

# 基于 Attention 机制的 CNN-GRU 配网线路重过载短期预测方法

杨 秀<sup>1</sup>, 胡钟毓<sup>1</sup>, 田英杰<sup>2</sup>, 谢海宁<sup>2</sup>, 陈文涛<sup>3</sup>

(1. 上海电力大学电气工程学院, 上海 200090; 2. 国网上海市电力公司电力科学研究院, 上海 200080;  
3. 国网新疆电力有限公司电力科学研究院, 新疆 乌鲁木齐 830002)

**摘 要:**随着用户用电需求增加, 迎峰度夏期间配网线路重过载较严重, 为电网运行增加安全隐患。实现配网线路重过载短期预测, 对合理安排负荷高峰时期运行方式和调度管理以及线路的安全运行具有重要意义。文中提出一种基于注意力(Attention)机制的卷积神经网络(CNN)—门限循环单元神经网络(GRU)组合预测模型。结合高相关性时间段的历史线路负载率数据和气象因素作为输入特征, 利用 CNN 处理多源数据并提取有效特征作为 GRU 的输入, 再通过 GRU 对时序特征集进行分析预测, 利用 Attention 机制对重要数据分配更多的注意力权重, 实现配网线路负载率的回归预测, 最后根据负载等级划分标准将负载率预测结果转化为负载等级。使用所提方法对上海市某区某 10 kV 线路数据进行实验。实验结果表明, 该预测方法比相同模型结构但以负载等级为输入的重过载分类预测, 更适用于配网线路重过载预测。

**关 键 词:**卷积神经网络; 注意力机制; 门限循环单元神经网络; 配网线路; 短期重过载预测

DOI: 10.19781/j.issn.1673-9140.2023.01.023 中图分类号: TM726 文章编号: 1673-9140(2023)01-0201-09

## Short-term heavy overload forecasting method of distribution net line based on CNN-GRU with Attention mechanism

YANG Xiu<sup>1</sup>, HU Zhongyu<sup>1</sup>, TIAN Yingjie<sup>2</sup>, XIE Haining<sup>2</sup>, CHEN Wentao<sup>3</sup>

(1. Electric Power Engineering of Shanghai University of Electric Power, Shanghai 200090, China; 2. State Grid Shanghai Electrical Power Research Institute, Shanghai 200080, China; 3. State Grid Xinjiang Electrical Power Research Institute, Urumqi 830002, China)

**Abstract:** With the increase of electricity demand, the heavy overload of distribution network lines during the peak period of electricity consumption becomes more serious, which increases the potential threats on the safety of grid operation. The short-term forecast of the heavy overload state of distribution lines is of great significance for rationally arranging the operation mode, for dispatch management, and for the safety operation of the line during peak load periods. This paper proposes a short-term forecast method for the heavy overload state of lines and a prediction model that CNN-GRU hybrid neural network with Attention mechanism. The historical load rate of lines with high auto-correlation and meteorological factors are combined as the input features, which is further used to extract the valid features by the CNN. The GRU neural network is utilized to analyze and predict time series data. By using the Attention mechanism to reassign corresponding weights, the load rate regression prediction result can be outputted, which can be finally converted into the load level

收稿日期: 2020-08-14; 修回日期: 2021-04-01

基金项目: 国家自然科学基金(51907114); 上海电力人工智能工程技术研究中心研究项目(19DZ2252800)

通信作者: 胡钟毓(1995—), 女, 硕士研究生, 主要从事电力大数据和人工智能技术研究; E-mail: huzhongyu@mail.shiep.edu.cn

according to the load level division standard. The method in this paper is performed on a 10kV line in a certain district of Shanghai. The experimental results show that this prediction method is more suitable for line heavy overload prediction than the method using the classification prediction model with the same model structure but with load level as input.

**Key words:** CNN; Attention mechanism; GRU; distribution net line; short-term heavy overload prediction

随着电网规模扩大和用户用电需求增加,夏季高温期和冬季低温期配网架空输电线路频繁出现线路电流长时间接近或大于线路最大允许载流运行情况,即迎峰度夏期间配网线路重过载较严重。温升是影响输电线路载流的重要因素,架空输电线路长时间重过载状态运行,在不利气象环境条件下,会导致线路温度持续增高,或长时间处于高温状态,从而降低线路机械强度,加快设备老化,为电网运行增加安全隐患<sup>[1-2]</sup>。

目前国内外在配网重过载方面的研究,多着眼于过载控制及缓解方法、在过载情景下电网连锁故障分析、输电线路过载风险评估分析<sup>[3-6]</sup>。国内外结合大数据预测线路重过载事件的研究较为匮乏。文献[3-5]利用潮流控制器或优化运行方案重新配置其网络拓扑,即将配电系统中因馈线故障、馈线过载问题引起的扩散效应降至最低。这些过载控制方法都基于实时监控传输线的线负载和变压器的负载,均是过载发生后采取补救措施,对电网运行维护没有事前提出预见性建议,不能将过载事件防患于未然。另外,配电网线路发生N-1意外事件时,极有可能造成其他线路重过载。文献[6]通过潮流计算模拟仿真电力系统发生N-1和N-2事件,预测相应情况下线路重过载量,以及重过载影响范围。以上研究均未考虑由于季节等因素导致用电侧正常用电负荷骤增造成的重过载事件。而配网线路众多,需要借助大数据和人工智能技术实现配网线路重过载预测。

