

## 基于多任务辅助学习的配网低电压成因分析

范李平<sup>1,2</sup> 朱庆<sup>1</sup> 李黄强<sup>2</sup> 杜丰夷<sup>2</sup> 黄宇<sup>2</sup> 刘云飞<sup>2</sup> 王东娟<sup>1</sup>  
(1. 三峡大学计算机与信息学院 宜昌 443002; 2. 国网宜昌供电公司 宜昌 443002)

**摘要:**当前配网低电压愈发严重,已经严重影响居民的日常生活,而维护工单反馈模糊,难以准确定位其原因。为了准确定位配网低电压的成因,提出一种基于多任务辅助学习的配网低电压成因分析模型。首先,获取低电压用户96点电流、电压等原始数据,并实现原始数据的预处理;其次,利用双向门控循环单元神经网络(bidirectional gated recurrent unit, BiGRU)挖掘数据的深度特征;最后,将引发配网低电压的主成因分析设置为主任务,子成因的分析作为相关辅助任务,利用相关辅助任务强化数据中隐藏特征学习,为主任务提供额外的监督信息,并采用多任务联合训练方式训练主成因分析模型,协助模型学习到更具鲁棒性的特征表示,提高配网低电压成因分析的准确率。实验结果表明,提出的基于多任务辅助学习的配网低电压成因分析模型具有较好的分析定位能力,最终分类准确率可达95.58%。

**关键词:**配网低电压;双向门控神经网络;多任务学习;辅助学习;联合训练

**中图分类号:** TN06 **文献标识码:** A **国家标准学科分类代码:** 510.99

## Analysis on the causes of low voltage in distribution network based on multi-task assisted learning

Fan Liping<sup>1,2</sup> Zhu Qing<sup>1</sup> Li Huangqiang<sup>2</sup> Du Fengyi<sup>2</sup> Huang Yu<sup>2</sup> Liu Yunfei<sup>2</sup> Wang Dongjuan<sup>1</sup>  
(1. College of Computer and Information, China Three Gorges University, Yichang 443002, China;  
2. State Grid Yichang Electric Power Supply Company, Yichang 443002, China)

**Abstract:** The current low voltage(LV) in the distribution network is becoming more and more serious, which seriously affects the daily life of residents, and the feedback of maintenance work orders is vague and unable to accurately locate the cause. In order to solve this problem, a LV cause analysis model based on multi-task assisted learning is proposed in the paper. Firstly, raw data such as current and voltage at 96 points of the LV users are obtained, and the pre-processing of raw data is achieved. Secondly, the deep features of the data are mined by using bidirectional gated recurrent unit (BiGRU) neural network, at the same time, the analysis of the main cause of LV is set as the main task, and the analysis of sub-causes is set as the auxiliary tasks, and which are used to strengthen the learning of hidden features in the data and provide additional supervisory information for the main task. Multi-task joint training is used to train the main cause analysis model, assist the model to learn more robust feature representations and improve the accuracy of LV cause analysis. The experimental results show that the LV causal analysis model based on multi-task assisted learning proposed in this paper has better analysis and localization ability, and the final classification accuracy can reach 95.58%.

**Keywords:** low voltage in distribution network; BiGRU; multi-task learning; assisted learning; joint training

### 0 引言

近年来,随着生活质量的不断提高,各种生活电器设备也在不断增加,许多地区的用电负荷呈骤增态势,出现配网低电压的情况愈发严重,与此同时,配网低电压的出现不仅影响照明设备的正常使用,更是缩短了照明设备和

电动机的寿命,造成工业产品质量下降及设备损坏<sup>[1]</sup>。而因负荷骤增、配电设备、线路残旧等问题综合导致的配网低电压,成因较为复杂,人工无法高效分析原因<sup>[2]</sup>。因此,为了准确有效的分析配网低电压的原因,减少出现配网低电压的情况,急需一种高效的配网低电压成因分析方法。

目前,许多学者在配网低电压成因分析领域展开了广

泛的研究,并得到了引发配网低电压现象的主要原因有电源点布局不合理、三相负载不平衡、台区出口侧配网低电压、配变过载、无功补偿不合理、低压供电半径过长、线路路径过细、10 kV 线路电压降低、季节性负荷变化等<sup>[3-8]</sup>。尽管这些学者得到了引起配网低电压的种种原因,然而,精准有效地分析定位配网低电压的原因还是比较困难。

为了准确得到配网低电压的成因,吴栋梁<sup>[9]</sup>利用特征识别的方法判断造成台区出口配网低电压的原因。王靖茗等<sup>[10]</sup>提出了一种基于 HPLC 台区的配网低电压分析与治理的方法,通过分析台区居民用户 24 点采集的电压、电流数据及相位信息,从而判断配网低电压的原因。李祖瑜<sup>[11]</sup>提出了一种基于敏感性分析的低电压成因探讨方法,通过对影响用户电压质量的主要因素进行敏感性分析,得到引起低电压现象的主要原因。郑金鑫等<sup>[12]</sup>利用大数据挖掘技术,构建基于分布参数的电压损耗模型,并运用 SPSS 软件进行多元线性回归分析,进而判断产生配网低电压的原因。

