

基于 CNN-ISSA-GRU 模型的短期负荷预测方法 *

刘可真¹, 梁玉平¹, 代莹皓¹, 吴政声², 董 敏³

(1. 昆明理工大学 电力工程学院, 云南 昆明 650500;

2. 中国能源建设集团云南省电力设计院, 云南 昆明 650051;

3. 云南经济管理学院 信息与智能工程学院, 云南 昆明 650304)

摘要: 电网的可靠运行及持续发展离不开对短期电力负荷的高效、准确预测。针对表征电网负荷变化的历史数据具有复杂性和时序性等特点,且现有的机器学习预测方法仍存在依据经验选取关键参数的不足,利用卷积神经网络(CNN)提取表征负荷变化的多维特征向量,构成时间序列输入到门控循环单元(GRU),并使用改进麻雀搜索算法(ISSA)对GRU网络中的超参数进行迭代寻优。预测试验样本来自云南某地区的负荷数据,所提方法的预测精度达到了98.624%,与循环神经网络(RNN)、GRU和长短期记忆(LSTM)等神经网络预测方法进行对比,算例表明,所提方法克服了依据经验选取关键参数难题的同时具有更高的预测精度。

关键词: 短期负荷预测; 卷积神经网络; 门控循环单元; 超参数寻优

中图分类号: TM714 文献标志码: A 文章编号: 1673-6540(2022)08-0079-08

doi: 10.12177/emca.2022.076

Short-Term Load Forecasting Method Based on CNN-ISSA-GRU Model *

LIU Kezhen¹, LIANG Yuping¹, DAI Yinghao¹, WU Zhengsheng², DONG Min³

(1. Faculty of Electric Power Engineering, Kunming University of Science and Technology,
Kunming 650500, China;

2. China Energy Engineering Group Yunnan Electric Power Design Institute Co., Ltd.,
Kunming 650051, China;

3. Faculty of Information and Intelligent Engineering, Yunnan University of Business Management,
Kunming 650304, China)

Abstract: Efficient and accurate short-term power load forecasting plays an important role in the reliable operation and sustainable development of the power grid. In view of the complexity and timing characteristics of the factors that affect the changes in power grid load, and the shortcomings of the existing machine learning prediction methods in selecting key parameters based on experience, the convolutional neural network (CNN) is used to extract the multidimensional feature vector representing the load change, which is constructed as a time series and input to the gated recurrent unit (GRU), and the improved sparrow search algorithm (ISSA) is used to iteratively optimize the hyperparameters in the GRU network. The prediction experimental sample comes from the load data of a certain area in Yunnan, and the prediction accuracy of the proposed method reaches 98.624%. Compared with the neural network prediction methods of RNN, GRU and LSTM, the calculation example shows that the proposed method overcomes the difficulty of selecting key parameters based on experience and has higher prediction accuracy.

收稿日期: 2022-04-27; 收到修改稿日期: 2022-06-28

* 基金项目: 云南省教育厅科学研究基金项目(2022J1279)

作者简介: 刘可真(1974—),女,博士,教授,研究方向为电力设备状态监测与评估技术。

梁玉平(1995—),男,硕士研究生,研究方向为机器学习在电力设备状态评估中的应用。

董 敏(1992—),男,硕士,讲师,研究方向为新型电力系统优化调度与市场交易。(通信作者)

Key words: short-term load forecasting; convolutional neural network (CNN); gated recurrent unit (GRU); hyperparameter optimization

0 引言

随着我国电力市场及其相关产业链的蓬勃发展,对负荷进行高效、准确地预测逐渐成为电网研究的重要内容。负荷预测是根据历史负荷的波动规律以及温度、日期类型等相关因素,对未来的电力需求进行估计。其中短期电力负荷预测对电网调度、市场交易计划的制定、降低发电机组的损耗,以及保证电网经济、可靠运行发挥着重要作用,故亟需对短期负荷预测方法进行深入研究,以提升电网运行可靠性及经济效益^[1-2]。

为了提高短期电力负荷预测精度,国内外众多专家学者开展了深入研究,预测模型总体可概括为时间序列模型、机器学习模型、模型组合三类。时间序列模型的预测效果依赖数据集的原始分布特性^[3]。机器学习模型主要包括循环神经网络(RNN)^[4]、支持向量机(SVM)^[5]、长短时记忆(LSTM)网络^[6]和门控循环单元(GRU)^[7-8]等。模型组合有两种形式:(1)如文献[9]分别用LSTM与极限梯度提升(XGBoost)模型预测后,赋予单一模型不同权重,寻找最优权值求和,使预测精度高于单一模型;(2)利用信号分解的原理对初始数据进行处理,方法有小波分解^[10]、经验模态分解(EMD)^[11]、变分模态分解(VMD)^[12]等,降低原始序列的非线性、非平稳特征,进而结合模型进行预测。电力负荷波动受到历史负荷、气象因素、日期类型^[13]等因素影响,使收集的历史数据具有较高的复杂性和时序性。CNN由于其特殊卷积层与池化层结构,可以自动提取出数据间的潜在特征形成特征向量,降低数据的复杂性,现已被应用在进行短期负荷预测的特征向量提取方面^[14]。由于RNN当前时刻的输出会受到上一时刻输出的影响,使其具有“记忆”性质,在时间序列预测中表现更优。RNN的两种变体LSTM和GRU,可以有效缓解RNN训练过程中的梯度消失与爆炸。GRU是在LSTM网络结构基础上进行改进的,其自身结构更加简单、有更快的收敛速度与较高的预测准确率^[15-16]。LSTM网络、深度置信网络(DBN)等传统机器学习法在进行数据预测时,需要根据人为经验或控制变量等方法确定模