随着电网信息化程度不断提高,在线监测装置等终端设备对电网运行数据的采集频率和数据准确性也不断提升,为电网运行特性分析和相关预测研究提供了高质量、海量化的数据集,为将深度学习应用于电网提供了数据基础<sup>[7]</sup>。电力短期负荷预测是国内外研究重点,目前基于灰色关联分析<sup>[8-9]</sup>、神经网络<sup>[10-13]</sup>、支持向量机<sup>[14]</sup>、决策树<sup>[15]</sup>、XGBoost<sup>[16-17]</sup>、高斯回归<sup>[18]</sup>等的机器学习方法应用取得了丰富的成果。而以上电力负荷预测方法多应用于市、县总

负荷中短期预测。线路重过载短期预测与总负荷短期预测的预测过程具有相似性,但线路重过载判断标准为单一数值。若预测结果落入线路重过载判断标准值邻域,易出现误判情况,故需要提出更精确的预测技术。

优化预测数据特征提取过程可以提高模型预测精度,文献[7-18]利用CNN有池化操作、局部连接以及权值共享等特性,经过训练有效地学习时间序列数据中的特征,作为后序预测部分神经网络的输入。结果发现CNN可以帮助模型提高负荷预测精度。CNN-GRU兼容适用于回归预测和分类预测,并且兼具快速收敛和有效特征的挖掘能力强的优点,目前已有研究将其应用于包括负荷预测<sup>[18-19]</sup>、情感分析<sup>[20]</sup>、文本分类<sup>[21]</sup>等对预测精度和速度均有较高要求的预测工作中。但已有研究缺少案例可用于研究对比CNN-GRU网络回归和分类预测的预测效果。

为了提高短期线路重过载预测精度,本文提出一种基于Attention机制的CNN-GRU混合神经网络模型的线路短期重过载预测方法。通过在CNN-GRU中增加Attention机制,对重要数据分配更多的注意力权重,可以增强神经网络学习时间序列长距离相互关系的能力<sup>[18, 22]</sup>。利用基于Attention机制的神经网络实现线路电流逐点预测,可以同时提高模型收敛速度和模型学习长距离特征的能力。它利用CNN处理多源数据提取有效特征,再通过GRU进行时序数据分析并利用Attention机制重新分配注意力权重,实现线路重过载预测。

本文以上海浦东某地区的一条10 kV线路数据作为样本进行预测。由于本文研究的线路重过载预测通过回归预测和分类预测均可实现,故以拥有较高准确率和较少低估率为其适用性评价标准,研究分析CNN-GRU-Attention网络回归和分类预测在重过载预测工作中的适用性。结果表明,CNN-GRU-Attention网络回归预测更适用于线路重

过载预测,有较高的预测准确率,且 CNN 和 Attention 机制有助于提高重过载预测效果(减少重过载等级低估情况)。

### 1 基于 Attention 机制的 CNN-GRU

#### 1.1 CNN-GRU 混合神经网络原理

CNN-GRU 混合神经网络由两部分组成:CNN 部分和 GRU 部分,如图 1 所示。其中 CNN 层能有效降低特征提取和数据重构的复杂程度,有池化操作、局部连接以及权值共享等特性,适用于处理时序数据的特征提取。时间序列数据直接作为 CNN 层输入,通过卷积层实现时间序列数据中的特征提取,然后利用池化层进一步提取时间维度最重要的特征,全连接层用于对以上时序特征进行抽象组合。具体公式如下:

$$a_c = f_{\text{relu}}(X * W + b) \tag{1}$$

$$f_{\text{relu}}(z) = \max(z, 0) \tag{2}$$

$$a_p(k) = \max(a_c(2k - 1), a_c(2k)) \tag{3}$$

式中,  $f_{\text{relu}}()$  为激活函数 ReLU,用于加速模型收敛;  $X \in \mathbb{R}^{s \times d}$  为输入时序特征;  $s$  为时间序列长度;  $d$  为特征向量维度;  $*$  为卷积操作;  $W$  为一维卷积核,尺寸为  $1 \times k$ ;  $b$  为偏置;  $a_c$  为一维卷积核  $W$  生成的特征映射,即卷积层输出;  $a_p(k)$  为池化层生成的特征映射  $a_p$  的第  $k$  个特征。




