

DOI: 10.19783/j.cnki.pspc.211373

基于新型日期映射法和 ISGU 混合模型的短期电力负荷预测

陈梓行¹, 金涛^{1,2}, 郑熙东^{1,2}, 庄致远¹

(1. 福州大学电气工程与自动化学院, 福建 福州 350116;

2. 智能配电网装备福建省高校工程研究中心(福州大学), 福建 福州 350116)

摘要: 针对电力负荷非线性、预测条件多样性、预测模型参数设置主观性等问题, 提出一种基于强适应性的日均负荷日期映射法、高非线性拟合性能的门控循环单元(Gate Recurrent Unit, GRU)和强搜索性能的改进麻雀搜索算法(Improved Sparrow Search Algorithm, ISSA)相结合的 ISSA-GRU(ISGU)混合模型进行短期电力负荷预测(Short-term Load Forecasting, STLF)。首先, 利用日均负荷日期映射法对星期-节假日因素进行映射, 解决该因素因非数字化导致不易输入预测网络的问题。随后, 从诸多相关因素中筛选出高度相关特征值, 以此解决预测条件多样性问题。最后, 构建 GRU 网络进行负荷预测, 并引入 ISSA 算法对 GRU 网络参数进行客观配置。为验证 ISGU 混合模型的有效性, 采用新加坡电力负荷数据进行实验, 并将实验结果与现有算法进行比较。实验结果表明, 所提方法对 STLF 具有良好性能, 有效提高了 STLF 统计标准的精度指标。

关键词: 短期电力负荷预测; 改进麻雀搜索算法; 门控循环单元; 日均负荷日期映射; ISGU 混合模型

Short-term power load forecasting based on a new date mapping method and an ISGU hybrid model

CHEN Zixing¹, JIN Tao^{1,2}, ZHENG Xidong^{1,2}, ZHUANG Zhiyuan¹

(1. College of Electrical Engineering and Automation, Fuzhou University, Fuzhou 350116, China;

2. Fujian Key Laboratory of New Energy Generation and Power Conversion, Fuzhou 350116, China)

Abstract: Given the nonlinear power load, diversity of prediction conditions, subjectivity of parameter setting of the prediction model, etc., an ISSA-GRU (ISGU) hybrid model based on the combination of a date mapping method based on daily average load with strong adaptability, a Gate Recurrent Unit (GRU) with high non-linear fitting performance and an improved sparrow search algorithm (ISSA) with strong search ability are proposed for short-term load forecasting (STLF). First, the data mapping method based on daily average load is used to map the week-holiday factor to solve the problem that it is difficult to input the prediction network because of non-digitization. Then, highly relevant eigenvalues are selected from many correlated factors to deal with the diversity of prediction conditions. Finally, the GRU network is constructed for load forecasting, and the ISSA algorithm is used to configure GRU network parameters objectively. To verify the effectiveness of the ISGU hybrid model, we use the Singapore power load data experiment, and compare the experimental results with the existing algorithms. The results show that this method has good performance for STLF and effectively improves the accuracy of STLF statistical standards.

This work is supported by the National Natural Science Foundation of China (No. 51977039).

Key words: short-term load forecasting; improved sparrow search algorithm (ISSA); gate recurrent unit (GRU); date mapping method based on daily average load; ISSA-GRU (ISGU)

0 引言

随着我国社会经济的迅猛发展, 市场对电能供应的安全性、可靠性和经济性等方面的要求逐渐提

高。面对电能需求随时间不断变化的特点, 电力部门应尽可能保证电能供需处于动态平衡状态, 以此追求最优的发电设备利用率与调度经济性, 避免产能过剩或供应不足。精确的电力负荷预测不仅有助于规划供电设备的运行检修计划, 保证供电可靠性, 而且还能为新机组投入计划与电网扩容改建计划给

基金项目: 国家自然科学基金资助项目(51977039)

予一定参考。现如今, 多样化预测模型、智能化电网改造给负荷预测提供技术以及数据支持。

近年来, 人工智能技术在电力负荷预测领域表现突出。浅层学习、深度学习以及其他机器学习算法百花齐放, 在负荷预测中取得良好的效果。基于浅层学习算法, 文献[1-2]利用 BP 神经网络非线性映射能力进行负荷预测, 但 BP 的反向传播算法容易使得其陷入局部最优。文献[3]中利用极限学习机 (Extreme Learning Machine, ELM) 进行风电功率预测, 相较 BP 网络, ELM 采用单隐含层结构与最小二乘法的权重更新策略, 使得 ELM 计算速度迅速。文献[4]中提出利用混合内核的核极限学习机 (Kernel Extreme Learning Machine, KELM) 进行负荷预测, 混合核函数的加入提高单核 KELM 的预测精度。基于其他机器学习算法, 支持向量机 (Support Vector Machine, SVM)、随机森林等人工智能技术也在负荷预测领域广泛使用。文献[5-6]采用随机森林算法进行负荷预测, 所需设置参数少, 但容易在解决回归问题时出现过拟合问题。文献[7-8]采用 SVM 算法进行负荷预测, 其算法鲁棒性好、泛化能力强, 但其模型训练耗时长, 面对大规模样本数据乏力。

相比浅层学习算法, 深度学习算法的特征提取能力更为强大, 并能处理海量数据集。循环神经网络 (Recurrent Neural Network, RNN) 擅于挖掘时间序列数据特点, 但其存在梯度爆炸与梯度消散等问题。长短期记忆网络 (Long Short-Term Memory, LSTM) 基于 RNN 结构进行改进, 改善 RNN 所存在的问题。文献[9-10]均提出采用 LSTM 进行负荷预测, 其中文献[9]将卷积神经网络 (Convolutional Neural Networks, CNN) 置于 LSTM 前端进行特征提取, 文献[10]利用多元线性回归算法 (Multivariable Linear Regression, MLR) 与 LSTM 分别对信号分解后的负荷信号高频与低频分量进行预测。文献[11]在 2014 年提出 GRU 网络, GRU 对 LSTM 网络进行简化, 该方法不仅在负荷预测中取得良好效果^[12-16], 并且还在风速、风电、电价预测中有优秀表现^[17-19]。