尽管以上研究取得了一些成果,但是在特征提取部分,传统算法对特征挖掘不充分,对配网低电压数据的时序数据信息利用不足;缺乏考虑原因之间的关联性,没有充分学习原因间的关联特征,模型过拟合严重,泛化能力一般,准确率较低。针对以上问题,本文结合深度学习强大的特征提取能力和多任务学习对不同任务相关信息挖掘的优势,提出了基于多任务辅助学习的配网低电压成因分析模型。该模型以双向门控循环单元神经网络(bidirectional gated recurrent unit, BiGRU)作为基础共享层,以深度提取配网低电压数据特征。同时,本文将主要关注引发配网低电压的主要原因分析,将引发配网低电压的主成因分析作为主任务,将子成因分析设定为相关的辅助任务。通过引入相关的辅助任务,强化对数据中潜在特征的学习,为主任务提供额外的监督信息,并采用多任务联合训练的方法训练模型,以协助模型学习更为鲁棒的特征表示。最终,在顶层输出层生成对配网低电压原因的准确诊断结果,实现对配网低电压成因的准确诊断。

## 1 相关理论

### 1.1 门控循环单元(GRU)

GRU 是循环神经网络的一种,其遵循时序规则提取数据特征,能够有效地挖掘时序数据的特征<sup>[13]</sup>。GRU 与传统的循环神经网络的主要区别在于其内部支持隐藏状态的门控机制,这一机制能够决定何时更新和重置隐藏状态,具备可学习性,有助于有效解决循环神经网络中出现的梯度消失或梯度爆炸问题。GRU 的基本结构如图 1 所示。

其中,  $X_t$  表示时间步  $t$  的输入,  $H_{t-1}$  表示时间步  $t-1$  的隐藏状态,  $H_t$  表示时间步  $t$  的隐藏状态,  $\tilde{H}_t$  表示时间步

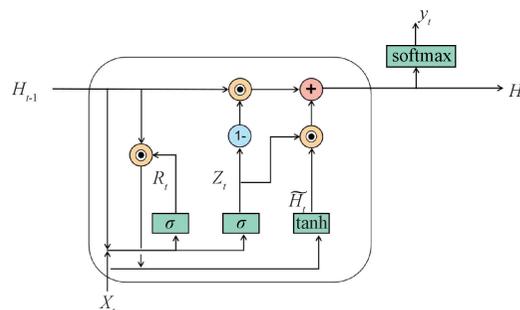


图 1 GRU 的基本结构

Fig. 1 The basic structure of the GRU

$t$  的候选隐状态,  $y_t$  是时间步  $t$  的输出,  $R_t$  表示重置门,  $Z_t$  表示更新门,  $\sigma$  表示 sigmoid 函数,  $\tanh$  表示双曲正切函数,  $\text{softmax}$  是输出层的激活函数。

### 1.2 BiGRU

GRU 能够挖掘数据的时序特征,但未能充分利用时序数据的双向信息<sup>[14]</sup>。BiGRU 是 GRU 的一种扩展形式,由前向 GRU 和反向 GRU 组合而成,通过利用两个方向的时序信息,能够有效捕获时序数据中的时序关系以及数据中多变量之间的相互影响,能有效解决 GRU 只采用单向数据信息的不足,在实际的应用中取得了不错的效果。BiGRU 神经网络的结构,如图 2 所示。

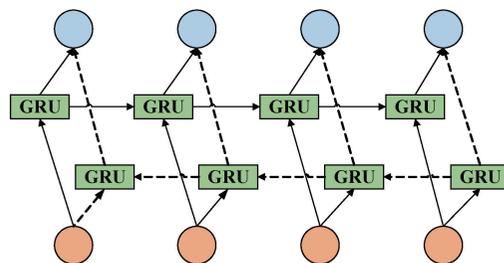


图 2 BiGRU 神经网络的基本结构

Fig. 2 The basic structure of a BiGRU neural network

实线和虚线分别表示前向 GRU 和反向 GRU 的计算过程。

### 1.3 多任务学习

目前大部分相关研究采用单任务学习模式<sup>[15]</sup>,分析定位配网低电压的原因。而实际情况下,不同原因之间存在隐式触发机制,一种原因的出现会引起其他原因的产生,原因之间存在关联特征<sup>[16]</sup>,仅利用单任务学习模式不仅无法有效挖掘不同原因之间的关联特征,无法共享领域相关信息,而且会放大显著特征的影响,影响模型的泛化能力<sup>[17]</sup>,致使原因定位不准确。多任务学习(multitask learning, MTL)是一种能够同时学习多个相关任务的深度学习算法<sup>[18]</sup>,不同的任务能够在学习过程中相互分享相关信息,通过利用任务之间的相关信息提高模型在任务上的泛化能<sup>[19]</sup>。多任务学习有很多种实现方式,比如

设置辅助任务、联合学习等<sup>[20]</sup>。

MTL 是一种基于共享机制的学习范式<sup>[21]</sup>,如何有效的设计共享机制也是多任务学习研究的重点。目前,硬共享机制是多任务学习中最常用的网络结构<sup>[22]</sup>,其结构如图 3 所示。通过共享隐藏层,提取不同任务之间的相关信息,并针对不同任务设计特有的分类器,能够有效地降低模型过拟合的风险。

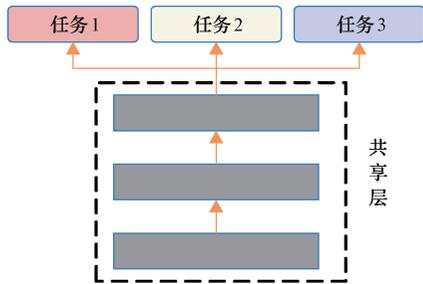


图 3 硬共享机制示意图

Fig. 3 Schematic diagram of the hard sharing mechanism

多任务学习之所以有较好的效果原因如下<sup>[23-24]</sup>:1)多任务学习为不同的相关任务进行了隐式的数据增强,对单个任务的数据规模进行了扩充;2)多任务学习能有效降低