型关键参数值的大小,导致模型预测效果不理想^[13,17]。麻雀搜索算法(SSA)具有控制参数少、求解速度高等优点,可以用以替代手动设置模型参数等重复工作^[19-20];但算法后期种群多样性和搜索能力均会有所下降^[21],因此提出一种改进麻雀搜索算法(ISSA)以增强算法对模型参数的寻优能力。

鉴于此,本文利用CNN从影响负荷因素的多维数据集里提取出有效的特征向量,表征负荷动态复杂变化的特征信息,并构造成时间序列输入到GRU,使用ISSA对GRU网络中的超参数进行迭代寻优。ISSA通过不断寻优得到GRU最优超参数(神经元个数m与学习率ε分别对模型的拟合能力和训练效果影响较大),确保模型达到最高预测精度。试验表明,相较于现有机器学习负荷预测方法,本文所提出的CNN-ISSA-GRU混合模型预测精度更高、稳定性更好。

1 基本原理

1.1 SSA

SSA是2020年提出的一种元启发式优化算法^[18],模拟了麻雀种群的捕食与反捕食的行为。在麻雀群觅食过程中,发现者拥有较高的初始适应度,有更大的觅食范围,负责为群体搜寻觅食范围和方向,在迭代过程中按式(1)更新自身位置。

$$X_{i,k}^{t+1} = \begin{cases} X_{i,k}^t \cdot \exp\left(\frac{-i}{\alpha \cdot iter_{max}}\right), R_2 < ST \\ X_{i,k}^t + Q \cdot L, R_2 \geq ST \end{cases} \quad (1)$$

式中: $X_{i,k}$ 为第*i*只麻雀在第*k*维度下的位置;*t*、*iter_{max}*分别为当前、最大迭代次数; α 为属于(0,1)的随机数;*R₂*、*ST*分别为范围在[0,1]、[0.5,1]的预警值和安全值;*Q*为随机值且服从正态分布;*L*为1×*k*维的全1矩阵。

加入者时刻观察发现者,与其竞争食物或围绕着其觅食,更新公式如下:

$$X_{i,k}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{X_{worst}^t - X_{i,k}^t}{i^2}\right), i > \frac{n}{2} \\ X_p^{t+1} + |X_{i,k}^t - X_p^{t+1}| \cdot A^+ \cdot L, i \leq \frac{n}{2} \end{cases} \quad (2)$$

式中:*X_p*、*X_{worst}*分别为当前发现者最优位置和全

局最差位置; A 为随机赋值为 1 或 -1 的 $1 \times k$ 维矩阵, 且 $A^+ = A^T (AA^T)^{-1}$; $i > \frac{n}{2}$ 表示第 i 只麻雀未获得食物, 需要调整位置觅食。

侦察者更新位置公式为

$$X_{i,k}^{t+1} = \begin{cases} X_{\text{best}}^t + \beta \cdot |X_{i,k}^t - X_{\text{best}}^t|, f_i > f_g \\ X_{\text{best}}^t + K \cdot \left(\frac{X_{i,k}^t + X_{\text{best}}^t}{|f_i - f_w| + \eta} \right), f_i = f_g \end{cases} \quad (3)$$

式中: X_{best} 为当前全局最优位置; β 为服从 $N(0, 1)$ 正态分布的随机值; K 为 $(-1, 1)$ 的随机值; f_i 、 f_g 、 f_w 分别为当前个体适应度、全局最优适应度、最差适应度; η 为避免分母为 0 而引入的常数。

1.2 ISSA

在 SSA 算法的后期迭代中, 麻雀个体同化性质严重, 容易陷入局部最优解, 出现停滞状况。为解决这一情况, 引入柯西-高斯变异策略以调整麻雀位置^[22]。按式(4)、式(5)对当前适应度最高的个体进行变异, 比较变异前后位置, 取最优值进行下一次迭代。

$$Z_{\text{best}}^t = X_{\text{best}}^t [1 + \lambda_1 \text{cauchy}(0, \delta^2) + \lambda_2 \text{Gauss}(0, \delta^2)] \quad (4)$$

$$\delta = \begin{cases} 1, f(X_{\text{best}}) < f(X_i) \\ \exp\left(\frac{|f(X_{\text{best}}) - f(X_i)|}{f(X_{\text{best}})}\right), f(X_{\text{best}}) \geq f(X_i) \end{cases} \quad (5)$$