建立机器学习预测模型时需要设置若干参数, 模型参数与预测结果精度相关联, 然而现有模型参数设置未有客观标准。因此许多学者针对该问题提出引入各种智能寻优算法对机器学习预测模型参数进行优化的混合模型。文献[20]中采用改进果蝇算法对 GRNN 的平滑因数进行优化, 并在短期电力负荷预测中取得良好的效果。文献[1]将遗传算法 (Genetic Algorithm, GA) 与模拟退火算法结合, 并引入 BP 网络中, 优化 BP 网络参数的设置, 其实验结果显示预测误差从 1.913% 降至 1.384%。文献[21-22]

引入粒子群算法 (Particle Swarm Optimization, PSO) 分别对深度置信网络与 SVM 参数进行寻优, 但倘若 PSO 算法的加速系数与最大速度设置的不合理, 则会导致粒子群错过最优解。在文献[7]中选取布谷鸟算法优化 SVM 模型参数。文献[23]采用灰狼算法 (Grey Wolf Optimizer, GWO) 优化最小二乘支持向量机, 该方法所需设置的参数少, 使其在澳大利亚新南威尔士、维多利亚和昆士兰州三组电力负荷数据中有良好的应用效果。

综上所述, 本文提出基于日均负荷日期映射法和 ISGU 混合网络模型的 STLf。首先, 提出基于日均负荷日期映射法将星期-节假日因素数字化。然后, 利用皮尔逊相关系数 (Pearson correlation coefficient, PCCs) 与互信息 (Mutual Information, MI) 算法对众多特征值进行筛选, 充分挖掘出相关性强的特征值。最后, 本文构建由 ISSA 参数寻优算法与 GRU 融合的混合模型进行 STLf。日均负荷日期映射法的自调整能力可以客观应对不同环境下负荷数据集的星期-节假日映射。ISGU 混合算法考虑负荷预测的条件性, 并提高对非线性负荷信号的拟合能力。ISSA 算法的嵌入解决 GRU 网络参数设置问题, 并且相较麻雀搜索算法 (Sparrow Search Algorithm, SSA), ISSA 算法具有更丰富的种群优势, 以及更优秀的搜索能力。因此, ISGU 混合算法在电力负荷预测领域有很大潜力, 本文通过新加坡负荷数据分析和仿真, 验证了该算法的可行性。

1 短期电力负荷特性

电力负荷预测模型刻画出诸多相关因素与电力负荷之间的内在联系, 如式(1)所示。

$$\mathbf{Y}^{\text{pred}} = f(\mathbf{PA}, \mathbf{RF}) = pa_1 \cdot rf_1 + L + pa_k \cdot rf_k \quad (1)$$

式(1)中的模型参数, 根据目标函数式(2)进行调整, 由此建立电力负荷预测模型。

$$\text{Minimize: } Loss = \|\mathbf{Y}^{\text{pred}} - \mathbf{Y}^{\text{act}}\|^2 \quad (2)$$

式中: \mathbf{Y}^{pred} 为电力负荷预测值; \mathbf{Y}^{act} 为电力负荷真实值; \mathbf{PA} 为预测模型参数; \mathbf{RF} 为相关因素。

根据电力负荷预测时间长短分类, 可分为超短期、短期、中期以及长期电力负荷预测。其中短期电力负荷预测是对未来若干日的负荷进行预测。精确的短期电力负荷预测为电力部门的停机与发电计划提供依据, 也为电力系统的稳定性与安全性提供保障。

诸多外部环境因素和人类用电行为影响电力负荷的变化。如图 1 所示, 局部时刻电力负荷的波动反映外部环境因素与人为因素的不固定性对负荷的

影响；但从宏观角度分析，人类的用电行为蕴含规律性，使得电力负荷的变化又呈现周期性。由于电力负荷的波动性与周期性，使得电力负荷预测具有不确定性、条件性、时间性以及多方案性。如图 2 所示，短期电力负荷受众多外部因素影响，其中气候因素与星期因素尤为明显，而在不同环境下，相关因素的影响程度也会不同，使电力负荷预测具有条件性和多方案性。并且，相关因素随时间变化，导致电力负荷预测的不确定性。

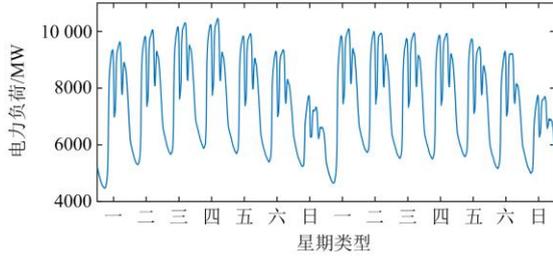


图 1 负荷周期变化图

Fig. 1 Load cycle diagram

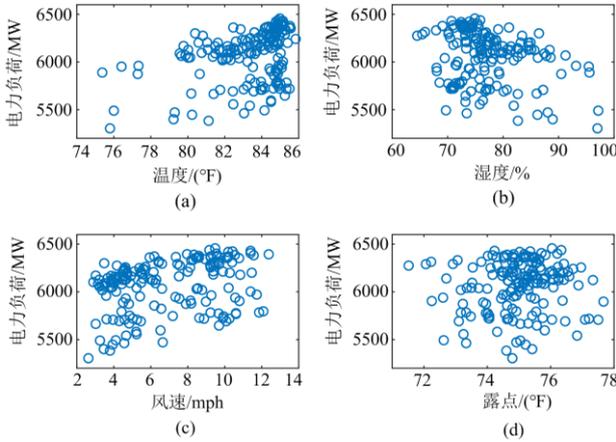


图 2 负荷与相关因素之间关系

Fig. 2 Relationship between load and related factors

电力负荷的非线性、负荷预测的不确定性与条件性等问题给 STLF 带来困难。本文旨在筛选出有效相关因素以解决负荷预测条件多样性问题，寻找对非线性负荷拟合能力强的预测模型，并引入合适的参数寻优算法配置预测模型参数。