模型过拟合的风险,因为多任务学习需要同时满足不同的相关任务,对模型有正则化的作用,降低了模型过拟合的风险;3)多任务学习能使模型更加专注于学习与任务相关的信息;4)多任务学习有助于模型挖掘更优的数据特征。

## 2 基于多任务辅助学习的配网低电压成因分析模型

目前,配网低电压数据量大且零散,通过人工方式提取数据特征的工作量过于庞大,且无法精准提取数据的有效特征,同时,现有研究较少考虑特征之间的关联,从而导致分析定位能力较差,难以精准定位配网低电压的具体原因。为了更准确地分析定位配网低电压成因,本文提出了一种基于多任务辅助学习的配网低电压成因分析模型,其整体结构如图 4 所示。该模型主要有输入层、BiGRU 共享层及多任务辅助训练层等 3 个部分组成,而多任务辅助训练层又被分为全连接层、任务层等两个部分。其中,输入层通过数据匹配和数据预处理操作,生成配网低电压数据集;BiGRU 共享层使用由 GRU 组成的 BiGRU 神经网络从配网低电压数据中挖掘数据的双向时序特征;全连接层根据不同任务的特性,进行样本特征重构;任务层则是各任务利用重构后的样本特征对配网低电压成因进行识别。

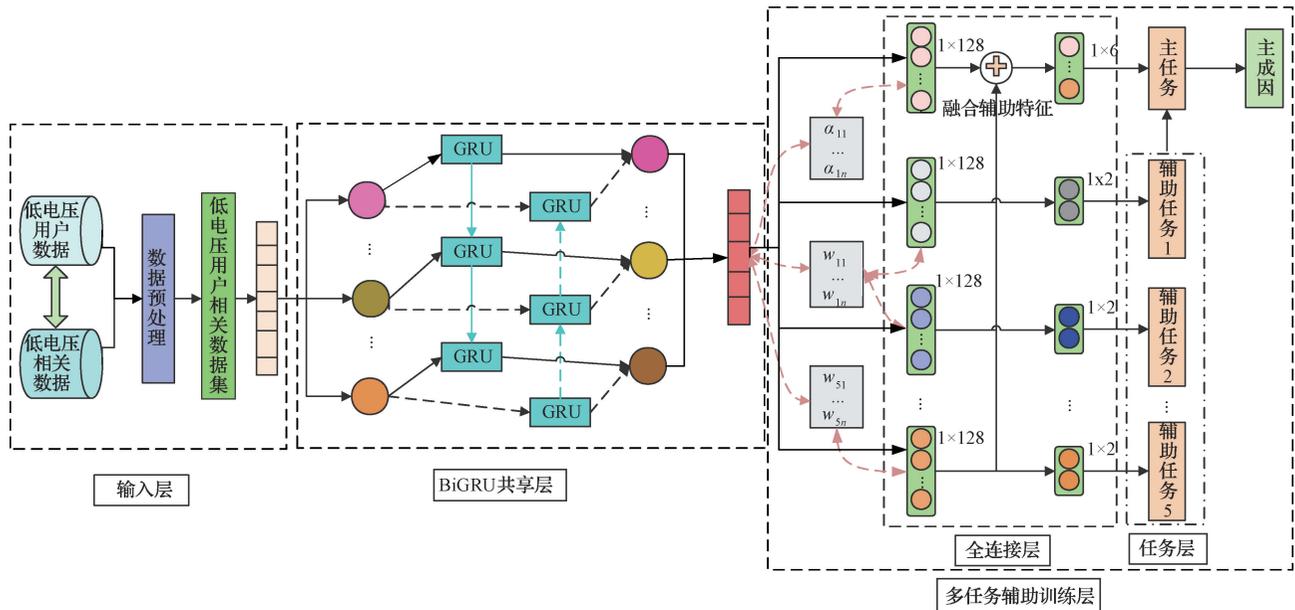


图 4 基于多任务辅助学习的配网低电压成因分析模型结构

Fig. 4 The structure of the low-voltage genesis analysis model of distribution network based on multi-task assisted learning

### 2.1 输入层

由于配网低电压用户数据和配网低电压相关数据是两个独立的数据集,无法直接作为模型的输入。本文利用配网低电压用户数据,对配网低电压相关数据中的电流、电压等数据进行关联操作。与此同时,关联之后的数据中存在数值缺失、单位不统一等问题,为了确保数据的完整性和一致性,对部分数据缺失的样本进行 0 值填充以及对

单位不统一的样本数据进行单位统一等预处理操作,将数据转化成适用于本文神经网络的数据形式,经过预处理后的数据会作为模型的输入  $\mathbf{X}$ , 设序列为  $n$  的输入数据  $\mathbf{X} = [x_1, x_2, x_3, \dots, x_n]$ 。