图 1 CNN-GRU 混合神经网络模型结构

Figure 1 A GRU unit in the 1st layer for time step t

然后将 CNN 部分输出作为 GRU 部分的输入,由 GRU 部分训练完成预测。GRU 适用于处理和预测时间序列中的间隔、延迟和周期性事件,并解决了循环神经网络的梯度消失问题。GRU 模型是长短期记忆网络(long short term memory network, LSTM)的一种效果很好的变体,具有与 LSTM 相似的单元内的数据流,但 GRU 删减了单独的存储单元,并实现“门”功能合并,使得网络训练数据更高效,同时提高了模型防止过拟合的能力。GRU 计算公式如下:

$$\gamma_t = \sigma(W_\gamma \cdot [h_{t-1}, x_t]) \tag{4}$$

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t]) \tag{5}$$

$$\tilde{h}_t = \tanh(W_{\tilde{h}} \cdot [\gamma_t \circ h_{t-1}, x_t]) \tag{6}$$

$$h_t = (1 - z_t) \circ h_{t-1} + z_t \circ \tilde{h}_t \tag{7}$$

式(4)~(7)中,1为让所有的信息通过细胞状态;0为没有信息被允许通过单元状态; $\sigma$ 为 sigmoid 函数; $\circ$ 为哈达玛乘积。

#### 1.2 Attention 机制原理

注意力机制是模仿人类注意力问题的解决方案,可以快速从大量信息中筛选出高价值的信息。本文主要用于解决 GRU 层针对多源数据组成的长时间序列提取最终矢量出现偏差的问题。方法是基于注意力机制为 GRU 层的输出结果合理分配注意力权重,更新其输出结果以减小偏差。本文 Attention 机制用作多层 GRU 层和 Dropout 层的接口,如图 2 所示。

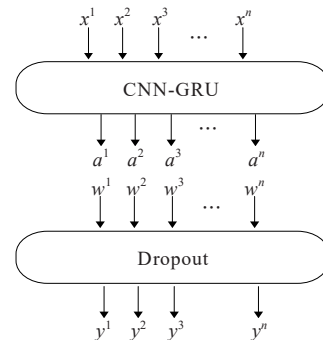


图 2 基于 Attention 机制的 CNN-GRU 结构

Figure 2 CNN-GRU network structure diagram with Attention mechanism

图 2 中,  $a$  为学习得到的输入序列  $x$  的特征,  $w$  为各特征的注意力权重,其中,注意力权重  $w$  计算公式为

$$w' = \frac{\exp(e')}{\sum_{t=1}^T \exp(e')} \quad (8)$$

### 1.3 基于 Attention 机制的 CNN-GRU 模型

本文提出一种基于 Attention 机制的 CNN 和 GRU 组合模型,如图 3 所示,以下简称为 CNN-GRU-Attention 混合网络模型。该模型主要由两部分组成:CNN 部分负责特征提取,GRU 部分负责负载率或负载等级预测,并将 Attention 机制用作 GRU 层和 Dropout 层的接口,用于减小输出结果偏差。

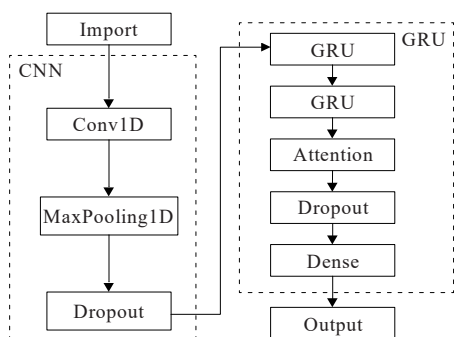


图 3 CNN-GRU-Attention 网络混合模型

Figure 3 CNN-GRU-Attention network hybrid model

本文预测模型的输入为多维时间序列,由相关时点的历史负载率/负载等级数据和气象数据多个特征量组成,表示为  $X = [x_1, x_2, \dots, x_t, \dots, x_n]^T$ 。传统神经网络对输入特征的质量要求较高,当输入特征维数过多时,预测模型将注意力分散,无法准确学习有效特征,且大大增加了学习时间。CNN-GRU-Attention 混合网络中的 CNN 部分可以自主学习综合历史负荷和气象特征的高级特征,实现多特征的抽象组合,实现特征降维。CNN 部分的输出特征向量为  $X'_c = [x_{c1}, x_{c2}, \dots, x_{ct}, \dots, x_{cn}]^T$ ,其计算过程如下:

$$a_c = f_{\text{relu}}(X * W + b_1) \quad (9)$$

$$a_p(t) = \max(a_c(t-1), a_c(t)) + b_2 \quad (10)$$

$$X'_c = f_{\text{Sigmoid}}(a_p \cdot W_2 + b_3) \quad (11)$$

在 CNN-GRU-Attention 混合网络的 GRU 部分,本文使用多层 GRU 学习降维后时间序列,通过增加模型的深度提高模型的预测能力,从而实现线路负载率或负载等级初步预测序列。接下来,基于 Attention 机制合理分配注意力权重减小输出结果偏差后,为防止过拟合以提升模型泛化能力,通过 Dropout 层正则化,得到一个新的序列。最后,