2 短期电力负荷预测 ISGU 算法

2.1 基于日均负荷日期因素映射

由于短期电力负荷预测的条件性特点，使影响电力负荷的相关因素众多。其中星期与节假日为非数字化因素，不易输入至预测模型中，因此本文提出一种基于日均负荷日期因素映射方法(“星期-节

假日因素”下述简称为“日期因素”)，其原理如下所述。

现假设各星期类型平均负荷所组成的矩阵为 $\mathbf{W}_k = [W_{\text{mon}}, W_{\text{tue}}, W_{\text{wed}}, W_{\text{thu}}, W_{\text{fri}}, W_{\text{sat}}, W_{\text{sun}}]$ ，则星期因素映射方式如式(3)所示。

$$\mathbf{W}_{\text{map}} = b \times e^{\frac{W_k}{\max(W_k)}} - \min \left(b \times e^{\frac{W_k}{\max(W_k)}} \right) + d \quad (3)$$

式中： \mathbf{W}_{map} 为星期因素映射值；缩放倍数 $b \in (0, \infty)$ 、 $d \in (0, \infty)$ 为常数。

节假日映射方式同理于星期映射，即利用节假日平均负荷值与其对应的星期类型的平均负荷值进行处理。当分别求出两者映射值后，根据式(4)得星期-节假日映射值(简称“日期映射”)。

$$\mathbf{WH}_{\text{map}} = \mathbf{W}_{\text{map}} + \mathbf{H}_{\text{map}} \quad (4)$$

式中： \mathbf{WH}_{map} 为星期-节假日映射值； \mathbf{H}_{map} 为节假日映射值。

2.2 GRU 网络

本文采用 PCCs 与 MI 算法对众多电力负荷的相关因素进行筛选，筛选出的特征值记为 \mathbf{C}_v ，其原理如式(5)、式(6)所示。

$$PCCs(\mathbf{F}, \mathbf{x}) = \frac{\sum_{i=1}^I (F_i - \bar{F})(x_i - \bar{x})}{\sqrt{\sum_{i=1}^I (F_i - \bar{F})^2} \sqrt{\sum_{j=1}^J (x_j - \bar{x})^2}} \quad (5)$$

$$MI(\mathbf{F}, \mathbf{x}) = \sum_{i=1}^I \sum_{j=1}^J p(F_j, x_i) \log_2 \left(\frac{p(F_j, x_i)}{q(F_j)q(x_i)} \right) \quad (6)$$

式中： \mathbf{x} 为电力负荷信号； \mathbf{F} 为相关因素； $p(\cdot, \cdot)$ 为联合分布函数； $q(\cdot)$ 为边缘分布函数。

将筛选出的特征值 \mathbf{C}_v 输入至 GRU 网络^[11]中进行负荷预测。

GRU 网络的重置门与更新门分别确定前一时刻状态记忆变量 $\mathbf{h}_{\lambda-1}$ 的遗忘程度与保留程度，式(7)、式(8)分别表示两者所对应的数学模型。

$$\mathbf{r}_{\lambda} = \sigma(\mathbf{W}_r \cdot [\mathbf{h}_{\lambda-1}, \mathbf{C}_v^{\lambda}]) \quad (7)$$

$$\mathbf{z}_{\lambda} = \sigma(\mathbf{W}_u \cdot [\mathbf{h}_{\lambda-1}, \mathbf{C}_v^{\lambda}]) \quad (8)$$

式中： $\sigma(\cdot)$ 为 sigmoid 激活函数； \mathbf{W}_r 为重置门权重； \mathbf{W}_u 为更新门权重； \mathbf{r}_{λ} 为重置门状态； \mathbf{z}_{λ} 为更新门状态。

由重置门状态 \mathbf{r}_{λ} 与 \mathbf{C}_v 、 $\mathbf{h}_{\lambda-1}$ 可得出当前时刻候选状态记忆变量 $\hat{\mathbf{h}}_{\lambda}^o$ ，如式(9)所示。

$$\hat{\mathbf{h}}_{\lambda}^o = \tanh(\mathbf{W}_o \cdot [\mathbf{r}_{\lambda} \cdot \mathbf{h}_{\lambda-1}, \mathbf{C}_v^{\lambda}]) \quad (9)$$

式中: $\tanh(\cdot)$ 为双曲正切激活函数; W_o 为权重。

最后根据更新门状态 z_λ 对 $h_{\lambda-1}$ 、 \hat{h}_λ^o 进行遗忘与保留, 由此获得 GRU 网络输出, 其数学公式如式(10)所示。

$$h_\lambda = (1 - z_\lambda) \times h_{\lambda-1} + z_\lambda \times \hat{h}_\lambda^o \quad (10)$$

将 h_λ 输入至全连接层中可以得到负荷预测结果 Y^{pred} 。

2.3 改进麻雀搜索算法

GRU 网络参数设置利用 ISSA 算法进行寻优, ISSA 算法基于 SSA 算法^[24]改进, 其算法原理如下所述。

首先 ISSA 算法采用对立学习算法生成初始化种群, 以此克服 SSA 算法初始化种群多样性不足的问题。现生成种群规模为 M 、搜索对象规模为 N 的初始化随机种群, 记为 $P'_{M \times N}$, 并根据式(11)生成对立种群。

$$p''_{mn} = lb_n + ub_n - p'_{mn} \quad m = 1, 2, L, M, n = 1, 2, L, N \quad (11)$$