式中: Z_{best}^t 为变异后个体位置; $\text{cauchy}(0, \delta^2)$ 、 $\text{Gauss}(0, \delta^2)$ 分别为满足柯西分布和高斯分布的随机值; $\lambda_1 = 1 - t^2 (\text{iter}_{\max}^2)^{-1}$ 、 $\lambda_2 = t^2 (\text{iter}_{\max}^2)^{-1}$ 随迭代次数变化。迭代过程中表现为 λ_1 逐渐减小、 λ_2 逐渐增大, 可以使算法脱离停滞状态, 协调算法的局部寻优与全局寻优能力。

1.3 CNN

作为一种典型的前馈神经网络, CNN 利用局部连接和共享权重两种方式对数据进行高效处理, 可以有效降低数据处理过程中存在的复杂性与过拟合等缺陷, 其结构由输入层、卷积层、池化层、全连接层和输出层组成^[23], 如图 1 所示。CNN 独特的卷积层与池化层交替排列, 多维度扫描和压缩数据、自动提取所需特征, 在减少数据特征维度的同时提高数据特征质量。

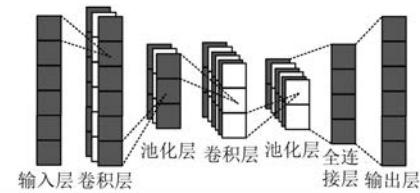


图 1 CNN 结构

1.4 GRU 神经网络模型

GRU 是于 2014 年提出的一种 RNN 变体结构, 解决 LSTM 网络在长序列训练时速度缓慢、计算公式复杂、设置参数较多等问题。

在长时间非线性序列的预测方面, LSTM 和 GRU 模型已经得到了广泛应用, 其组成结构单元都包括: 输入层、隐藏层和输出层, 不同之处在于 GRU 网络用一个更新门代替了 LSTM 网络中的输入门与遗忘门。GRU 结构如图 2 所示, 其中隐藏层包含更新门 z_t 与重置门 r_t 。 z_t 、 r_t 分别控制对前一时刻信息的记忆(越大记忆性越强)、忽略(越小忽略性越高)程度。

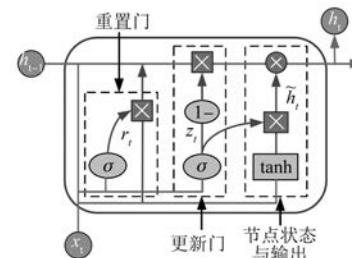


图 2 GRU 网络结构

GRU 模型的输入为 x_t , 通过结合 z_t 与 r_t 得到的输出 h_t 公式如下:

$$z_t = \sigma(W^{(z)}x_t + U^{(z)}h_{t-1}) \quad (6)$$

$$r_t = \sigma(W^{(r)}x_t + U^{(r)}h_{t-1}) \quad (7)$$

$$h''_t = \tanh(r_t \cdot Uh_{t-1} + Wx_t) \quad (8)$$

$$h_t = (1 - z_t) \cdot h''_t + z_t \cdot h_{t-1} \quad (9)$$

式中: h''_t 表示输入 x_t 与前一个输出结果 h_{t-1} 的结合; $W^{(z)}$ 、 $U^{(z)}$ 、 $W^{(r)}$ 、 $U^{(r)}$ 、 W 和 U 表示训练参数矩阵; \cdot 代表元素复合关系; σ 和 \tanh 分别为 Sigmoid、 \tanh 的双曲正切函数。

2 CNN-ISSA-GRU 混合模型及其评价指标

2.1 预测模型叙述

短期电力负荷与用户的用电习惯、历史负荷、

气温、日期等密切相关,负荷曲线呈现出非线性、非平稳的趋势。历史负荷数据在短期负荷预测过程中起着重要作用,其包含了未来负荷变化的重要特征信息。传统方法进行负荷预测时,输入到模型的特征向量是人为选取预测时刻前一段时间(如前2 h、连续前几天同时刻等)的负荷值,这不仅破坏了历史负荷数据内部的特征规律,而且降低了预测模型的精准度。此外气温数据、日期类型影响着预测模型准确度,且这些因素极具波动性与不确定性,直接作为特征输入GRU时,造成模型预测精度偏低。CNN凭借卷积、池化层交替排列结构可以有效地从影响负荷变化的因素中挖掘出潜在的相关信息,提取出重要的特征信息进一步构造成时间序列输入到GRU网络。ISSA在保证GRU模型预测精度最高的前提下,搜寻模型的最优参数(m 与 ε),实现电网负荷短期精准预测。

