 张立峰, 刘旭. 基于 CNN-GRU 神经网络的短期负荷预测[J]. 电力科学与工程, 2020, 36(11): 53-57.

-
- [27] 姚程文, 杨苹, 刘泽健. 基于 CNN-GRU 混合神经网络的负荷预测方法[J]. 电网技术, 2020, 44(9): 3416-3424.
- [28] 苏向敬, 山衍浩, 周汶鑫, 等. 基于 GRU 和注意力机制的海上风机齿轮箱状态监测[J]. 电力系统保护与控制, 2021, 49(24): 141-149.
- [29] 侯慧, 王晴, 赵波, 等. 关键信息缺失下基于相空间重构及机器学习的电力负荷预测[J]. 电力系统保护与控制, 2022, 50(4): 75-82.
- [30] 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.

附录 A

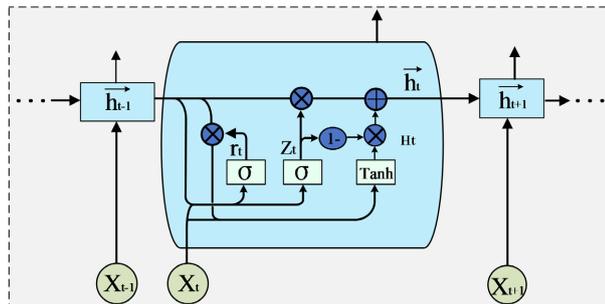


Figure A1. Basic unit of GRU network
图 A1. GRU 网络基本单元

$$\begin{cases} r_t = \sigma(W_r \cdot [h_{t-1}, x_t]) \\ z_t = \sigma(W_z \cdot [h_{t-1}, x_t]) \\ H_t = \phi(W_H \cdot [r_t \times h_{t-1}, x_t]) \\ h_t = (I - z_t) \times h_{t-1} + z_t \times H_t \\ y_t = \sigma(W_o \cdot h_t) \end{cases} \quad (A-1)$$

式中： r_t 表示重置门状态， z_t 表示更新门的状态， H_t 表示当前时刻候选集的状态， h_t 表示当前时刻的状态记忆变量， y_t 表示当前时刻的输出向量； W_r ， W_z ， W_H ， W_o ，分别表示各状态单元的权重系数； x_t 表示输入向量， h_{t-1} 上一个时刻的状态信息， I 表示单位矩阵向量， σ 表示 sigmoid 激活函数； ϕ 表示 tanh 激活函数；其中 σ 与 ϕ 的数学表达如下：

$$\sigma(x) = \frac{1}{1 + e^x} \quad (A-2)$$

$$\phi(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (A-3)$$

$$MAE = \frac{\left(\sum_{i=1}^N |y_i^{\text{pred}} - y_i^{\text{real}}| \right)}{N} \quad (A-4)$$

$$MAPE = \frac{\left(\sum_{i=1}^N \left| \frac{y_i^{\text{pred}} - y_i^{\text{real}}}{y_i^{\text{pred}}} \right| \right)}{N} \quad (A-5)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i^{\text{pred}} - y_i^{\text{real}})^2} \quad (A-6)$$

$$R^2 = \left[1 - \frac{\sum_{i=1}^N (y_i^{\text{pred}} - y_i^{\text{real}})^2}{\sum_{i=1}^N (y_i^{\text{real}} - y_{av}^{\text{real}})^2} \right] \times 100\% \quad (A-7)$$

$$APE = \frac{|y_i^{\text{pred}} - y_i^{\text{real}}|}{\max(y_i^{\text{pred}}, y_i^{\text{real}})} \quad (A-8)$$

式中： N 表示合环电流测试样本个数 i 为序号； y_i^{pred} 表示合环电流预测值； y_i^{real} 表示实际合环电流值； y_{av}^{real} 表示合环电流实际值的平均值。