式中: lb_n 表示第 n 个待寻优参数的下限; ub_n 表示第 n 个待寻优参数的上限。

根据 $2M$ 个种群个体所对应适应度的排序, 取前 M 个适应度最优的种群个体作为最终的初始化种群, 记为 $P_{M \times N}$ 。

发现者为种群中适应度良好的个体, 其进行食物搜索并指导其余个体的运动, 该类群体位置更新方式如式(12)所示。

$$P_m^{t+1} = \begin{cases} P_m^t + rand \cdot P_m^t & R_2 < ST \\ P_m^t + Q \cdot L & R_2 \geq ST \end{cases} \quad (12)$$

式中: $R_2 \in [0, 1]$ 和 $ST \in [0.5, 1]$ 分别代表警报值和安全阈值; $rand$ 与 Q 是 $[0, 1]$ 之间的随机数; L 表示 $1 \times N$ 的矩阵, 其元素均为 1。

SSA 算法中发现者在 $R_2 < ST$ 时的位置更新公式使得发现者每个维度都在缩小, 则发现者搜索食物范围受到限制。因此, ISSA 采用鸟群算法对发现者位置更新思路进行替代^[25]。

在麻雀种群的加入者位置更新中引入随机游走策略, 其公式如式(13)一式(15)所示。

$$P_m^{t+1} = \begin{cases} P_m^t + a(t) \cdot c(t) & m > M/2 \\ P_{pd}^{t+1} + |P_m^t - P_{pd}^{t+1}| \cdot A^+ \cdot L & \text{otherwise} \end{cases} \quad (13)$$

$$a(t) = 2 - \frac{t}{t_{\max}} \quad (14)$$

$$A^+ = A^T (AA^T)^{-1} \quad (15)$$

式中: P_{pd} 为发现者当前最佳位置; A 为 $1 \times N$ 矩阵,

其元素随机赋值 1 或 -1; $a(t)$ 为控制因子; $c(t)$ 为满足柯西分布的随机数; t 为当前迭代次数; t_{\max} 为最大迭代次数。

适应度低的加入者为获得更多能量需飞往其他地方进行觅食, 而非跟随发现者。在 SSA 算法中该类加入者的位置更新方式容易使其往搜索边界进行更新, 因此 ISSA 算法引入随机游走位置更新策略。Cauchy 分布式随机步长的随机游走策略所产生的飞行步长差异性大, 使得加入者飞行策略多样化。

麻雀种群中的警戒者是随机产生的, 其位置更新公式如式(16)所示。

$$P_m^{t+1} = \begin{cases} P_{\text{best}}^t + \beta \cdot |P_m^t - P_{\text{best}}^t| & f_m > f_g \\ P_m^t + K \left(\frac{|P_m^t - P_{\text{worst}}^t|}{(f_m - f_w) + \varepsilon} \right) & f_m = f_g \end{cases} \quad (16)$$

式中: P_{best} 为当前全局最优位置; P_{worst} 为当前全局最差位置; β 为 $[0, 1]$ 之间的随机数; K 为 $[-1, 1]$ 之间的随机数; f_m 为当前麻雀个体适应度; f_g 与 f_w 分别为当前全局最优与最差适应度; ε 为趋近于 0 的数, 其用于避免分母为 0。

最后采用贪心算法决定各麻雀个体位置更新结果。

ISSA 算法中的随机数 $rand$ 、 Q 、 β 、 K 均采用如式(17)所示的 PWMLCM 混沌映射产生。

$$x_r^{t+1} = F_p(x_r^t) = \begin{cases} x_r^t / s & 0 \leq x_r^t < s \\ (x_r^t - s) / (0.5 - s) & s \leq x_r^t < 0.5 \\ F_p(1 - x_r^t) & 0.5 \leq x_r^t < 1 \end{cases} \quad (17)$$

式中: 随机数 $x_r \in [0, 1]$; 控制参数 $s \in [0, 0.5]$ 。

2.4 评价指标与算法流程

本文采用相对误差(RE)、平均绝对误差(MAE)、平均绝对百分比误差(MAPE)和均方根误差(RMSE)四个指标对负荷预测精度进行衡量。四者数值越低, 说明预测精度越高, 式(18)一式(20)分别为精度指标的数学表达式。

$$MAE = \frac{1}{\Omega} \sum_{\omega=1}^{\Omega} |Y_{\omega}^{\text{pred}} - Y_{\omega}^{\text{act}}| \quad (18)$$

$$MAPE = \frac{1}{\Omega} \sum_{\omega=1}^{\Omega} \left| \frac{Y_{\omega}^{\text{pred}} - Y_{\omega}^{\text{act}}}{Y_{\omega}^{\text{act}}} \right| \times 100\% \quad (19)$$

$$RMSE = \sqrt{\frac{1}{\Omega} \sum_{\omega=1}^{\Omega} (Y_{\omega}^{\text{pred}} - Y_{\omega}^{\text{act}})^2} \quad (20)$$

式中: Y_{ω}^{pred} 为第 ω 个负荷预测值; Y_{ω}^{act} 为第 ω 个负

荷真实值。

基于 ISGU 算法的短期电力负荷预测流程如图 3 所示，其主要步骤如下：

- 1) 利用日均负荷日期映射法对日期因素进行数字化映射，由此获得日期因素映射值 WH_{map} ；
- 2) 利用 PCCs 与 MI 算法对相关因素 F (例如气候、星期、节假日、历史电力负荷等)进行筛选，选择出合适的特征值 C_v ；
- 3) 构建 GRU 网络进行电力负荷预测，其输入参数为 C_v 。与此同时，将 ISSA 算法引入 GRU 网络的构建，利用 ISSA 算法对 GRU 网络中的隐含层节点数与迭代次数进行寻优，即搜索对象规模 $N = 2$ ；
- 4) 完成 GRU 网络构建，最终获得负荷预测结果 Y^{pred} 。