2.2 预测模型结构

本文所提基于CNN-ISSA-GRU的预测模型如图3所示,主要包括数据预处理层、CNN层、ISSA寻优层、GRU预测输出层。

步骤1。采用min-max公式将特征数据集进行标准化处理,变换至区间[0,1],划分训练集、测试集,输入到CNN层。min-max公式为

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (10)$$

式中: x^* 为标准化后的样本; x_{\min} 、 x_{\max} 分别为样本最小、最大值。

步骤2。CNN层挖掘影响负荷变化的特征向量,构造为时间序列,输入GRU层。

步骤3。初始化ISSA参数,建立GRU层,计算适应度和个体最优位置,开始训练并以平均绝对百分比误差(MAPE)评价麻雀种群在训练集的适应度。

步骤4。依据式(1)~式(5)更新麻雀发现者、加入者、侦察者位置 $X_{i,k}^{k+1}$,即更新参数 m 与 ε ,得到当前适应度值,与上一步适应度比较取最优值,使预测精度最高。

步骤5。当适应度不再变化或达到最大次数 $iter_{\max}$ 时终止迭代,获取当前GRU最优超参数 m 和 ε ,否则继续步骤4。

步骤6。使用GRU最优超参数更新预测模

型,在测试集中预测比较精度。

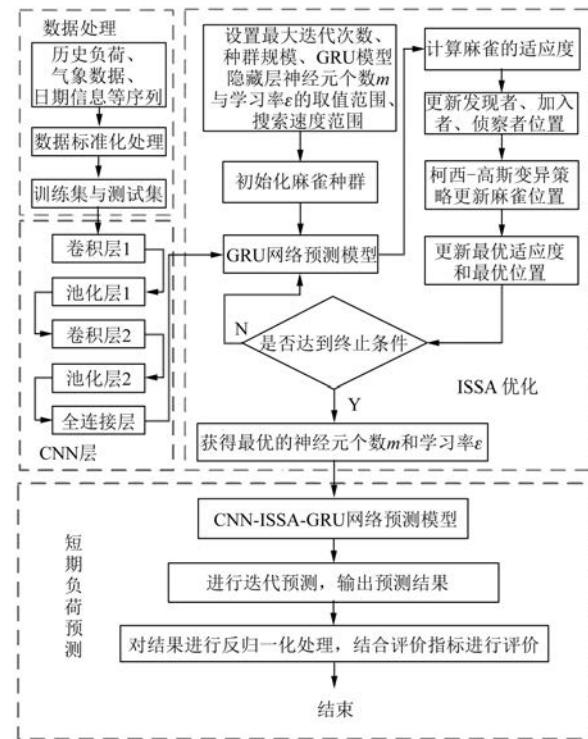


图3 基于CNN-ISSA-GRU的预测模型

2.3 模型评价标准

为了验证本文所提预测模型的性能,选取如下指标对模型进行评价。

平均绝对百分比误差:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{X_{act}(i) - X_{pred}(i)}{X_{act}(i)} \right| \quad (11)$$

根均方误差:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n [X_{act}(i) - X_{pred}(i)]^2}{n}} \quad (12)$$

预测精度:

$$FA = \left[1 - \frac{|X_{act}(i) - X_{pred}(i)|}{X_{act}(i)} \right] \times 100\% \quad (13)$$

式中: n 为测试集容量; $X_{act}(i)$ 和 $X_{pred}(i)$ 分别表示 i 时刻负荷的真实值和预测值; $MAPE$ 和 $RMSE$ 与预测精度呈负相关关系,其值越小代表着预测越准确; FA 则相反,其值越大代表着预测越准确。

3 算例分析

为验证本文所提出的CNN-ISSA-GRU网络模型预测方法的准确性,进行算例分析。测试样本

使用云南某地区共 3 年的电力负荷数据,采集周期为 15 min,一天采集 96 个点,将预测结果与 CNN-SSA-GRU、CNN-GRU、GRU、LSTM 和 RNN 模型作对比,验证所提模型的可靠性。

3.1 试验环境、负荷数据集划分与特征选取

试验在 Win10(64bit)操作系统下进行,基于 Anaconda 平台,编程语言为 Python,Keras 主要有模块化、支持训练模型层的自由组合等特征,采用 Keras 实现基于 CNN-ISSA-GRU 网络模型的短期负荷预测。样本所使用的数据集为 2013 年 1 月 1 日至 2015 年 12 月 31 日,共 105 120 个历史负荷数据。以 2013 年至 2014 年的电力负荷特征数据作为训练集,2015 年的数据作为测试集。本文确定模型的输入特征向量为历史负荷数据、预测日及前一日的最高温度、最低温度、平均温度、周日期类型、工作日类型,星期一到星期日用数字 1~7 表示、工作日与节假日分别用 1 和 2 表示,形成相应的特征矩阵并输入模型。