### 2.2 BiGRU 共享层

经过输入层处理后的数据  $X$ , 将作为 BiGRU 共享层的输入,数据进入 BiGRU 共享层之后,将分别输送到正向

GRU 神经元和反向 GRU 神经元中,先经过 GRU 中的重置门和更新门,利用配网低电压数据样本在当前时间步  $t$  的时序特征  $X_t$  和上一个时间步  $t-1$  的隐藏状态  $H_{t-1}$ ,得到保留部分隐藏状态  $H_{t-1}$  后的重置特征  $R_t$  以及替换部分当前状态  $X_t$  后的更新特征  $Z_t$  如下:

$$R_t = \sigma(X_t W_{xr} + H_{t-1} W_{hr} + b_r) \quad (1)$$

$$Z_t = \sigma(X_t W_{xz} + H_{t-1} W_{hz} + b_z) \quad (2)$$

式中:  $W_{xr}$ 、 $W_{hr}$ 、 $W_{xz}$  及  $W_{hz}$  代表权重矩阵;  $b_z$  和  $b_r$  是偏置。

其次,重置特征  $R_t$  和更新特征  $Z_t$  再结合上一个时间步  $t-1$  的隐藏状态  $H_{t-1}$ ,得到配网低电压数据样本时间步  $t$  的候选隐藏信息  $\tilde{H}_t$ ,与此同时,将配网低电压数据样本在时间步  $t$  的重置特征  $R_t$ 、更新特征  $Z_t$  及候选隐藏信息  $\tilde{H}_t$  进行整合操作,得到配网低电压数据样本在时间步  $t$  的时序特征  $H_t$ ,最后,将前向 GRU 神经元和反向 GRU 神经元计算得到的时序特征  $\vec{H}_t$  和  $\overleftarrow{H}_t$  合并,得到配网低电压数据样本最终的双向时序特征  $\vec{H}$  为:

$$\tilde{H}_t = \tanh(X_t W_{xh} + (R_t \odot H_{t-1}) W_{hh} + b_h) \quad (3)$$

$$H_t = Z_t \odot H_{t-1} + (1 - Z_t) \odot \tilde{H}_t \quad (4)$$

$$\vec{H} = \vec{H}_t \parallel \overleftarrow{H}_t \quad (5)$$

式中:  $W_{xh}$ 、 $W_{hh}$  代表权重矩阵;  $b_h$  是偏置;  $\odot$  表示向量间的点乘;  $\vec{H}_t$ 、 $\overleftarrow{H}_t$  分别代表前向 GRU 神经元和反向 GRU 神经元计算得到的时序特征。

### 2.3 多任务辅助训练层

为了挖掘并学习配网低电压样本在不同任务场景中的细节和关联信息,捕获各原因间的关联特征,模型设置了 5 个辅助任务,通过利用不同任务对特征挖掘的差异性,能够有效学习不同方向的特征,增强模型对不同数据分布、局部区域、全局区域的关注度,并通过融合辅助特征丰富主任务特征的语义信息,帮助提高主任务的泛化能力。各任务详情如表 1 所示。

表 1 任务详情  
Table 1 Mission details

任务	任务描述
主任务	获得引起配网低电压的 5 种原因(台区出口侧配网低电压、无功补偿不足、三相电流不平衡、配变过载、配变重载)的主成因
辅助任务 1	获得由台区出口侧配网低电压引起配网低电压的概率
辅助任务 2	获得由无功补偿不足引起配网低电压的概率
辅助任务 3	获得由三相电流不平衡引起配网低电压的概率
辅助任务 4	获得由配变过载引起配网低电压的概率
辅助任务 5	获得由配变重载引起配网低电压的概率

从 BiGRU 共享层学习的双向时序特征  $\vec{H}$  在全连接层中对主任务进行辅助特征融合和降维运算,对子任务进

行降维运算,如下式:

$$\vec{h}_t^i = W_1 \vec{H}_t + b_1 \quad (6)$$

$$\vec{h}_t^M = \frac{\sum_{i=1}^n \vec{h}_t^i}{n} \quad (7)$$

式中:  $W_1$  代表双向时序特征  $\vec{H}_t$  的权重矩阵;  $\vec{h}_t^i$  代表降维后的时序特征;  $\vec{h}_t^M$  代表主任务融合辅助特征后的时序特征;  $b_1$  是偏置;  $n$  代表任务总数。

经过全连接层运算后的双向时序特征将作为任务层的输入,并在任务层中利用 softmax 激活函数,计算降维后配网低电压数据特征类别概率分布  $y_t$ ,并对  $y_t$  进行最大值的下标取值操作,得到预测结果  $y_{predict}$  如下:

$$y_t = \text{softmax}(W_2 \vec{h}_t^M + b_2) \quad (8)$$

$$y_{predict} = \text{argmax}(y_t) \quad (9)$$

式中:  $W_2$  代表双向时序特征  $\vec{h}_t^M$  的权重矩阵;  $b_2$  是偏置。

得到预测结果  $y_{predict}$  之后,将利用交叉熵损失函数<sup>[25]</sup>计算主任务和各子任务的预测结果  $y_{predict}$  与真实结果  $y_{true}$  之间的误差  $Loss_i$ ,并根据主任务和各子任务的损失权重  $W_i$ ,对主任务和各子任务的损失加权求和,计算模型的整体损失 TotalLoss,在 TotalLoss 反向传播过程中,各任务的全连接网络会与 BiGRU 共享层之间进行参数交互,共同优化模型参数,寻求模型最优解,促使模型学习更好的表征如下:

$$Loss_i = - \sum_{k=1}^n \sum_{p=1}^C y_{k,p} \log(\hat{y}_{k,p}) \quad (10)$$

$$TotalLoss = \sum_i^N W_i Loss_i \quad (11)$$

式中:  $k$  代表样本索引;  $n$  代表样本总数;  $N$  代表任务总数;  $i$  代表任务索引;  $C$  为类别总数;  $y_{k,p}$  和  $\hat{y}_{k,p}$  分别代表第  $k$  个样本属于第  $p$  类的标记值和预测值。