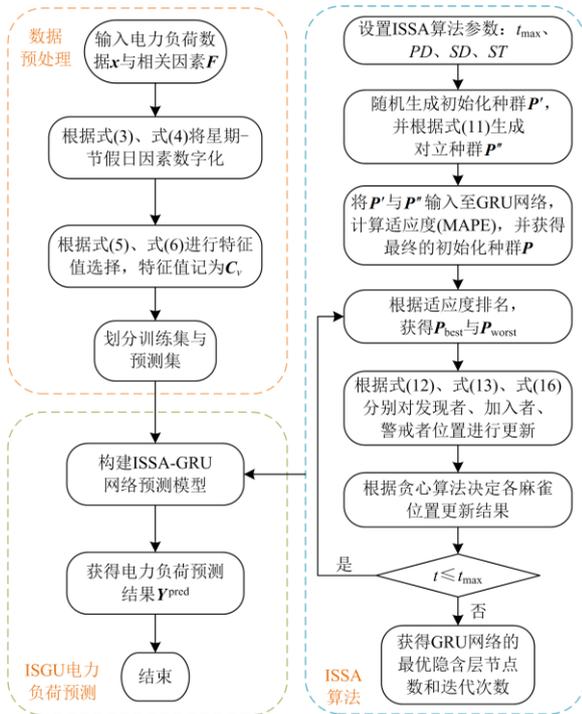


图 3 ISGU 算法流程图

Fig. 3 ISGU algorithm flow chart

3 案例验证

使用 2019 年 7 月 1 日至 12 月新加坡的电力负荷及相关气候数据^[26-27]对本文所提出的基于日均负荷日期映射法以及 ISGU 混合网络的短期电力负荷预测的有效性进行验证。

3.1 日均负荷日期映射法与短期负荷关系分析

为验证映射方法的有效性，本文将用新加坡 12 月 12 日至 15 日及 12 月 25 日的预测结果进行说明。新加坡电力数据如图 4 所示。首先可从图中得出，

新加坡昼夜负荷差异大，负荷具有波动性，特别是在用电高峰期时，其负荷数据波动十分明显。其次，新加坡休息日与节假日的负荷值大幅小于工作日，该现象说明人类在不同日期类型的生活生产方式有着极大的不同，导致需求的负荷量差异大。因此，对于日期因素的处理，不仅需要考虑到不同地区的电力负荷供需的区别，而且还需考虑不同日期类型的负荷供需的区别。

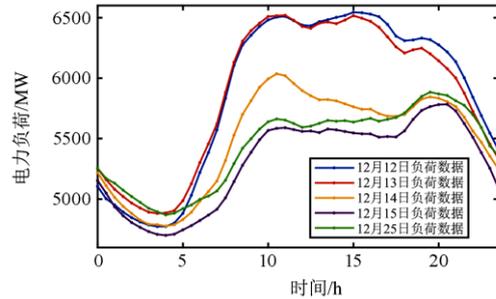


图 4 新加坡电力负荷数据

Fig. 4 Singapore power load data

根据新加坡电力数据以及基于日均负荷日期映射法，新加坡数据组星期一至星期日的映射值分别设置为 0.94、1、0.98、0.98、0.96、0.66、0.5，非节假日、处于工作日的节假日与处于休息日的节假日的映射值分别设置为 0、-0.5、-0.1。

图 5 为新加坡工作日预测相对误差，其体现出现在未考虑日期因素情况下，工作日负荷预测出现偏差，而采用本文映射方式考虑日期因素后，预测负荷值对实际负荷值的拟合程度有提升。表 1 表明相比未考虑日期因素，本文方法使得新加坡实验组的 MAPE 指标降低 0.8825%。

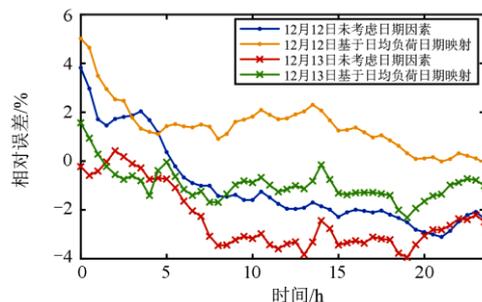


图 5 考虑日期因素的工作日预测误差

Fig. 5 Forecast error of working days considering date factors

图 6 为新加坡休息日的预测相对误差。由于新加坡负荷数据的波动，导致未考虑日期因素时，对休息日负荷趋势的捕捉出现偏差，其中 12 月 16 日各时刻点预测的相对误差的最大值高达 -7.7695%。

由表 1 可得知, 相比未考虑日期因素, 本文方法使 MAPE 指标降低 1.0082%。

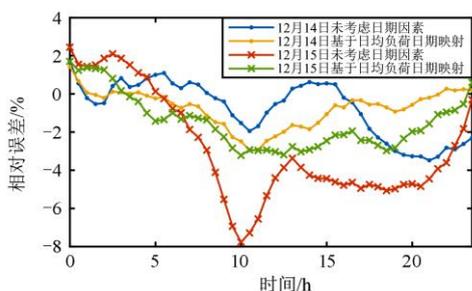


图 6 考虑日期因素的休息日预测误差

Fig. 6 Forecast error of rest days considering date factors

图 7 为新加坡节假日的预测相对误差。由于该节假日处于工作日, 使该日的负荷量骤降。然而, 未考虑日期因素的预测方式无法分辨出该类特殊情况, 使其预测趋势与工作日类似, 故该预测方式无法对节假日的负荷进行预测。本文所提出的方法客观反映节假日情况, 使得预测模型对节假日负荷趋势的拟合十分良好, 其各时刻点的最大预测相对误差仅有 4.5166%, 而未考虑日期因素时的最大相对误差跃升至 18.5974%。由表 1 的结论可以进一步得

出, 相对于未考虑日期因素的预测方式, 本文方法使 MAPE 下降 6.5882%, RMSE 下降 467.8878 MW, MAE 下降 365.6776 MW。基于不同种类精度指标分析结果, 表明本文方法预测效果大幅提升。

