

DOI:10.19651/j.cnki.emt.2519702

基于 MPSR 和 IHBA-BiGRU-Attention 的 短期电力负荷预测*

于春雨 高健玮 汤培泉 张健 程琪
(青岛理工大学机械与汽车工程学院 青岛 266520)

摘要: 短期电力负荷预测面临着影响因素多、负荷数据本身非线性、非平稳等问题,导致传统预测方法精度不足难以满足工程应用,为此,本文提出了一种基于 MPSR 和 IHBA-BiGRU-Attention 的组合预测模型。首先,利用 Spearman 相关系数优选电力负荷影响因素,与电力负荷序列组成多变量时间序列;其次,对该时间序列进行多变量相空间重构(MPSR),以此作为输入变量;采用融合 Kent 混沌映射、密度因子改造和小孔成像反向学习策略的改进蜜獾算法(IHBA),对双向门控循环单元(BiGRU)网络的超参数进行寻优,并引入注意力(Attention)机制对 BiGRU 的隐藏状态序列进行动态加权,构建基于 MPSR 和 IHBA-BiGRU-Attention 的短期电力负荷预测模型;最后,在澳大利亚和新加坡的电力负荷数据集上进行对比实验,结果表明该模型的平均绝对百分比误差分别为 0.650% 和 1.067%,均低于其他模型,验证了其有效性;同时,在国内南方某地区实际负荷数据集上进行预测实验,平均绝对百分比误差为 1.523%,优于对比模型,验证了所提模型的工程应用价值。

关键词: 短期电力负荷预测;多变量相空间重构;改进蜜獾算法;双向门控循环单元;注意力机制

中图分类号: TN91; TM715 **文献标识码:** A **国家标准学科分类代码:** 470.40

Short-term power load forecasting based on MPSR and IHBA-BiGRU-Attention

Yu Chunyu Gao Jianwei Tang Peiquan Zhang Jian Cheng Qi

(School of Mechanical & Automotive Engineering, Qingdao University of Technology, Qingdao 266520, China)

Abstract: Short-term power load forecasting faces challenges such as multiple influencing factors, nonlinear and non-stationary load data, which make traditional prediction methods insufficient for engineering applications. To address this, this paper proposes a combined prediction model based on MPSR and IHBA-BiGRU-Attention. First, Spearman correlation coefficients are used to select power load influencing factors, forming a multivariate time series with load sequences; subsequently, multivariate phase space reconstruction (MPSR) is applied to this time series as input variables. An improved honey badger algorithm (IHBA) integrating Kent chaotic mapping, density factor modification and small-hole imaging opposite learning strategy is employed to optimize hyperparameters of the bidirectional gated recurrent unit (BiGRU) network, while the attention mechanism is applied to dynamically weight hidden state sequences of BiGRU, constructing a short-term power load prediction model based on MPSR and IHBA-BiGRU-Attention; finally, comparative experiments on power load datasets from Australia and Singapore showed mean absolute percentage errors of 0.650% and 1.067%, respectively, both lower than other models, validating its effectiveness. Additionally, predictive experiments on actual load datasets from a southern region in China achieved a mean absolute percentage error of 1.523%, outperforming competing models and demonstrating the engineering applicability of the proposed model.

Keywords: short-term power load forecasting; multivariate phase space reconstruction; improved honey badger algorithm; bidirectional gated recurrent unit; attention mechanism

0 引言

短期电力负荷预测是现代电力系统智能化调度与优化

运行的核心环节,其精度直接关乎电力系统的经济性、安全性与稳定性^[1]。随着电力市场化改革的推进和新能源规模化接入,电力负荷预测面临着非线性强、波动性大、多因素

收稿日期:2025-08-27

* 基金项目:国家自然科学基金(51977112)、山东省自然科学基金(ZR2024ME210)项目资助

耦合等诸多挑战^[2],传统预测方法在复杂多变的运行环境下已难以满足电网对负荷预测的实际需求^[3]。因此,提出一种能够适应多元复杂环境、具有高预测精度的短期电力负荷预测方法,不仅能够提升电力系统运行效率与安全水平,更是支撑新型电力系统向“源网荷储”协同模式转型的重要保障,具有显著的工程应用价值。