## 3 实验及分析

### 3.1 数据集及数据预处理

实验使用的数据来自于某市电网获取的配网低电压数据集,该数据集共收集了用户 96 点电流、电压、负荷等数据,共 17 354 条。该数据集存在部分数据缺失、数值异常及数值单位不统一等问题,导致原始数据的质量不高,无法直接使用。通过对原始数据进行缺失数据填充、异常数值替换及单位统一等操作,构建了用于本实验的无标签原始数据集。

由于原始数据的局限性,本实验仅针对台区出口侧配网低电压、配变重载、配变过载、无功补偿不足、三相电流不平衡等 5 种原因进行分析。此外,为了解决原始数据集无标签的问题,通过查阅相关资料,对无标签数据进行标注,建立适用于文中实验的配网低电压数据集,标注规则详见附录。数据样例、数据分布情况及主任务标签匹配情况如表 2~4 所示。

表2 数据样例

Table 2 Sample data

名称	特征
最低的电压	191.7
出口侧电压	219
变压器的视在功率	7.6
A相电流	4.1
B相电流	8.9
C相电流	20.9
变压器的总功率因数	0.9
变压器的额定容量	100
CT变比	30
MTL、AuxT1L、AuxT2L、AuxT3L、 AuxT4L、AuxT5L	2、0、0、1、0、0

注: MTL代表主任务的标签, AuxT1L~AuxT5L分别代表辅助任务1~5的标签, 辅助任务是二分类任务, 标签为0或1

### 3.2 实验环境及超参设置

实验使用 12th Gen Intel(R) Core(TM) i7-12700 2.10 GHz 处理器, NVIDIA RTX 2080Ti 显卡, 在 Anaconda(基于 python3.8) 环境下进行。同时, 将数据集的 80% 划分为训练集, 20% 划分为验证集, BiGRU 的层数设置为 4 层, 每层 128 个神经元, 使用 Adam 优化更新网络参数, 初始学习率为 0.001, 训练轮数为 500 轮。

### 3.3 评价指标

由表 3 可知, 5 种原因的数据占比分布非常不平衡。评估指标只采用准确率(accuracy)是不可靠的, 因此实验又加入了精确率(precision), 综合指标 F1-score 及召回率(recall)等适用于数据分布不平衡情况的评估指标<sup>[15]</sup>, 用来综合评估模型分析定位引发配网低电压原因的能力。

$$Accuracy = \frac{TP + TN}{TP + FN + FP + TN} \times 100\% \quad (12)$$

$$Precision = \frac{TP}{TP + FP} \times 100\% \quad (13)$$

$$Recall = \frac{TP}{TP + FN} \times 100\% \quad (14)$$

$$F1-score = \frac{2Precision \cdot Recall}{Precision + Recall} \times 100\% \quad (15)$$

表3 数据分布情况

Table 3 Data distribution

原因	台区出口侧配网低电压	无功补偿不足	三相负荷不平衡	配变重载	配变过载	其他原因
数据占比	295	35	12 460	1 440	1 319	1 805

表4 主任务标签匹配情况

Table 4 The main task tag match

原因	台区出口侧配网低电压	无功补偿不足	三相负荷不平衡	配变重载	配变过载	其他原因
标签	0	1	2	3	4	5

式中: Accuracy 表示被正确分类的样本总数占总样本数的比例; Precision 表示真正样本占预测为正样本的比例; Recall 表示正样本被正确分类的样本总数占正样本总数的比例; F1-score 是 Precision 和 Recall 的调和平均, 越趋近于 1 表示分类的综合性能越好。

### 3.4 实验与结果分析

#### 1) 损失占比分析

为促进模型更好地理解任务之间的关联性、平衡各任务对模型的影响, 并提升模型性能, 对比了各任务在不同损失占比情况下模型的性能, 结果如表 5 所示。

表5 损失占比对模型性能的影响

Table 5 The impact of the loss percentage on the performance of the model

MT	T1	T2	T3	T4	T5	准确率/%	精确率/%	召回率/%	F1-score/%
0.90	0.02	0.02	0.02	0.02	0.02	95.35	<b>95.37</b>	95.35	95.33
0.90	0.005	0.015	0.05	0.01	0.02	<b>95.58</b>	95.31	<b>95.58</b>	<b>95.41</b>
0.90	0.01	0.01	0.06	0.01	0.01	95.38	95.27	95.38	95.31
0.95	0.01	0.01	0.01	0.01	0.01	95.55	95.17	95.55	95.31
0.80	0.04	0.04	0.04	0.04	0.04	94.46	94.31	94.46	94.35
0.80	0.03	0.03	0.08	0.03	0.03	94.23	94.25	94.23	94.23
0.80	0.02	0.04	0.07	0.03	0.04	94.48	94.25	94.48	94.35
0.85	0.03	0.03	0.03	0.03	0.03	95.17	94.91	95.17	95.02

注: MT 代表主任务, T1~T5 代表辅助任务 1~5

由表 5 可知,当主任务的损失占比在 0.90 及以上时,模型的各项评估指标都很出色,都在 95% 以上,其中,当各辅助任务损失占比分别为 0.005、0.015、0.05、0.01、0.02 时,模型的准确率、召回率、F1-score 达到最高,分别为 95.58%、95.58%、95.41%;而当各辅助任务损失占比均为 0.02 时,模型的精确度比第 2 行的精确度高 0.06%,高达 95.37%;而当主任务的损失占比在 0.80~0.90 时,模型的性能出现了轻微的波动;当主任务和辅助任务的损失占比分别为 0.80、0.03、0.03、0.08、0.03、0.03 时,模型