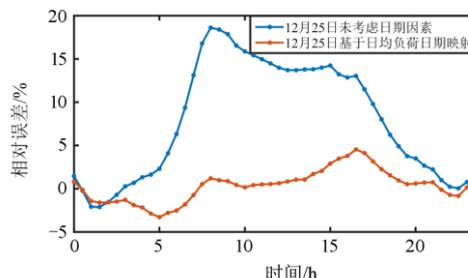


图 7 考虑日期因素的节假日预测误差

Fig. 7 Forecast error of holiday considering date factors

综上所述, 对工作日、休息日及节假日负荷预测情况的分析, 可发现考虑日期因素对捕捉负荷变化趋势效果显著。本文所提出的基于日均负荷日期映射法不仅解决星期-节假日因素的非数字化原因而难作为特征值输入预测网络的问题, 并且由于该方法根据负荷日平均值进行映射, 因此其具有对不同负荷数据集的适应能力。

表 1 考虑日期因素的预测精度

Table 1 Prediction accuracy considering date factors

实验组	方法	工作日			休息日			节假日		
		MAPE/%	RMSE/MW	MAE/MW	MAPE/%	RMSE/MW	MAE/MW	MAPE/%	RMSE/MW	MAE/MW
新加坡	未考虑日期因素	2.1489	146.0499	129.9823	2.3767	169.3172	130.8035	8.0570	568.4707	444.8928
	本文方法	1.2664	86.9445	73.8509	1.3685	94.4407	75.7380	1.4688	100.5829	79.2152

3.2 新加坡负荷数据预测案例分析

该案例分析选取新加坡 2019 年 7 月 1 日至 12 月 11 日电力负荷以及相关数据作为训练集, 12 月 12 日至 15 日数据作为预测集。首先利用 PCCs 对气候以及日期因素进行筛选, 其结果如表 2 所示; 利用 MI 对历史负荷因素进行筛选, 其结果如图 8 所示。

当皮尔逊相关系数 $|PCCs| > 0.2$ 时, 则表示具有相关关系, 因此本文以 $|PCCs| = 0.2$ 作为阈值对其进行特征值筛选。基于表 2 的结果分析得出, 温度、湿度、露点、风速以及日期因素对负荷预测均具有参考性, 故将其考虑为特征值。

表 2 相关因素与负荷之间 PCCs 分析

Table 2 PCCs analysis between related factors and load

实验组	PCCs				
	温度	露点	湿度	风速	日期
新加坡	0.5658	-0.2	-0.5473	0.4011	0.3739

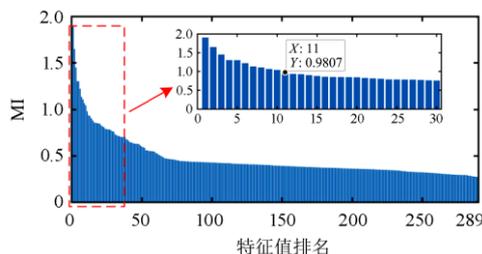


图 8 历史负荷因素 MI 分析结果

Fig. 8 MI analysis results of historical load factor

基于电力负荷周期性的原因, 使历史负荷因素对负荷预测有参照性。然而, 历史电力负荷数据众多, 因此本文引入 MI 算法对历史负荷因素进行筛选。经过多次实验, 选择 0.9807 为历史电力负荷特征值筛选的阈值。

数据预处理完毕后, 将采用 ISGU 混合网络进行负荷预测。ISSA 与 SSA 中安全阈值 ST 设置为 0.8, 加入者与警戒者个数分别为初始种群数的 20%

与 10%。GRU 采用单隐含层网络，学习率为 0.001，miniBatchSize 为 24，权重更新方法为 Adam 算法。

为验证 ISSA 寻优算法的有效性，本文使用 GA、PSO、SSA 算法与其进行对比，实验结果如图 9 所示。从图中可分析得出，GA 算法与 SSA 算法分别第 6 代与第 16 代时陷入局部最优，PSO 算法虽在寻优后期仍不断探索更优参数，但最终预测精度却远不如 SSA 算法。本文所提出的 ISSA 算法提高初始随机种群的多样性，并在第 97 代寻优时进一步提高预测网络精度，因此 ISSA 算法不易陷入局部最优。相较于 GA 与 PSO 寻优算法，ISSA 算法所需设置的参数少，并且 ISSA 算法对预测网络精度的提升明显优于 GA、PSO、SSA 算法，其精度分别比三者高出 0.1197%、0.0926%、0.0543%。

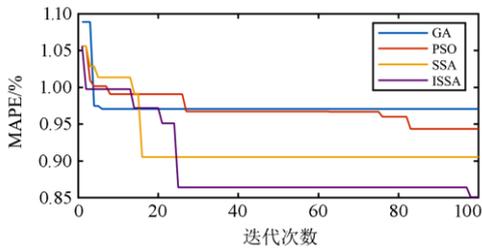


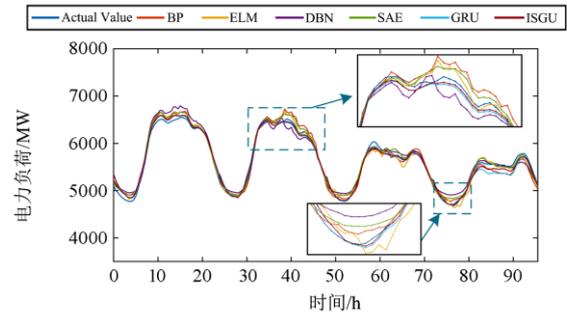
图 9 ISSA 参数寻优分析

Fig. 9 ISSA parameter optimization analysis

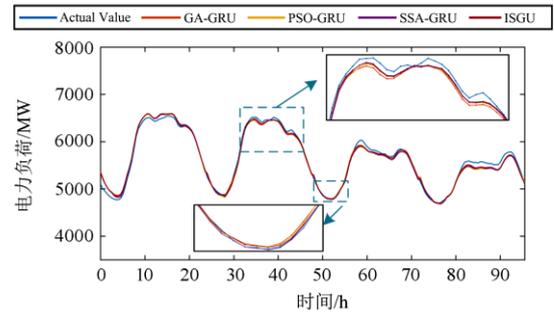
为体现 ISGU 混合模型的优势，本文引入 5 组常用单一预测模型以及 3 组混合预测模型。其中单一预测模型分别为：BP、ELM、深度置信网络(Deep Belief Networks, DBN)、栈式自编码(Stacked Autoencoder, SAE)、GRU；混合预测模型分别为：GA-GRU、PSO-GRU、SSA-GRU。9 种方法的预测结果如图 10 所示。