由 Dense 全连接层输出线路负载率或负载等级预测序列,记为  $Y = [y_1, y_2, \dots, y_t, \dots, y_n]^T$ ,其计算过程如下:

$$a'_c = \text{GRU}(X'_c) \quad (12)$$

$$w_{\text{atti}} = \frac{\exp(\dot{e})}{\sum_{t=1}^T \exp(e_t)} \quad (13)$$

$$Y = f_{\text{Sigmoid}}(a'_c w_{\text{atti}} \cdot W_o + b_o) \quad (14)$$

## 2 预测流程和评价指标

### 2.1 特征选择

根据先验知识和相关性分析结果选择相关性高的特征作为神经网络模型输入,可以加快模型收敛,提高模型实际效果。线路负载率/负载等级预测影响因素主要为两类:气象信息和相似时点负载。

本文气象信息包括日平均温度、日最高温度、日最低温度、小时平均温度、气压、风力、每小时降水概率。通过相关性分析,选择相关性高的气象信息作为输入特征。由于线路负载具有周期性,可以通过自相关性分析,选择与待测时点相近的负载时点数据,用于丰富预测模型的先验信息。

综上所述,本文构建了包含气象因素、相似时点负载因素的多维特征向量作为预测模型的输入。

### 2.2 训练模型

CNN-GRU-Attention 混合网络模型集合 CNN 高效提取特征和 GRU 处理和预测线路负载率/负载等级时间序列中的间隔、延迟和周期性的优点。输入、输出变量属性和组成对 GRU 预测效果影响很大。本文结合 CNN-GRU-Attention 混合网络可实现短期线路重过载预测的 2 种方法,构成名为 A 和 B 的对照组,用于对比 CNN-GRU-Attention 网络回归预测和分类预测在重过载预测工作中的适用性。其中,A 是实现配网线路负载率短期回归预测后,根据负载等级划分标准将负载率预测结果转化为负载等级,B 是线路负载等级的短期分类预测。具体预测过程如下。

1) 数据预处理。通过特征分析确定模型的输入、输出变量。A 和 B 的输入均为多维时间序列(包

括气象信息、相似时点负载数据),输出量均为待测时点线路负载等级。其中需将B的输入特征和A的输出量离散化(将线路负载率根据负载等级划分标准,转化为线路负载等级)。然后将输入输出数据集矩阵化、归一化,并把预处理后的数据集划分为训练集、验证集以及测试集3个部分。

2) 训练模型。采用逐点预测方式,利用训练集和验证集训练构建CNN-GRU-Attention混合网络模型。经过多次迭代,训练集和验证集的损失函数MAE均收敛后完成模型训练。

3) 重过载预测。结合评价指标,将测试集输入训练完成的模型中进行预测,用于评价模型预测未知数据的预测性能。调整模型参数至测试集预测效果最佳。

### 2.3 评价指标

为评估重过载预测的性能,针对预测最终输出量(A和B最终输出量均为线路负载等级),通过统计预测结果与实际负载等级相比统计准确、低估和高估的时点数量。准确时点数量越大、低估时点数量越少,则越适用于重过载预测。并统计A和B中,各网络模型对照组(GRU、CNN-GRU、CNN-GRU-Attention)训练过程平均迭代一步所需时间,以评价文中模型训练速度。

针对A的线路负载率回归预测,利用均方根误差、平均绝对百分误差来评价GRU、CNN-GRU、CNN-GRU-Attention这3种模型的数据拟合、数据预测的效果。

1) 均方根误差(root mean squared error, RMSE)是用来衡量观测值同真值之间的偏差。其公式如下:

$$R_{MSE} = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2} \quad (15)$$

2) 平均绝对百分误差(mean absolute percentage error, MAPE)不仅考虑预测值与真实值的误差,还考虑了误差与真实值之间的比例。其公式如下:

$$M_{APE} = \frac{100}{m} \sum_{i=1}^m \left| \frac{(y_i - \hat{y}_i)}{y_i} \right| \quad (16)$$

## 3 算例分析

为验证本文所提方法的科学性和可靠性,以及

对比A、B方法的优劣。本文实验样本为上海市浦东区某商住混合区域的一条10 kV架空线路电流数据和浦东气象数据,时间跨度为2017年1月1日至2018年11月31日,采样间隔为15 min。

### 3.1 数据预处理

为使数据样本更好地适应建模的数据格式,需要对初始数据进行数据变换(构建负载率、负载等级参数)、集成操作、归一化等。结合实际工程中的辐射型接线线路重过载指标和线路负载率分布概率,将线路负载等级划分如表1所示。然后划分数据集为训练集、验证集、测试集,划分比例为6:2:2。训练集和验证集用于训练模型,测试集作为预测对象。