的各项评估指标达到最低,相比最高值分别下降 1.35%、1.12%、1.35%、1.17%。出现这种情况,原因在于辅助任务损失占比偏多且各辅助任务的占比分配不合理,致使模型的性能下降。

2) 消融分析

针对本文提出的多任务辅助学习模块进行消融分析。通过实验对比添加辅助任务与不添加辅助任务的损失和准确率,每间隔 10 次记录一次损失值和准确率,结果如图 5 所示。

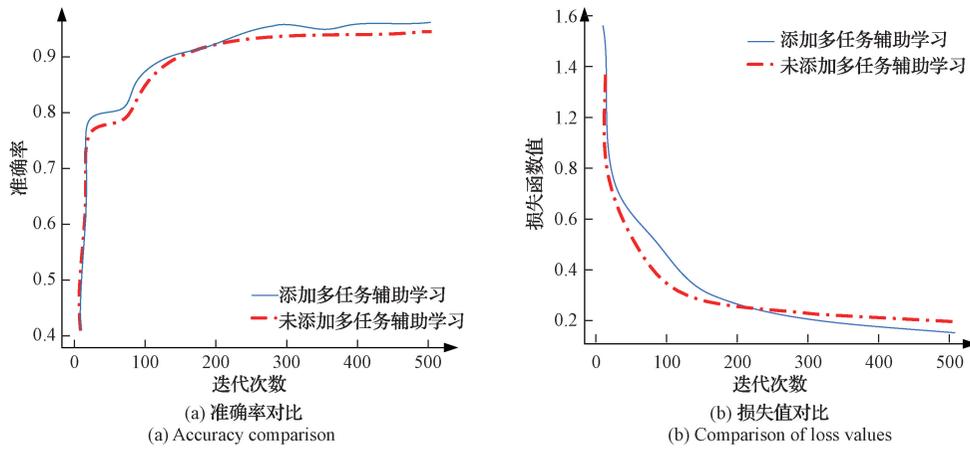


图 5 添加辅助任务与未添加辅助任务的准确率和损失  
Fig. 5 Accuracy and loss of added and no secondary tasks

由图 5(a)可以看出,模型在添加辅助任务的情况下,模型的准确率比未添加辅助任务的准确率整体偏高,且添加辅助任务的准确率最高可达 95.58%,未添加辅助任务的准确率只能达到 93.53%,相比提高了 2.05%;由图 5(b)可知,在前 200 轮的训练中,添加辅助任务的模型损失比未添加辅助任务的模型损失整体偏大,且损失下降速度相比较慢,而从 200 轮以后,添加辅助任务的模型损失比未添加辅助任务的模型损失普遍偏小,并且损失下降的速度比其更快。原因在于当模型未添加辅助任务时,模型所需提取的特征相对单一,前 200 轮的损失收敛速度较快,致使损失较低,而当模型添加辅助任务时,模型需要提取能够同时适应多个任务的特征,需要捕获各任务之间的关联特征,导致损失下降慢,损失偏高;而训练次数超过 200 次后,添加辅助任务的模型比未添加辅助任务的模型提取的特征更好,模型的损失更低,下降的更快。以上结果也证实了多任务辅助学习的有效性。

此外还将本文提出的模型分别与 BiLSTM、CNN、GA-SVM、Transformer、BiLSTM-Attention、Bi-LSTMA-CNNA 及基于自注意力机制的深度学习模型<sup>[26-29]</sup> 7 种分类模型进行对比实验,得到的模型分类结果如表 6 所示。

由表 6 可以看出,本文模型分类效果普遍高于其余 7 种分类模型。与分类效果最差的 CNN 模型相比,模型的准确率、精确率、召回率、F1-score 分别比 CNN 模型高

表 6 不同模型分类结果对比

Table 6 Comparison of classification results of different models (%)

模型	准确率	精确率	召回率	F1-score
CNN	84.17	82.77	84.17	82.15
BiLSTM	93.42	93.20	93.42	93.29
GA-SVM	88.63	87.54	88.63	87.71
Transformer	90.16	90.09	90.16	90.12
BiLSTM-Attention	93.45	93.16	93.45	93.23
Bi-LSTMA-CNNA	91.49	90.81	91.49	91.21
自注意力机制	92.18	92.09	92.18	92.13
本文	95.58	95.31	95.58	95.41

11.41%、12.54%、11.41%、13.26%,表明本文模型能有效学习蕴藏在数据中的时间依赖关系;而与 BiLSTM-Attention 模型相比,本文模型的准确率、精确率、召回率、F1-score 分别比 BiLSTM-Attention 模型高 2.13%、2.15%、2.13%、2.18%,表明 BiGRU 神经网络不仅能充分挖掘数据中的双向时序特征,而且门控机制能有效保留蕴藏在数据中重要的时序信息,其次,多任务辅助学习进一步增强了关联特征学习,为主任务提供额外的特征,两者有机结合,从整体上增强了模型的分析定位能力。