3.2 CNN-ISSA-GRU 模型参数选择与优化结果

CNN-ISSA-GRU 网络模型由数据输入预处理层、CNN 层、ISSA 优化层和 GRU 预测输出层构成。将收集到的影响电力负荷变化的历史负荷数据和温度数据标准化处理后输入 CNN 模型,提取出关键的特征信息,经过调整模型结构和参数以及对预测结果进行分析,确定模型参数如下:构建的 CNN 模型由 2 个卷积层(2 层都为一维卷积,核数目分别为 32 与 64,激活函数为 Relu)、2 个池化层(采用最大池化的方式以保留更多的特征信息,步长为 1)和全连接层(数据由卷积层和池化层处理后经全连接层按时间顺序转化输出)组成;GRU 模型结构包含 2 层 GRU 隐藏层,采用 Adam 训练其内部参数^[24],激活函数使用 tanh 函数,时间窗口大小为 10,批处理设置为 60;ISSA 对 GRU 的 m 、 ϵ 优化过程中,参数设置如下:麻雀种群数量为 20,发现者比例为 0.2、安全值 ST 为 0.8,侦查者比例为 0.1,算法最大迭代次数 $iter_{max}$ 为 100, m 与 ϵ 的搜索范围分别为 [1, 32] 和 [-0.01, 0.01]。

利用训练集数据对 m 与 ϵ 进行优化的结果如图 4 所示,ISSA 对 GRU 模型中超参数进行优化过程的收敛速度比 SSA 优化速度快,对模型的关键参数有着更强的寻优能力,随着迭代次数的

不断增加,SSA-GRU 与 ISSA-GRU 的适应度值最终稳定在 2.236 和 1.513,GRU 模型 2 层隐藏层神经元的个数 m 分别取值 8 和 16、 ϵ 为 0.002 2 时,本文所提出的 CNN-ISSA-GRU 混合模型预测方法在保证较快收敛速度的同时极大提高了预测精度。

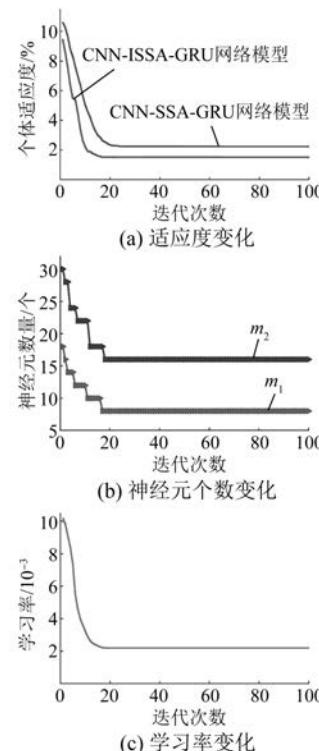


图 4 CNN-ISSA-GRU 最优 m 、 ϵ 和 $iter_{max}$ 的变化

3.3 CNN-ISSA-GRU 模型预测结果分析

本文所提出的基于 CNN-ISSA-GRU 混合模型的短期负荷预测方法,对测试集数据中单独一天和连续半年内的负荷预测结果评价指标如表 1 所示,表中 FA_{avg} 表示预测精度的平均值。

表 1 不同预测模型对比

模型	一天		半年	
	MAPE/%	FA _{avg}	MAPE/%	FA _{avg}
RNN	3.386	96.614	3.590	96.410
LSTM	2.965	97.035	3.269	96.731
GRU	2.776	97.224	2.555	97.445
CNN-GRU	1.694	98.306	2.316	97.684
CNN-SSA-GRU	1.785	98.215	2.228	97.772
CNN-ISSA-GRU	1.113	98.887	1.318	98.682

通过分析可知,CNN-ISSA-GRU 模型无论是在单独一天还是连续半年内进行日前短期负荷预测时,均比其他 5 种对比模型具有更高的预测精度。连续半年的测试中,CNN-ISSA-GRU 方法相比 CNN-GRU、GRU、LSTM、RNN 4 类预测模型,MAPE 指标分别降低了 0.088%、0.327%、1.041% 和 1.3624%, FA_{avg} 指标分别提高了 0.09%、0.33%、1.06% 和 1.39%,表明 GRU 模型在处理时间序列问题上有较好的预测效果,也反映了使用麻雀搜索来优化其超参数的必要性;进一步试验将提出的 CNN-ISSA-GRU 模型与 CNN-SSA-GRU 预测效果进行对比,其中 MAPE 降低了 0.91%, FA_{avg} 提高了 0.92%,表明使用 ISSA 对 GRU 模型进行参数优化不仅自动得到其最优解,还进一步提高了预测精度,具有更高的可靠性。

表 2 为本文所提的 CNN-ISSA-GRU 预测模型与其他 5 种方法对测试集数据中 4 个季节进行负荷预测的平均误差汇总表,从表中可以看出本文

所提的方法在一年不同季节中预测误差均最低,四季平均预测精度达到了 98.624%,相较于 CNN-SSA-GRU、CNN-GRU、GRU、LSTM、RNN 模型,MAPE 指标分别降低了 1.038%、1.118%、1.402%、1.996% 和 2.356%,RMSE 分别降低了 44.047、47.936、75.029、125.368 和 154.21,对试验数据进行综合分析表明本文所提出的模型在电网短期负荷预测方面有着更高的预测精度和稳定性。