表1 线路负载等级划分标准

Table 1 Line load classification criteria

线路负载率范围	负载等级	线路状态
[0,0.6)	0	轻载
[0.6,0.7)	1	轻载
[0.7,0.8)	2	重载
[0.8,1]	3	重载
(1,∞)	4	过载

### 3.2 特征选择

1) 气象因素相关性。计算线路负载率、离散负载等级与气象预报中可获取的气象因素:日平均温度、日最高温度、日最低温度、小时平均温度、气压、风力、每小时降水概率的Spearman相关系数并排序,如表2所示。Spearman相关系数又称秩相关系数,是利用两变量的秩次大小作线性相关分析,对原始变量的分布不作要求,属于非参数统计方法,适用范围较广。

线路负载率转化为线路负载等级后与各气象因素相关性强弱发生变化,气压和温度相关因素相关性明显加强。而线路负载率与湿度、风速、温度相关性较高。

2) 历史线路负载率数据相关性。对线路负载率时间序列进行自相关函数(autocorrelation function, ACF)测试。计算不同滞后时长下的ACF曲线,单位滞后时长为1 h,如图4所示。由图4可知,滞后时间在2 h以内的ACF值和前三天期间同时段的ACF值大于0.8,说明1~2 h内及前三天期间同时段线路负载率之间存在较强的自相关性。

表2 线路负载等级、负载率与气象因素Spearman相关系数

Table 2 Spearman correlation coefficient between line load level / load rate and meteorological factors

气象因素	线路负载率	线路负载等级
小时平均气压	-0.038 543 713	-0.244 401 672
小时平均湿度	-0.253 953 802	-0.100 614 116
小时平均降水概率	-0.037 410 268	-0.055 263 944
小时平均风速	0.143 134 659	0.022 296 031
日最高温度	0.052 399 456	0.293 197 403
小时平均温度	0.135 053 067	0.294 735 239
日最低温度	0.070 300 189	0.295 953 231
日平均温度	0.059 820 149	0.296 327 806




图4 线路电流时间序列自相关函数

Figure 4 ACF of line current time series

为提高模型短期预测效果,本实验分别构建A、B组高相关性特征输入数据集,耦合与预测时点负载率/负载等级Spearman相关系数大于0.1的气象因素和前三天同时段历史线路负载率/负载等级数据作为模型输入特征向量,具体如表3所示。其中,A组输入参数的时间步长为1,维数为13;B组输入参数的时间步长为1,维数为15。

表3 模型输入特征

Table 3 Model input characteristics

A组输入特征参数	B组输入特征参数
1天前 $T-2, T-1, T$ 时点负载率	1天前 $T-2, T-1, T$ 时点负载等级
2天前 $T-2, T-1, T$ 时点负载率	2天前 $T-2, T-1, T$ 时点负载等级
3天前 $T-2, T-1, T$ 时点负载率	3天前 $T-2, T-1, T$ 时点负载等级
小时平均湿度	小时平均气压
小时平均风速	小时平均湿度
小时平均温度	日最高温度
—	小时平均温度
—	日最低温度
—	日平均温度

### 3.3 模型超参数

CNN设计为1层卷积层(Conv1D),卷积核数目为32,卷积核大小为 $1*1$ ,激励函数为ReLU。在

池化层中,池大小为1。CNN层输出特征序列通过Dropout层后作为二层GRU层的输入,最后通过Dense层输出预测序列。Dropout层参数设为0.1,二层GRU中神经元数设置为(64,128)。其中,设置模型参数GRU隐藏层激励函数为ReLU,Dropout参数为0.1,Dense全连接层激励函数为linear,epochs=25,batch\_size=32,损失函数为MAE,优化器为adam。

### 3.4 实验结果

根据本文预测流程,分别以A组回归预测和B组分类预测2种方式训练简单GRU、GRU-Attention、CNN-GRU-Attention混合网络的预测模型,并均调参至预测效果最佳。使用逐点预测方式,用该模型实现测试时段的预测(2018年2月至5月),预测点时间间隔为15min。然后将最终输出量转化为负载等级,即根据表1中电线负载等级指标将对A组短期线路负载率预测结果转化为负载等级,根据四舍五入原则对B组日前短期线路负载等级预测结果取整。统计高估、低估和准确时点数量,以及训练模型平均一步迭代时间,如表4所示。并计算A组线路负载率回归预测结果的RMSE、MAPE,用以对比和A、B这2种预测方式应用于预测线路重过载的适用性和以上3种模型预测效果。

在表4评价指标中,“准确”指负载等级预测结果与实际负载等级一致;“低估1级”指负载等级预测结果与实际负载等级相比向下浮动1级,“低估2级”和“低估3级”同理;“高估1级”负载等级预测结果与实际负载等级相比向上浮动1级,“高估2级”和“高估3级”同理;“迭代时间”指模型训练过程中每迭代一次所需平均时间,单位为s。