#### 4 结论

本文提出了基于多任务辅助学习的配网低电压成因分析方法,将 BiGRU 与多任务学习有机结合,充分利用了 BiGRU 在时序信息捕获方面的能力和多任务学习中信息共享及关联关系学习的优势。结果表明,该方法能够有效的挖掘数据中蕴含的时序特征,并且通过多任务辅助学习能进一步提高模型的准确率,抑制过拟合,相比现有的一些分类模型具有更好的泛化能力,面对复杂的电力数据能有效定位引发配网低电压的原因,给相关部门提供更加精准的结果。然而,本文所识别的配网低电压成因仅是单原因,未来将深入研究,在已有模型的基础上进行改进,实现配网低电压成因的多原因识别,以提高该方法的实用性。

#### 参考文献

- [1] 夏得青, 向星宇, 李宽龙, 等. 农村配电网低电压治理研究进展[J]. 电气技术, 2023, 24(6): 1-5.  
XIA D Q, XIANG X Y, LI K L, et al. Research progress on low voltage governance in rural distribution networks [J]. Electrical Engineering, 2023, 24(6): 1-5.
- [2] 王小虎, 戴乔旭. 低电压问题成因分析及措施制定系统的设计[J]. 机电工程技术, 2022, 51(12): 238-240, 256.  
WANG X H, DAI Q X. Analysis of causes of low voltage problems and design of measure-making system [J]. Mechanical & Electrical Engineering Technology, 2022, 51(12): 238-240, 256.
- [3] 谢峥, 杨楠, 刘钊, 等. 考虑不确定性和安全效能成本的配电网低电压综合治理方法[J]. 电力系统保护与控制, 2020, 48(9): 36-48.  
XIE ZH, YNAG N, LIU ZH, et al. Low voltage comprehensive management method of a distribution network considering the uncertainty and safety efficiency cost [J]. Power System Protection and Control, 2020, 48(9): 36-48.
- [4] 孟晓芳, 王俊, 王英男, 等. 计及分布式电源局部调压能力的 10 kV 配电网低电压治理方法[J]. 电力系统保护与控制, 2019, 47(10): 65-72.  
MENG X F, WANG J, WANG Y N, et al. Low-voltage control method for 10 kV distribution network considering distributed generation capability of local voltage regulation[J]. Power System Protection and Control, 2019, 47(10): 65-72.
- [5] 胡翔, 邵叶晨, 雷超, 等. 计及电压不可行节点的配电网低电压治理方法[J]. 电力系统保护与控制, 2017, 45(13): 102-109.  
HU X, SHAO Y CH, LEI CH, et al. A solution method for low voltage problem in distribution network considering voltage-violated buses[J]. Power System Protection and Control, 2017, 45(13): 102-109.
- [6] 陆伟明, 吕梦丽. 台区低电压问题分析及其解决措施[J]. 电工技术, 2019(24): 60-61, 64.  
LU W M, LYU M L. Analysis and solutions of low voltage problem in substation area [J]. Electric Engineering, 2019(24): 60-61, 64.
- [7] 林跃欢, 黄彦璐, 田兵, 等. 配电网低电压治理方案动态评价方法研究[J]. 电测与仪表, 2023, 60(6): 74-80.  
LIN Y H, HUANG Y L, TIAN B, et al. Research on dynamic evaluation method of low-voltage governance scheme in distribution network [J]. Electrical Measurement & Instrumentation, 2023, 60(6): 74-80.
- [8] 李兰芳, 李鑫, 黄嘉健, 等. 基于前推回代法的低电压台区成因数据分析[J]. 机电信息, 2018(12): 1-3.  
LI L F, LI X, HUANG J J, et al. Analysis of the genesis data of low voltage stations based on the push-back generation method[J]. Mechanical and Electrical Information, 2018(12): 1-3.
- [9] 吴栋梁. 基于特征识别的台区出口低电压成因诊断模型[J]. 安徽电力, 2018(3): 4.  
WU D L. Diagnostic model of low voltage at outlet of station area based on feature recognition[J]. Anhui Electric Power, 2018(3): 4.
- [10] 王靖茗, 刘和迪, 刘演. 基于 HPLC 台区的低电压分析与治理方法[J]. 大众用电, 2022, 37(2): 48-49.  
WANG J M, LIU H D, LIU Y. Low voltage analysis and treatment method based on HPLC station area[J]. Popular Utilization of Electricity, 2022, 37(2): 48-49.
- [11] 李祖瑜. 基于敏感性分析的低电压成因探讨[J]. 电工技术, 2022(17): 58-60.  
LI Z Y. Discussion on causes of low voltage based on sensitivity analysis [J]. Electric Engineering, 2022(17): 58-60.
- [12] 郑金鑫, 高顿. 基于数据挖掘的配电网低电压成因分析[J]. 电工材料, 2023(2): 63-67.  
ZHENG J X, GAO D. Analysis of cause of low voltage