表 3 汇总了不同算法模型验证一天中每个小时的第一个 15 min 时监测负荷的实际值、预测值以及两者的绝对百分比误差。结果表明本文所提的模型在 24 个监测点的预测结果平均绝对百分比误差、最大绝对百分比误差分别为 1.205%、3.038%,相比于 CNN-SSA-GRU、CNN-GRU、GRU、LSTM 和 RNN 模型,MAPE 分别降低了 0.986%、1.179%、1.337%、1.849% 和 2.002%,证明所提 CNN-ISSA-GRU 预测模型的平均误差和最大误差均优于其他模型,有着更高的预测精度。

表 2 不同模型不同季节预测结果比较

模型	春季		夏季		秋季		冬季		四季平均	
	MAPE/%	RMSE								
RNN	3.629	251.735	3.233	235.222	4.336	302.182	3.728	258.647	3.732	261.647
LSTM	3.197	228.911	2.854	180.715	3.894	274.625	3.544	246.967	3.372	232.805
GRU	2.832	184.198	2.302	142.218	3.348	239.413	2.629	164.034	2.778	182.466
CNN-GRU	2.264	138.212	2.429	151.715	2.611	164.615	2.673	166.951	2.494	155.373
CNN-SSA-GRU	2.365	145.516	1.986	125.655	2.718	176.718	2.585	158.046	2.414	151.484
CNN-ISSA-GRU	1.201	102.853	1.446	109.731	1.372	106.148	1.486	111.015	1.376	107.437

表 3 实际值和预测值及绝对百分比误差

预测 时刻	真实值/ kW	CNN-ISSA-GRU		CNN-SSA-GR		CNN-GRU		GRU		LSTM		RNN	
		预测值/ kW	绝对百 分比误 差/%	预测值/ kW	绝对百 分比误 差/%	预测值/ kW	绝对百 分比误 差/%	预测值/ kW	绝对百 分比误 差/%	预测值/ kW	绝对百 分比误 差/%	预测值/ kW	绝对百 分比误 差/%
0:15	5 165.78	5 063.415	1.982	5 060.896	2.03	4 978.997	3.616	5 290.02	2.405	5 237.505	1.389	5 110.708	1.066
1:15	4 809.43	4 822.347	0.269	4 720.445	1.85	4 729.187	1.669	5 042.98	4.856	4 985.666	3.664	4 891.328	1.703
2:15	4 627.20	4 634.046	0.148	4 518.767	2.343	4 535.067	1.991	4 862.76	5.091	4 792.975	3.583	4 729.152	2.203
3:15	4 461.63	4 489.063	0.615	4 374.489	1.953	4 390.680	1.59	4 704.06	5.434	4 656.474	4.367	4 591.104	2.902
4:15	4 375.24	4 412.638	0.855	4 260.651	2.619	4 283.319	2.101	4 586.16	4.821	4 532.113	3.585	4 475.820	2.299
5:15	4 322.96	4 347.667	0.571	4 212.438	2.557	4 294.530	0.658	4 523.71	4.644	4 460.077	3.172	4 406.687	1.937
6:15	4 395.75	4 387.069	0.197	4 271.992	2.815	4 405.547	0.223	4 476.30	1.832	4 455.877	1.368	4 390.613	0.117
7:15	4 801.71	4 715.253	1.801	4 635.511	3.461	5 025.504	4.661	4 562.95	4.972	4 655.355	3.048	4 644.327	3.278
8:15	6 090.82	6 199.668	1.787	5 959.925	2.149	6 329.884	3.925	6 444.07	5.800	5 811.187	4.591	5 698.610	6.439
9:15	7 446.01	7 322.484	1.659	7 242.506	2.733	7 539.982	1.262	7 230.04	2.900	7 106.383	4.561	7 232.433	2.868
10:15	7 693.50	7 734.293	0.530	7 485.693	2.701	7 996.319	3.936	7 531.02	2.112	7 505.238	2.447	7 517.773	2.284
11:15	7 740.41	7 793.677	0.688	7 575.078	2.136	7 872.091	1.701	7 6750.1	0.844	7 546.431	2.506	7 770.208	0.385
12:15	6 413.92	6 436.844	0.357	6 168.358	3.829	6 045.094	5.750	6 394.31	0.306	6 711.256	4.636	6 513.405	1.551
13:15	5 677.95	5 686.988	0.159	5 607.418	1.242	5 801.380	2.174	5 933.54	4.502	5 823.211	2.558	5 965.873	5.071