根据负载等级评价指标分析,A、B组各模型重过载预测结果准确率均较高。结合考虑实际应用中要求减少预测结果中低估的情况,本实验中A组CNN-GRU-Attention混合模型预测结果低估时点数最少,只有2个时点出现低估1级的情况。B组CNN-GRU-Attention混合模型预测结果中低估情况时点数较多,有9个时点出现低估1级的情况;A组中CNN-GRU-Attention混合模型虽高估时点数最多(高估1级时,点数为18),但其预测负载等级均为2级以下,即线路负载率小于0.8,属于轻载,如表5所示。

表 4 模型预测结果比较

Table 4 Comparison of model prediction results

模型	分组	评价指标							
		低估 1 级/次	低估 2 级/次	低估 3 级/次	高估 1 级/次	高估 2 级/次	高估 3 级/次	准确/次	迭代时间/s
GRU	A	11	0	0	6	0	0	9 582	6
	B	9	0	0	9	1	0	9 580	9
GRU-Attention	A	6	0	0	8	0	0	9 585	8
	B	9	0	0	9	1	0	9 580	10
CNN-GRU-Attention	A	2	0	0	18	0	0	9 579	9
	B	9	0	0	10	1	0	9 579	13

表 5 A 组 CNN-Attention-GRU 混合神经网络模型  
预测结果高估情况统计

Table 5 Statistics on the overestimation of the  
CNN-Attention-GRU hybrid model in group A

时点 序号	实际负载率	预测负载率	实际负载等级	预测负载等级
90	0.670 43	0.709 270 368	1	2
184	0.584 27	0.615 770 874	0	1
274	0.680 05	0.703 726 693	1	2
276	0.688 42	0.706 720 203	1	2
277	0.696 36	0.707 392 081	1	2
278	0.680 05	0.714 872 086	1	2
283	0.589 71	0.625 201 421	0	1
284	0.560 43	0.601 006 743	0	1
365	0.576 75	0.601 950 443	0	1
366	0.585 11	0.614 634 387	0	1
375	0.589 30	0.641 921 193	0	1
376	0.572 15	0.623 190 830	0	1
377	0.565 46	0.605 895 573	0	1
463	0.584 27	0.606 537 345	0	1
469	0.586 78	0.656 810 359	0	1
470	0.581 35	0.617 589 492	0	1
471	0.567 96	0.612 275 598	0	1
2 963	0.553 74	0.600 528 085	0	1

从高估情况出现时间分布情况分析,高估情况出现时间较集中并且持续时间较短,均小于 1 h,故 A 组回归预测方式高估时点的情况较多,对重过载预测可靠性影响较小;从各训练模型平均迭代训练时间分析,A 组各方法训练模型过程中迭代时间低于 B 组。在增加迭代次数的条件下,B 组训练模型所需时间明显高于 A 组,将增加时间成本和能耗,经济性较差。分析 A 组中 3 种模型的负载等级低估

时点统计(见表 4)和负载率回归预测结果的 RMSE、MAPE(见表 6),发现结合 Attention 机制和 CNN 可以提高 GRU 网络预测准确率和针对重过载预测的适用性。测试集中 2018 年 2 月 7 日的负载率实际值和不同方法的短期线路负载率预测曲线对比如图 5 所示,可知本文预测模型在负载率峰值时段拟合实际值效果比另外 2 种模型好,具有更高的预测精度,且该现象具有普遍性。线路重过载多出现于负载率峰值时段,即 CNN-GRU-Attention 混合模型可更准确地预测线路重过载。

表 6 A 组 3 种模型预测结果比较

Table 6 Comparison of prediction results of  
three models in group A

模型	评价指标	
	RMSE	MAPE
GRU	0.017 000	0.006 365
GRU-Attention	0.015 000	0.005 181
CNN-GRU-Attention	0.012 000	0.004 166

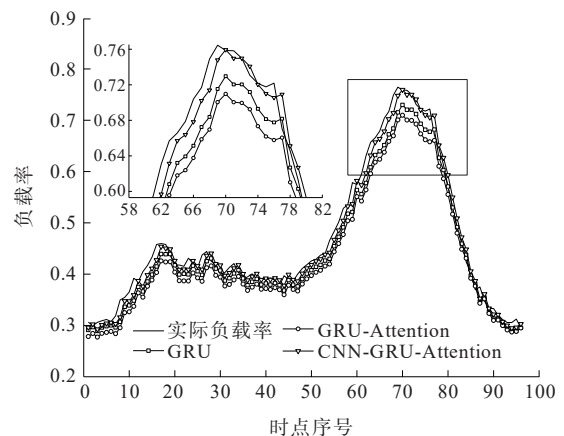


图 5 A 组 2018 年 2 月 7 日预测结果对比

Figure 5 Comparison of forecast results of  
group A in February 7th, 2018

综上所述,本实验中A组利用CNN-GRU-Attention神经网络模型短期回归预测线路负载率后转化为负载等级数的预测方法更适用于配网线路重过载预测。

## 4 结语

配电网10 kV线路为台区配变供电,线路实时负荷为各台区配变负荷叠加,线路电流受用户共性的用电行为影响较大,用户偶然因素造成的电流变化会在内部相互抵消从而对电流的影响较小。但线路重过载判断标准为单一数值,若预测结果落入线路重过载判断标准值邻域,易出现误判情况,故需要针对负载峰值时段预测精度更高的预测方法。本文提出一种基于Attention机制的CNN-GRU混合网络模型的线路短期重过载预测方法。并分析对比该方法以回归预测和分类预测方式实现重过载预测的适用性及其准确率。得到以下结论。