- in distribution network based on data mining[J]. *Electrical Engineering Materials*, 2023(2): 63-67.
- [13] 张心成,李翔晟,李藏龙,等. 基于改进 GRU 模型算法的锂电池 SOC 估计[J]. *电子测量技术*, 2023, 46(11): 57-65.
- ZHANG X CH, LI X SH, LI C L, et al. SOC estimation of lithium battery based on improved gated recurrent unit model algorithm [J]. *Electronic Measurement Technology*, 2023, 46(11): 57-65.
- [14] 孙坤,尹晓红. 基于数据去噪和 CNN-BiGRU 的 SO<sub>2</sub> 排放预测[J]. *电子测量技术*, 2023, 46(13): 66-72.
- SUN K, YIN X H. SO<sub>2</sub> emission prediction based on data denoising and CNN-BiGRU [J]. *Electronic Measurement Technology*, 2023, 46(13): 66-72.
- [15] 欧阳金鑫,张澳归,蒋航,等. 基于深度置信网络的电网安全稳定控制系统故障诊断方法[J]. *电测与仪表*, 2024,61(7):1-6.
- OUYANG J X, ZHAMG AO G, JIANG H, et al. Fault diagnosis method of power grid security and stability control system based on deep belief network [J]. *Electrical Measurement & Instrumentation*, 2024, 61(7):1-6.
- [16] CHEN J, ZHU D Y, SHEN X Q, et al. MiniGPT-v2: Large language model as a unified interface for vision-language multi-task learning [J]. *ArXiv preprint arXiv:2310.09478*, 2023.
- [17] LIU Y J, LU Y N, LIU H, et al. Hierarchical prompt learning for multi-task learning[C]. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2023.
- [18] UPADHYAY R, PHLIPO R, SAINI R, et al. Sharing to learn and learning to share: Fitting together meta-learning, multi-task learning, and transfer learning: A meta review [J]. *ArXiv preprint arXiv: 2111. 12146*, 2021.
- [19] 王伟,李开成,许立武,等. 基于一维卷积神经网络多任务学习的电能质量扰动识别方法[J]. *电测与仪表*, 2022, 59(3): 18-25.
- WANG W, LI K CH, XU L W, et al. Power quality disturbance recognition method based on multi-task learning and one-dimensional convolutional neural network[J]. *Electrical Measurement & Instrumentation*, 2022, 59(3): 18-25.
- [20] LIU Z T, LIU Q Q, CHEN J H, et al. Enhancing deep knowledge tracing with auxiliary tasks [C]. *Proceedings of the ACM Web Conference*, 2023.
- [21] ZHANG Y, QIANG Y. A survey on multi-task learning[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2021, 34(12): 5586-5609.
- [22] 李红光,王菲,丁文锐. 面向目标分类识别的多任务学习算法综述[J]. *航空学报*, 2022, 43(1): 24889.
- LI H G, WANG F, DING W R. A review of multi-task learning algorithms for object classification and recognition [J]. *Acta Aeronautica et Astronautica Sinica*, 2022, 43(1): 24889.
- [23] 常兴亚,武云鹤,陈东岳,等. 基于多任务学习的视频异常检测方法[J]. *仪器仪表学报*, 2023, 44(8): 21-29.
- CHANG X Y, WU Y H, CHEN D Y, et al. Video anomaly detection method based on multi task learning[J]. *Chinese Journal of Scientific Instrument*, 2023, 44(8): 21-29.
- [24] 谢平,胡锦城,江国乾,等. 基于多任务学习的快速序列视觉呈现脑电图分类[J]. *仪器仪表学报*, 2023, 44(11): 215-223.
- XIE P, HU J CH, JINAG G Q, et al. Classification of rapid serial visual presentation based EEG with multi-task learning[J]. *Chinese Journal of Scientific Instrument*, 2023, 44(11): 215-223.
- [25] 黄庆康,宋恺涛,陆建峰. 应用于不平衡多分类问题的损失平衡函数[J]. *智能系统学报*, 2019, 14(5): 953-958.
- HUANG Q K, SONG K T, LU J F. Application of the loss balance function to the imbalanced multi-classification problems [J]. *CAAI Transactions on Intelligent Systems*, 2019, 14(5): 953-958.
- [26] 冯治国,金日,罗冲,等. 基于 Transformer 神经网络的变压器状态监测[J]. *国外电子测量技术*, 2023, 42(2): 145-150.
- FENG ZH G, JIN R, LUO CH, et al. Power transformer state monitoring based on transformer deep neural network [J]. *Foreign Electronic Measurement Technology*, 2023, 42(2): 145-150.
- [27] 王雷,何坤,李宗帅,等. 基于 BiLSTM-Attention 的迁移学习变工况故障识别方法研究[J]. *电子测量与仪器学报*, 2023, 37(7): 205-212.
- WANG L, HE K, LI Z SH, et al. Transfer learning based on BiLSTM-Attention research on fault identification methods for variable operating conditions [J]. *Journal of Electronic Measurement*

- and Instrumentation, 2023, 37(7): 205-212.
- [28] 占妮. 基于 Bi-LSTMA-CNNA 的线上评论情感分析模型[J]. 电子测量技术, 2021, 44(3): 83-86.  
ZHAN N. Online comment sentiment analysis based on Bi-LSTMA-CNNA [J]. Electronic Measurement Technology, 2021, 44(3): 83-86.
- [29] 杨东儒, 魏建文, 林雄威, 等. 基于自注意力机制的深度学习模拟电路故障诊断[J]. 仪器仪表学报, 2023, 44(3): 128-136.  
YANG D R, WEI J W, LIN X W, et al. A fault diagnosis algorithm for analog circuits based on self-attention mechanism deep learning [J]. Chinese

Journal of Scientific Instrument, 2023, 44(3): 128-136.

#### 作者简介

范李平, 硕士, 高级工程师, 主要研究方向为配网低电压大数据分析。

E-mail: 184948938@qq.com

朱庆, 硕士研究生, 主要研究方向为低电压原因分析。

E-mail: 2974142573@qq.com

王东娟(通信作者), 博士, 副教授, 主要研究方向为电力大数据应用技术。

E-mail: wdj@ctgu.edu.cn