从图 10 中的整体预测结果以及局部放大部分可明显观察到，单一预测模型对负荷波动区域的预测出现较为明显的偏差，而 ISGU 混合模型预测精度远好于单一预测模型，其对真实负荷值的拟合程度高，能够捕捉负荷波动的趋势；相比其他混合预测模型，由于 ISSA 算法不易陷入局部最优、寻优能力强等优点使 ISGU 模型预测精度仍为最优。图 11 给出了相对误差指标箱型图，分析可得 ISGU 混合网络对未来各时刻点预测的相对误差集中在 0% 附近，相对误差的平均值趋近 0%，说明 ISGU 模型预测的精度与稳定性均有高水准。

表 3 与图 12 给出各模型 MAPE、RMSE 以及 MAE 三大指标。图表表明，GRU 对非线性数据的拟合程度高于其他单一网络模型，其精度相对于 BP、ELM、DBN、SAE 分别提高 0.3712%、0.2263%、



(a) 单一预测模型



(b) 混合预测模型

图 10 各算法预测对比图

Fig. 10 Comparison of each algorithm prediction

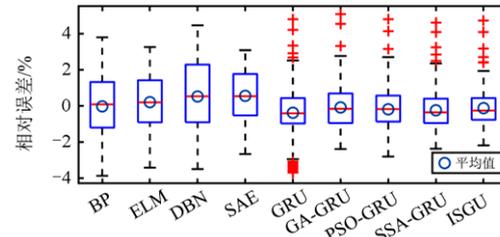


图 11 各算法预测相对误差箱型图

Fig. 11 Box diagram of relative prediction error of each algorithm

表 3 各算法预测精度分析

Table 3 Prediction accuracy analysis of each algorithm

模型	MAPE/%	RMSE/MW	MAE/MW
BP	1.4337	98.5035	81.0710
ELM	1.2888	86.8272	72.1637
DBN	1.7104	116.2084	96.2369
SAE	1.2100	80.1993	67.4310
GRU	1.0625	79.4255	59.6481
GA-GRU	0.9707	67.5862	54.5047
PSO-GRU	0.9436	67.7910	53.1499
SSA-GRU	0.9053	64.6380	51.0604
ISGU	0.8510	61.6966	47.6967

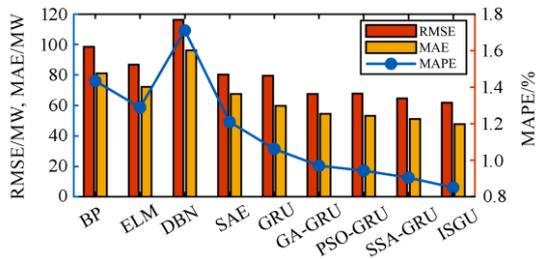


图 12 各算法预测精度对比

Fig. 12 Comparison of prediction accuracy of each algorithm

0.6479%、0.1475%。由此可见，GRU 网络对非线性数据的分析能力与捕捉数据波动的能力十分强大。在引入 ISSA 后，ISGU 网络预测的 MAPE 指标高出 GRU 网络 0.2115%。因此，参数寻优算法的引入可以大幅度提高网络精度，有利于解决人为设置网络参数带来的主观性以及网络精度下降等问题。ISGU 相较于其他混合网络模型，其预测精度表现仍然最为优秀。

4 结论

针对电力负荷非线性、预测条件多样性以及算法参数设置无客观依据等问题，本文提出一种基于日均负荷日期映射法和 ISGU 混合模型的 STLF。首先基于日均负荷日期映射法对日期因素进行数字化，然后利用 PCCs 与 MI 方法进行特征值选择，最后利用 ISGU 混合模型进行预测。论文采用新加坡电力负荷进行算法有效性验证，其负荷波动大，对预测具有一定挑战性。基于实验结果分析，得出以下结论：基于日均负荷日期映射法客观地将日期因素考虑至负荷预测中，并具有自调整能力；ISSA 算法改善主观性调参缺陷，并具有初始种群多样性以及不易陷入局部最优等优点；ISGU 混合网络模型具有良好的非线性拟合能力，并在短期电力负荷预测中有良好表现。