1) 结合实际应用中需减少低估情况的要求,将线路负载率预测结果转化为线路负载等级后,CNN-GRU-Attention混合模型回归预测方式的等级低估时点数最少,预测准确率较高,且较分类预测方式其模型迭代训练时间更短。虽然其高估时点的情况较多,但高估1级后仍均为轻载状态,对重过载预测可靠性影响较小。

2) CNN-GRU-Attention混合模型回归预测方法以增加较少计算时间为代价,使预测结果在线路重过载多发的负载率峰值时段,较传统GRU网络模型、GRU-Attention网络模型具有更高的拟合度。因此可得,增加Attention机制和CNN形成混合网络,具有提高GRU网络预测准确率和适用性的作用,即在重过载预测中引入该模型结构的CNN-GRU-Attention混合神经网络具有必要性。

综上所述,本文实验中利用CNN-GRU-Attention神经网络模型以回归预测方式,实现线路负载率预测后再转化为负载等级数的预测方法更适用于线路重过载预测。而且最终输出量形式为负载等级可以弱化用电低谷时段对负载率预测准确率的需求,在一定程度上可以减少部分实际数据由于各种因素产生的误差影响。本文实验分析样本为辐射

型10 kV线路电流数据,没有扩展研究其他接线方法的线路电流数据。而且模型验证集数据非连续的时序数据缺失日期较多,故预测模型训练过程中验证集损失函数有较大的波动,若以完整数据集训练模型将提高模型训练效果。

## 参考文献:

- [1] 卢艺,陶凯,林声宏. 架空导线载流量动态计算与应用[J]. 电网技术,2009,33(20):76-81.  
YU Yi, TAO Kai, LIN Shenghong. Dynamic ampacity calculation of overhead transmission lines and its application[J]. Power System Technology, 2009, 33(20): 76-81.
- [2] 付善强,王孟夏,杨明,等. 架空导线载流量的多时段联合概率密度预测[J]. 电力系统自动化,2019,43(17):102-113.  
FU Shanqiang, WANG Mengxia, YANG Ming, et al. Multi-period joint probability density forecasting for thermal rating of overhead line[J]. Automation of Electric Power Systems,2019,43(17):102-113.
- [3] SONG P, XU Z, DONG H. UPFC-based line overload control for power system security enhancement[J]. IET Generation, Transmission and Distribution, 2017, 11(13): 3310-3317.
- [4] KO Y. An inference methodology based on the local minimum tree search to solve the distribution system events under heavy load condition[J]. IEEE Transactions on Power Delivery,2012,27(2):725-734.
- [5] JIN X, MU Y, JIA H, et al. Alleviation of overloads in transmission network: A multi-level framework using the capability from active distribution network[J]. International Journal Of Electrical Power & Energy Systems,2019,112:232-251.
- [6] BALARAMAN S, KAMARAJ N. Cascade BPN based transmission line overload prediction and preventive action by generation rescheduling[J]. Neurocomputing, 2012,94:1-12.
- [7] 陆继翔,张琪培,杨志宏,等. 基于CNN-LSTM混合神经网络模型的短期负荷预测方法[J]. 电力系统自动化, 2019,43(8):131-137.  
LU Jixiang, ZHANG Qipei, YANG Zhihong, et al. Short-term load forecasting method based on CNN-LSTM hybrid neural network model[J]. Automation of Electric Power Systems,2019,43(8):131-137.
- [8] 吴云,雷建文,鲍丽山,等. 基于改进灰色关联分析与编