续表 3

预测 时刻	真实值/ kW	CNN-ISSA-GRU		CNN-SSA-GR		CNN-GRU		GRU		LSTM		RNN	
		预测值/ kW	绝对百 分比误 差/%	预测值/ kW	绝对百 分比误 差/%	预测值/ kW	绝对百 分比误 差/%	预测值/ kW	绝对百 分比误 差/%	预测值/ kW	绝对百 分比误 差/%	预测值/ kW	绝对百 分比误 差/%
14:15	6 967.00	6 869.612	1.398	6 874.010	1.335	6 870.490	1.385	7 009.51	0.610	6 901.894	0.935	7 124.448	2.260
15:15	7 103.95	7 205.567	1.430	7 009.965	1.323	6 927.735	2.481	7 095.91	0.113	7 192.740	1.250	7 307.366	2.863
16:15	7 190.02	7 331.152	1.963	7 111.886	1.087	7 276.695	1.206	7 255.13	0.906	7 273.917	1.167	7 447.964	3.588
17:15	6 992.92	7 141.501	2.125	7 015.679	0.325	6 652.083	4.874	6 911.11	1.170	7 340.448	4.970	7 333.441	4.870
18:15	6 068.45	5 908.361	2.638	6 134.646	1.091	6 183.501	1.896	6 044.26	0.399	6 103.653	0.580	6 176.566	1.782
19:15	6 261.68	6 182.646	1.262	6 432.702	2.731	6 349.123	1.396	6 359.35	1.560	6 441.572	2.873	6 418.417	2.503
20:15	5 960.70	6 019.834	0.992	6 129.588	2.833	6 072.550	1.876	6 033.06	1.214	5 808.633	2.551	6 384.054	7.102
21:15	5 802.51	5 883.137	1.390	5 956.249	2.65	6 018.766	3.727	5 970.55	2.896	5 603.125	3.436	6 224.519	7.273
22:15	5 595.03	5 425.066	3.038	5 706.935	2.00	5 633.037	0.679	5 604.56	0.170	5 223.490	6.641	5 757.131	2.897
23:15	5 255.95	5 312.305	1.072	5 403.009	2.798	5 127.556	2.443	5 332.52	1.457	5 076.312	3.418	5 662.104	7.727
平均	—	—	1.205	—	2.191	—	2.384	—	2.542	—	3.054	—	3.207
最大	—	—	3.038	—	3.829	—	5.75	—	5.8	—	6.641	—	7.727

2015 年 12 月某天负荷实际值与其他模型预测值的大小变化曲线如图 5 所示, 其对应预测点的绝对百分比误差变化折线图如图 6 所示, 从图中可以看出每种预测模型都可以达到对短期电力负荷预测精度的要求, 但在负荷变化趋势较大的波峰波谷时, 本文所提出的 CNN-ISSA-GRU 模型方法对实际峰谷负荷数据拟合能力更强, 预测误差最小, 与日负荷实际变化趋势也基本保持一致, 为电网进行短期负荷预测提供理论支持。

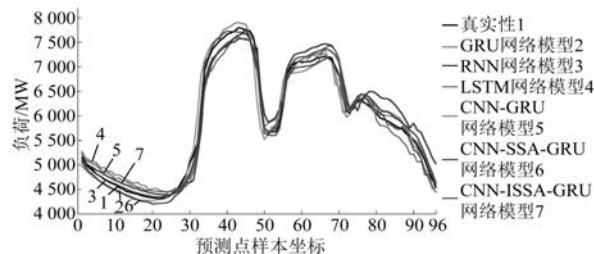


图 5 负荷预测曲线与实际曲线对比图

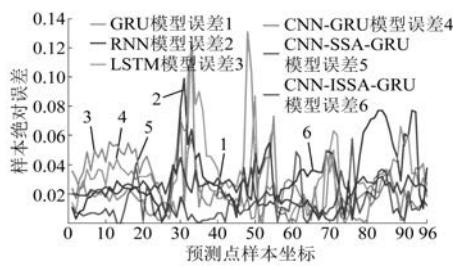


图 6 样本绝对误差对比

4 结语

为提高电网短期负荷预测的精度, 本文提出

了一种基于 CNN-ISSA-GRU 的短期电力负荷预测方法。得出以下结论:

(1) 采用 CNN 独特的卷积层与池化层, 多维度扫描和压缩数据、自动提取所需特征, 构造成时间序列输入预测模型;

(2) 使用 ISSA 不断自动迭代更新, 在达到最高预测精度的前提下, 寻找 GRU 模型关键参数的最优值, 克服了传统经验参数选择导致的模型预测准确度低的问题;

(3) 与传统的 GRU、LSTM 和 RNN 预测模型相比较, 本文所提基于 CNN-ISSA-GRU 混合模型的负荷预测方法具有更高的预测精度和可靠性。

【参考文献】

- [1] 庞昊, 高金峰, 杜耀恒. 基于多神经网络融合的短期负荷预测方法[J]. 电力自动化设备, 2020, 40(6): 37.
- [2] KHWAJA A S, ZHANG X, ANPALAGAN A, et al. Boosted neural networks for improved short-term electric load forecasting[J]. Electric Power Systems Research, 2017, 143: 431.
- [3] 叶林, 滕景竹, 蓝海波, 等. 变尺度时间窗口和波动特征提取的短期风电功率组合预测[J]. 电力系统自动化, 2017, 41(17): 29.
- [4] 胡玉可, 夏维, 胡笑旋, 等. 基于循环神经网络的船舶航迹预测[J]. 系统工程与电子技术, 2020, 42(4): 871.
- [5] 赵佩, 代业明. 基于实时电价和加权灰色关联投影的 SVM 电力负荷预测[J]. 电网技术, 2020, 44