参考文献

- [1] ISLAM B, BAHARUDIN Z, NALLAGOWNDEN P. Development of chaotically improved meta-heuristics and modified BP neural network-based model for electrical energy demand prediction in smart grid[J]. *Neural Computing & Applications*, 2017, 281: 877-891.
- [2] 李国庆, 刘钊, 金国彬, 等. 基于随机分布式嵌入框架及 BP 神经网络的超短期电力负荷预测[J]. *电网技术*, 2020, 44(2): 437-445.
LI Guoqing, LIU Zhao, JIN Guobin, et al. Ultra short-term power load forecasting based on randomly distributive embedded framework and BP neural network[J]. *Power System Technology*, 2020, 44(2): 437-445.
- [3] LI Zhi, YE Lin, ZHAO Yongning, et al. Short-term wind power prediction based on extreme learning machine with error correction[J]. *Protection and Control of Modern Power Systems*, 2016, 1(1): 9-16.
- [4] CHEN Yanhua, KLOFT M, YI Yang, et al. Mixed kernel based extreme learning machine for electric load forecasting[J]. *Neurocomputing*, 2018, 312: 90-106.
- [5] LAHOUAR A, SLAMA J B H. Day-ahead load forecast using random forest and expert input selection[J]. *Energy Conversion and Management*, 2015, 103: 1040-1051.
- [6] 李焱, 贾雅君, 李磊, 等. 基于随机森林算法的短期电力负荷预测[J]. *电力系统保护与控制*, 2020, 48(21): 117-124.
LI Yan, JIA Yajun, LI Lei, et al. Short term power load forecasting based on a stochastic forest algorithm[J]. *Power System Protection and Control*, 2020, 48(21): 117-124.
- [7] ZHANG Xiaobo, WANG Jianzhou, ZHANG Kequan. Short-term electric load forecasting based on singular spectrum analysis and support vector machine optimized by cuckoo search algorithm[J]. *Electric Power Systems Research*, 2017, 146: 270-285.
- [8] 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): 1325-1332.
ZHAO Pei, DAI Yeming. Power load forecasting of SVM based on real-time price and weighted grey relational projection algorithm[J]. *Power System Technology*, 2020, 44(4): 1325-1332.
- [9] 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.
- [10] LI Jian, DENG Daiyu, ZHAO Junbo, et al. A novel hybrid short-term load forecasting method of smart grid using MLR and LSTM neural network[J]. *IEEE Transactions on Industrial Informatics*, 2021, 17(4): 2443-2452.
- [11] CHO K, VAN MERRIENBOER B, GULCEHRE C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation[C] // *Empirical Methods in Natural Language Processing*, 2014, Doha, Qatar: 1724-1734.
- [12] 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): 593-602.
DENG Daiyu, LI Jian, ZHANG Zhenyuan, et al. Short-term electric load forecasting based on EEMD-GRU-MLR[J]. Power System Technology, 2020, 44(2): 593-602.
- [13] 庄家懿, 杨国华, 郑豪丰, 等. 并行多模型融合的混合神经网络超短期负荷预测[J]. 电力建设, 2020, 41(10): 1-8.
ZHUANG Jiayi, YANG Guohua, ZHENG Haofeng, et al. Ultra-short-term load forecasting using hybrid neural network based on parallel multi-model combination[J]. Electric Power Construction, 2020, 41(10): 1-8.
- [14] 郭玲, 徐青山, 郑乐. 基于TCN-GRU模型的短期负荷预测方法[J]. 电力工程技术, 2021, 40(3): 66-71.
GUO Ling, XU Qingshan, ZHENG Le. A forecasting method for short-term load based on TCN-GRU model[J]. Electric Power Engineering Technology, 2021, 40(3): 66-71.
- [15] 李正浩, 李孟凡. 基于深度学习的智能型负荷预测方法的研究[J]. 智慧电力, 2020, 48(10): 78-85, 112.
LI Zhenghao, LI Mengfan. Smart load forecasting method based on deep learning[J]. Smart Power, 2020, 48(10): 78-85, 112.
- [16] 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.
- [17] PENG Zhiyun, PENG Sui, FU Lidan, et al. A novel deep learning ensemble model with data denoising for short-term wind speed forecasting[J]. Energy Conversion and Management, 2020, 207.
- [18] NIU Zhewen, YU Zeyuan, TANG Wenhua, et al. Wind power forecasting using attention-based gated recurrent unit network[J]. Energy, 2020, 196.
- [19] 谢谦, 董立红, 匡向阳. 基于Attention-GRU的短期电价预测[J]. 电力系统保护与控制, 2020, 48(23): 154-160.
XIE Qian, DONG Lihong, SHE Xiangyang. Short-term electricity price forecasting based on Attention-GRU[J]. Power System Protection and Control, 2020, 48(23): 154-160.
- [20] 祝学昌. 基于IFOA-GRNN的短期电力负荷预测方法研究[J]. 电力系统保护与控制, 2020, 48(9): 121-127.
ZHU Xuechang. Research on short-term power load forecasting method based on IFOA-GRNN[J]. Power System Protection and Control, 2020, 48(9): 121-127.
- [21] 梁智, 孙国强, 李虎成, 等. 基于VMD与PSO优化深度信念网络的短期负荷预测[J]. 电网技术, 2018, 42(2): 598-606.
LIANG Zhi, SUN Guoqiang, LI Hucheng, et al. Short-term load forecasting based on VMD and PSO optimized deep belief network[J]. Power System Technology, 2018, 42(2): 598-606.
- [22] SELAKOV A, CVIJETINOVIC D, MILOVIC L, et al. Hybrid PSO-SVM method for short-term load forecasting during periods with significant temperature variations in city of Burbank[J]. Applied Soft Computing, 2014, 16: 80-88.
- [23] YANG Ailing, LI Weide, YANG Xuan. Short-term electricity load forecasting based on feature selection and least squares support vector machines[J]. Knowledge-based Systems, 2019, 163: 159-173.
- [24] XUE Jiankai, SHEN Bo. A novel swarm intelligence optimization approach: sparrow search algorithm[J]. Systems Science & Control Engineering, 2020, 8(1): 22-34.
- [25] 吕鑫, 慕晓冬, 张钧. 基于改进麻雀搜索算法的多阈值图像分割[J]. 系统工程与电子技术, 2021, 43(2): 318-327.
LÜ Xin, MU Xiaodong, ZHANG Jun. Multi-threshold image segmentation based on improved sparrow search algorithm[J]. Systems Engineering and Electronics, 2021, 43(2): 318-327.
- [26] Price information[EB/OL].[2020-08-23]. <https://www.emcsg.com/marketdata/priceinformation#priceDataView>.
- [27] Weather underground[EB/OL].[2020-08-23]. <https://www.wunderground.com/>.

收稿日期: 2021-10-11; 修回日期: 2021-11-30

作者简介:

陈梓行(1997—), 男, 硕士研究生, 研究方向为电力负荷预测; E-mail: 1532810655@qq.com

金涛(1976—), 男, 通信作者, 教授, 博士生导师, 研究方向为智能电网相关技术, 电力系统稳定性分析与控制等; E-mail: jintly@fzu.edu.cn

郑熙东(1996—), 男, 博士研究生, 研究方向为风电并网, 储能平抑风电波动. E-mail: 511869706@qq.com

(编辑 魏小丽)