近年来,数据驱动建模技术已成为电力负荷预测的重要手段^[4]。早期短期电力负荷预测研究中,支持向量回归(support vector regression, SVR)^[5]法和极限学习机(extreme learning machine, ELM)^[6]法虽然能够拟合电力负荷数据间的非线性关系,但无法捕捉时序性特征;为了弥补时序性缺陷,程明等^[7]将门控循环单元(gated recurrent unit, GRU)用于电力负荷预测,但其只能利用历史信息,不能考虑未来信息,预测精度有限。为了提升预测精度,唐竹等^[8-9]利用双向门控循环单元(bidirectional gated recurrent unit, BiGRU),综合运用历史与未来信息实现电力负荷预测,但单一模型仍难以达到理想的预测效果。相比之下,组合模型因综合各模型性能优势而得以广泛应用^[10]。如李科等^[11]将多尺度卷积神经网络(multi-scale convolutional neural network, MSCNN)与 BiGRU、注意力(Attention)机制结合,建立了基于 MSCNN-BiGRU-Attention 的组合预测模型,通过对电力负荷数据进行多尺度时序提取,实现电力负荷预测,但存在复杂度与计算成本过高问题。Sun 等^[12]通过自适应噪声完备集合经验模态分解(complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)提取电力负荷的多维度动态特征,并通过 GRU 与随机配置网络(stochastic configuration network, SCN)进行预测,但模型参数选取依赖经验导致泛化性能受限。为提高预测模型泛化能力,俞胜等^[13]则采用极限梯度提升(extreme gradient boosting, XGBoost)决策树对多维负荷数据进行降维和特征提取,结合 Informer 构建组合预测模型,但该方法对数据质量要求较高,且易出现过拟合。以上文献借助序列分解和特征提取算法以减少负荷扰动时对预测模型的影响,但缺乏针对电力负荷内在变化规律的探究。为克服这点,Ma 等^[14]针对存在多个相关特征的时间序列,基于多变量相空间重构(multivariable phase space reconstruction, MPSR),将历史电力负荷序列重构成一个低阶非线性动态系统,从而在高维相空间中捕捉系统的非线性特性,进而提高预测精度,但未解决能超参数自动寻优难题。为此,学者们将优化算法与神经网络相结合,优化预测模型的超参数。如 Wang 等^[15]利用蝴蝶优化算法(butterfly optimization algorithm, BOA)算法对长短期记忆神经网络(long short-term memory, LSTM)的参数进行寻优,取得了一定的成效,但易陷入局部最优;Liu 等^[16]利用黏菌算法(slime mould algorithm, SMA)算法优化 LSTM 的超参数,提高了模型参数的寻优效率,但依然存在寻优精度低、易得到局部极值等问题;朱婷等^[17]用蜜

獾算法(honey badger algorithm, HBA)优化 BiGRU 的超参数,并结合自注意力机制(SelfAttention)预测短期电力负荷,结果虽有提升,但迭代后期 HBA 易陷入局部最优,搜索效率不高。为了改进 HBA 的不足,增强原始的 HBA 算法的鲁棒性,袁媛等^[18]结合 Sine 混沌映射、反馈共享阶段与莱维飞行策略提出了一种多策略改进混沌蜜獾算法(chaotic honey badger algorithm, CHBA),虽局部探索能力增强,但在复杂场景下仍存在全局收敛性与稳定性不足缺陷。

针对上述问题,本文提出一种基于 MPSR 和 IHBA-BiGRU-Attention 的组合预测模型,在提高短期电力负荷预测精度的同时推进工程应用,为区域电网供需研判、调度规划等提供科学支持。首先,虑及电力负荷影响因素众多,利用 Spearman 相关性分析实现特征优选,降低数据维度;然后,将优选特征与电力负荷序列组成多变量时间序列,经混沌特性判定后,基于 MPSR 挖掘其内在动态规律,以突破传统模型对时序关联性捕捉不足局限;提出多策略改进蜜獾优化算法(improved honey badger algorithm, IHBA),以解决原始 HBA 初始化分布不均匀、挖掘与采蜜阶段布局不平衡与易局部陷入最优等缺陷,同时替代人工繁琐调参,实现 BiGRU 的参数自适应寻优;引入 Attention 机制强化关键时序特征权重,构建 IHBA-BiGRU-Attention 电力负荷预测模型;最后,利用澳大利亚和新加坡某地区的电力负荷数据验证组合模型预测性能,结合国内南方某地区的实际数据开展工程应用,验证本文方法的实用性。

1 基本原理

1.1 Spearman 相关性分析

本文采用 Spearman 相关系数法来衡量不同影响因素与电力负荷之间的关联程度,计算公式为:

$$\rho = 1 - \frac{6 \sum d_i^2}{m(m+1)(m-1)} \quad (1)$$

式中: ρ 为 Spearman 相关系数,范围在 $-1 \sim 1$ 。 m 为每个变量中样本的个数; d_i 为两个变量中对应数据点的秩差。 $|\rho|$ 越大,说明变量之间的相关性越强。

1.2 多变量相空间重构

MPSR 通过时间延迟嵌入法,引入多变量及其延迟项从时序数据中重建系统相空间,可在高维空间精准刻画动态系统的动力学行为。对于混沌时间序列,其对应的动力系统蕴含全部信息,而高维空间能容纳更多信息维度,能够更准确地揭示混沌系统的内在演化规律,为后续预测奠定数据基础。

1) 混沌特性判定

最大 Lyapunov 指数是混沌时间序列的核心判定指标,若最大 Lyapunov 指数 > 0 ,则表明该序列具备混沌特性,可开展相空间重构,本文使用 Wolf 法^[19]计算最大 Lyapunov 指数。