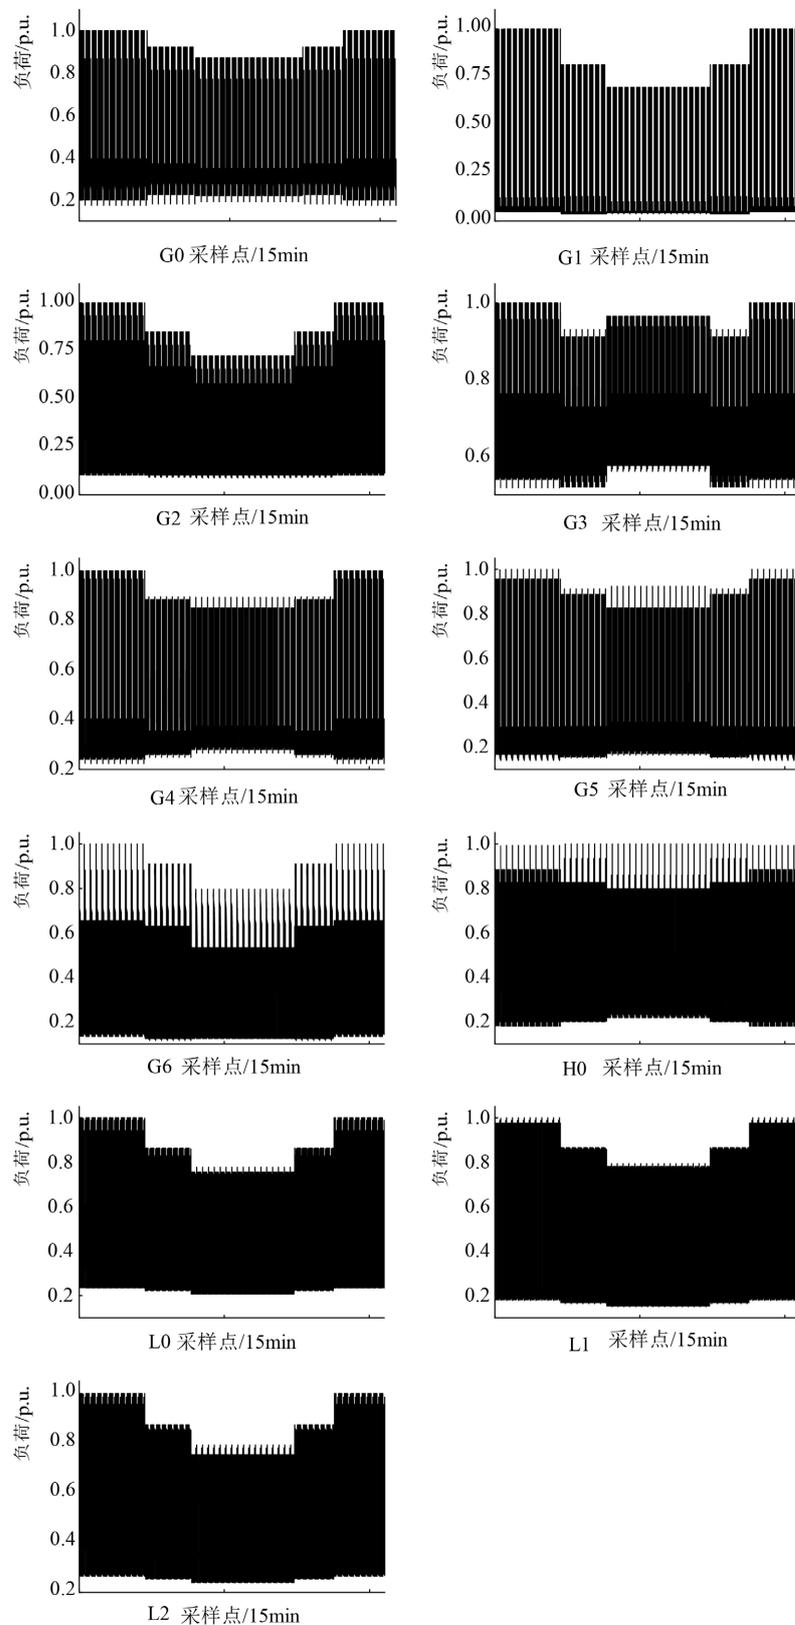


Figure A2. The load profiles simulated by DIgSILENT

图 A2. DIgSILENT 模拟的负荷曲线

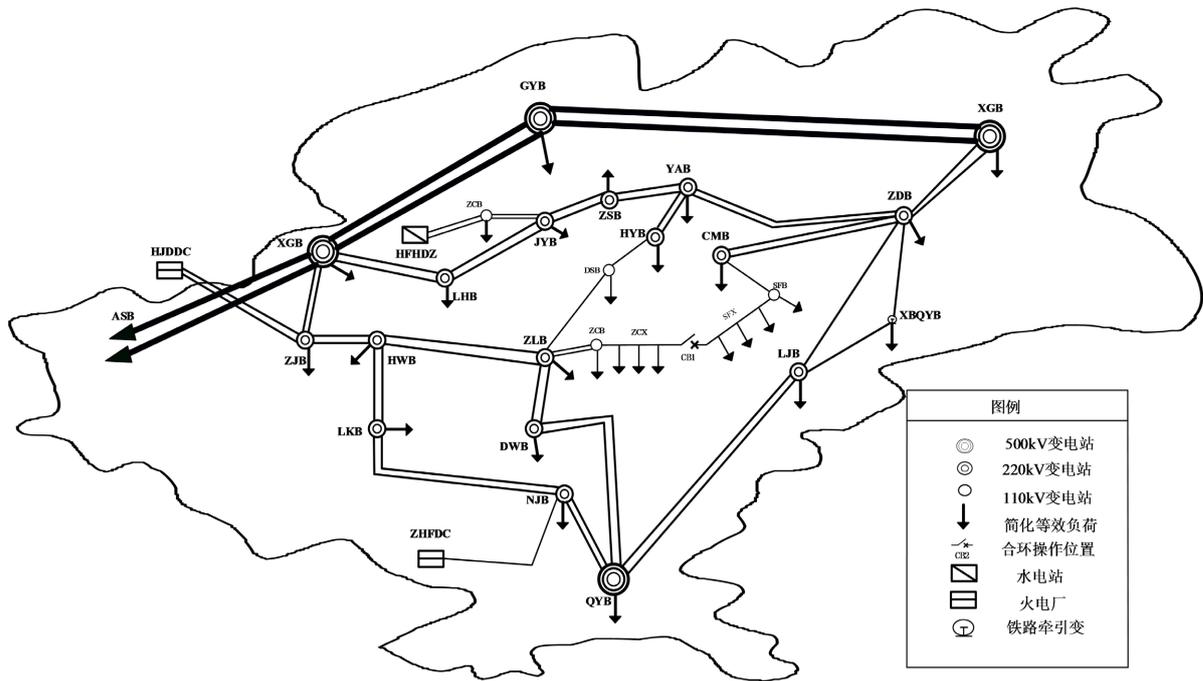


Figure A3. The schematic diagram for a distribution system in Guizhou

图 A3. 贵州某城市配电网中压馈线合环示意图