- 蝠优化神经网络的短期负荷预测[J]. 电力系统自动化, 2018,42(20):67-72.
- WU Yun, LEI Jianwen, BAO Lishan, et al. Short-term load forecasting based on improved grey relational analysis and neural network optimized by bat algorithm[J]. Automation of Electric Power Systems, 2018,42(20):67-72.
- [9] 黄南天, 齐斌, 刘座铭, 等. 采用面积灰关联决策的高斯过程回归概率短期负荷预测[J]. 电力系统自动化, 2018, 42(23):64-71.
- HUANG Nantian, QI Bin, LIU Zuoming, et al. Probabilistic short-term load forecasting using Gaussian process regression with area grey incidence decision making[J]. Automation of Electric Power Systems, 2018,42(23):64-71.
- [10] 史常凯, 闫文棋, 张筱慧, 等. 基于BP网络和灰色模型的春节配变重过载预测[J]. 电力科学与技术学报, 2016,31(3):140-145.
- SHI Changkai, YAN Wenqi, ZHANG Xiaohui, et al. Heavy overload forecasting of distribution transformer during the spring festival based on BP network and grey model[J]. Journal of Electric Power Science and Technology, 2016, 31(3):140-145.
- [11] 王淞瑶, 张智晟. 基于量子加权多层级GRU神经网络的综合能源系统多元负荷短期预测[J]. 电力系统保护与控制, 2022,50(23):85-93.
- WANG Songyao, ZHANG Zhisheng. Short-term multivariate load forecasting of an integrated energy system based on a quantum weighted multi-hierarchy gated recurrent unit neural network[J]. Power System Protection and Control, 2022,50(23):85-93.
- [12] 徐鹏超, 李琰, 赵艳雷. 基于自适应变异蝙蝠优化BP神经网络的短期风电功率预测[J]. 电测与仪表, 2021,58(4):121-127.
- XU Pengchao, LI Yan, ZHAO Yanlei. Short-term wind power prediction based on BP neural network with adaptive mutation bat optimization algorithm[J]. Electrical Measurement & Instrumentation, 2021,58(4):121-127.
- [13] KONG W, DONG Z Y, JIA Y, et al. Short-term residential load forecasting based on LSTM recurrent neural network [J]. IEEE Transactions on Smart Grid, 2019,10(1):841-851.
- [14] 杨胡萍, 余阳, 汪超, 等. 基于VMD-CNN-BIGRU的电力系统短期负荷预测[J]. 中国电力, 2022,55(10):71-76.
- YANG Huping, YU Yang, WANG Chao, et al. Short-term load forecasting of power system based on VMD-CNN-BIGRU[J]. Electric Power, 2022,55(10):71-76.
- [15] 马瑞, 龚人杰, 杨海晶. 基于信息粒化和支持向量机的母线等效负荷波动预测方法[J]. 电力系统及其自动化学报, 2019,31(4):25-31.
- MA Rui, GONG Renjie, YANG Haijing. Fluctuation prediction method for equivalent load of bus based on information granulation and support vector machine[J]. Proceedings of the CSU-EPSC, 2019,31(4):25-31.
- [16] 魏震波, 余雷. 基于FFT, DC-HC及LSTM的短期负荷预测方法[J]. 智慧电力, 2022,50(3):37-43.
- WEI Zhenbo, YU Lei. Short-term load forecasting method based on FFT, DC-HC and LSTM[J]. Smart Power, 2022,50(3):37-43.
- [17] 王刚, 杨晓静, 张志军, 等. 基于深度神经网络与权值共享的工业园区负荷预测[J]. 电测与仪表, 2021,58(1):137-141.
- WANG Gang, YANG Xiaojing, ZHANG Zhijun, et al. Load forecasting in industrial park based on deep neural network and weightsharing[J]. Electrical Measurement & Instrumentation, 2021,58(1):137-141.
- [18] 赵兵, 王增平, 纪维佳, 等. 基于注意力机制的CNN-GRU短期电力负荷预测方法[J]. 电网技术, 2019,43(12):4370-4376.
- ZHAO Bing, WANG Zengping, JI Weijia, et al. A short-term power load forecasting method based on attention mechanism of CNN-GRU[J]. Power System Technology, 2019,43(12):4370-4376.
- [19] 李正浩. 基于NACEMD-GRU的组合型日前负荷预测方法[J]. 电网与清洁能源, 2021,37(6):43-50.
- LI Zhenghao. A combined method of day-ahead load forecasting based on NACEMD-GRU[J]. Power System and Clean Energy, 2021,37(6):43-50.
- [20] 徐菲菲, 芦霄鹏. 结合卷积神经网络和最小门控单元注意力的文本情感分析[J]. 计算机应用与软件, 2020,37(9):75-80+125.
- XU Feifei, LU Xiaopeng. Text sentiment analysis based on Attention C\_MGU[J]. Computer Applications and Software, 2020,37(9):75-80+125.
- [21] 谢施君, 雷汉坤, 王乃会, 等. 基于BP神经网络的CVT暂态电压传递特性补偿技术[J]. 高压电器, 2022,58(2):149-157.
- XIE Shijun, LEI Hankun, WANG Naihui, et al. Compensation technology on transient voltage transfer characteristics of CVT based on BP neural network[J]. High Voltage Apparatus, 2022,58(2):149-157.
- [22] 林盛振, 谢敏, 黄彬彬, 等. 基于贝叶斯正则优化NARX神经网络的电力负荷预测[J]. 供用电, 2022,39(9):51-60.
- LIN Shengzhen, XIE Min, HUANG Binbin, et al. Power load forecasting based on Bayesian regularization optimized NARX neural network[J]. Distribution & Utilization, 2022,39(9):51-60.