- (4) : 1325.
- [6] TANG D, LI C, JI X, et al. Power load forecasting using a refined LSTM [C] // Proceedings of the 2019 11th International Conference on Machine Learning and Computing, 2019; 104-108.
- [7] 张宏鹏, 黄长强, 轩永波, 等. 用门控循环单元实时预测空战飞行轨迹 [J]. 系统工程与电子技术, 2020, 42(11) : 2546.
- [8] 牛哲文, 余泽远, 李波, 等. 基于深度门控循环单元神经网络的短期风功率预测模型 [J]. 电力自动化设备, 2018, 38(5) : 36.
- [9] 陈振宇, 刘金波, 李晨, 等. 基于 LSTM 与 XGBoost 组合模型的超短期电力负荷预测 [J]. 电网技术, 2020, 44(2) : 614.
- [10] 张鹏, 齐波, 张若愚, 等. 基于经验小波变换和梯度提升径向基的变压器油中溶解气体预测方法 [J]. 电网技术, 2021, 45 (9) : 3745.
- [11] 邓带雨, 李坚, 张真源, 等. 基于 EEMD-GRU-MLR 的短期电力负荷预测 [J]. 电网技术, 2020, 44(2) : 593.
- [12] 谢乐, 仇炜, 李振伟, 等. 基于变分模态分解和门控循环单元神经网络的变压器油中溶解气体预测模型 [J]. 高电压技术, 2022, 48(2) : 653.
- [13] 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.
- [14] 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.
- [15] 陈海文, 王守相, 王绍敏, 等. 基于门控循环单元
- ~~~~~
- (上接第 78 页)
- [13] 高敬业, 杨鸿雁, 蔡潇, 等. 基于形态学的贯通式同相 AT 牵引供电系统牵引网单端电流方向暂态保护 [J]. 电机与控制应用, 2021, 48(8) : 98.
- [14] WU Z, HUANG N. Ensemble empirical mode decomposition: a noise-assisted data analysis method [J]. Advances in Adaptive Data Analysis, 2009, 1 (1) : 1.
- [15] WANG Y H, YEH C H, YOUNG H W V, et al. On the computational complexity of the empirical mode decomposition algorithm [J]. Physica A: Statistical Mechanics and its Applications, 2014, 400(2) : 159.
- [16] KHAN S I, DIAB M S, MAHMOUD S A. Design of low power Teager energy operator circuit for sleep spindle and K-Complex extraction [J].
- 网络与模型融合的负荷聚合体预测方法 [J]. 电力系统自动化, 2019, 43(1) : 65.
- [16] KANG K, SUN H B, ZHANG C K, et al. Short-term electrical load forecasting method based on stacked auto-encoding and GRU neural network [J]. Evolutionary Intelligence, 2019, 12: 385.
- [17] 孔祥玉, 郑锋, 鄂志君, 等. 基于深度信念网络的短期负荷预测方法 [J]. 电力系统自动化, 2018, 42(5) : 133.
- [18] XUE J, SHEN B. A novel swarm intelligence optimization approach: sparrow search algorithm [J]. Systems Science & Control Engineering, 2020, 8 (1) : 22.
- [19] 马晨佩, 李明辉, 巩强令, 等. 基于麻雀搜索算法优化支持向量机的滚动轴承故障诊断 [J]. 科学技术与工程, 2021, 21(10) : 4025.
- [20] 刘可真, 阮俊枭, 赵现平, 等. 基于麻雀搜索优化的 Attention-GRU 短期负荷预测方法 [J]. 电力系统及其自动化学报, 2022, 34(4) : 99.
- [21] 李丹丹, 吴宇翔, 朱聪聪, 等. 基于麻雀搜索与遗传算法的 J-A 磁滞模型参数辨识方法 [J/OL]. 高电压技术, doi: 10.13336/j.1003-6520.hve.20210840.
- [22] 张伟康, 刘升, 任春慧. 混合策略改进的麻雀搜索算法 [J]. 计算机工程与应用, 2021, 57(24) : 74.
- [23] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述 [J]. 计算机学报, 2017, 40(6) : 1229.
- [24] KINGMA D, BA J. Adam: A method for stochastic optimization [J]. arXiv: 1412. 6980, 2014.
- ~~~~~

Microelectronics Journal, 2020, 100(1) : 104785.

- [17] KARIMIAN A, HOSSEINIAN S H. Online tracking of voltage flicker for inverter-based distributed generation using Teager energy operator [J]. International Transactions on Electrical Energy Systems, 2020, 30(4) : e12292.
- [18] LI Y, WU L, LI J, et al. DC fault detection in MTDC systems based on transient high frequency of current [J]. IEEE Transactions on Power Delivery, 2019, 34 (3) : 950.
- [19] 常非, 赵丽平, 冯金博. 五电平交直交变换器在贯通同相供电中的应用 [J]. 电力系统及其自动化学报, 2015, 27(1) : 26.