2) 多变量时间序列相空间重构

设有 R 个时间序列 $\{T_1, T_2, \dots, T_i, \dots, T_R\}$, 其中第 i 个时间序列 $T_i = \{x_{i,1}, x_{i,2}, \dots, x_{i,j}, x_{i,n}\}$, $i = 1, 2, \dots, R$ 。采用 C-C 法^[20]同时求取延迟时间 τ 和嵌入维数 d 。记每个单变量时间序列的延时时间分别为 $\tau_1, \tau_2, \dots, \tau_R$, 嵌入维数分别为 $d_1, d_2, \dots, d_R$, 则 k 时刻的相空间状态坐标为:

$$\mathbf{P}_k = \begin{pmatrix} x_{1,k}, x_{1,k-\tau_1}, x_{1,k-(d_1-1)\tau_1}; \dots; \\ x_{R,k}, x_{R,k-\tau_R}, x_{R,k-(d_R-1)\tau_R} \end{pmatrix} \quad (2)$$

根据 Takens 嵌入定理, 若重构后的相空间维数 d 足够大(其中 $d = \sum_{i=1}^R d_i$), 则存在确定性映射 $F: \mathbf{R}^d \rightarrow \mathbf{R}^d$, F 是 d 维空间上的光滑函数, 满足:

$$\mathbf{P}_{k+1} = F(\mathbf{P}_k) \quad (3)$$

多变量相空间矩阵为:

$$\mathbf{P} = \begin{bmatrix} \mathbf{P}_{N_0} \\ \mathbf{P}_{N_0+1} \\ \vdots \\ \mathbf{P}_k \end{bmatrix} = \begin{bmatrix} x_{1,N_0} & x_{1,N_0-\tau_1} & \dots & x_{1,N_0-(d_1-1)\tau_1} & \dots & x_{R,N_0-(d_R-1)\tau_R} \\ x_{1,N_0+1} & x_{1,N_0+1-\tau_1} & \dots & x_{1,N_0+1-(d_1-1)\tau_1} & \dots & x_{R,N_0+1-(d_R-1)\tau_R} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ x_{1,k} & x_{1,k-\tau_1} & \dots & x_{1,k-(d_1-1)\tau_1} & \dots & x_{R,k-(d_R-1)\tau_R} \end{bmatrix} \quad (4)$$

式中: $k = N_0, N_0+1, \dots, N, N_0 = \max\{(d_R-1)\tau_R + 1\}$ 。

由式(2)~(4)可知, MPSR 后的每个相点不仅保留了单变量电力负荷时间序列的演化过程, 更将外界影响因素融入系统, 因此可充分挖掘电力负荷与相关影响因素的时间耦合特性, 突破单变量重构信息维度不足的局限。

1.3 BiGRU 神经网络

BiGRU 神经网络^[21]核心结构由 2 个 GRU 层组成(如图 1 所示), 分别负责处理序列的正向信息和反向信息, 这 2 个 GRU 层输出后被加权合并以形成最终的序列表示, 计算公式为:

$$\begin{cases} \vec{h}_t = \text{GRU}(x_t, \vec{h}_{t-1}) \\ \overleftarrow{h}_t = \text{GRU}(x_t, \overleftarrow{h}_{t-1}) \\ h_t = W\vec{h}_t + V\overleftarrow{h}_t + b_t \end{cases} \quad (5)$$

式中: $\vec{h}_t$ 和 $\overleftarrow{h}_t$ 分别为 t 时刻 GRU 前向和后向隐藏层的输出值; W 为正向权重系数; V 为反向权重系数; b_t 为偏置矩阵; h_t 为最终隐藏层状态输出。其结构如图 1 所示。

1.4 注意力机制

利用 Attention 机制增加关键特征对 BiGRU 输出变量的影响, 从而提高模型的预测性能, 注意力层的计算公式为:

$$s_t = \tanh(u, h_t + w_t) \quad (6)$$




图 1 BiGRU 结构

Fig. 1 Structure of BiGRU

$$\alpha_t = \text{softmax}(s_t) = \frac{\exp(s_t)}{\sum_{t=1}^n \exp(s_t)} \quad (7)$$

$$y = \sum_{t=1}^n \alpha_t h_t \quad (8)$$

式中: s_t 为注意力评分函数; α_t 为注意力权重; softmax 代表激活函数; u_t, w_t 代表权重系数; n 为文本序列的长度; y 为注意力层的输出值。

2 多策略改进蜜獾算法

2.1 标准蜜獾算法

HBA 是 HASHIM 等^[22]通过模拟蜜獾的觅食行为提出的群智能优化算法, 核心步骤为:

1) 初始化阶段。初始化蜜獾种群规模 Q , 利用式(9)生成它们各自的位置 X_i 。

$$X_i = lb_i + r_1 \times (ub_i - lb_i) \quad (9)$$

式中: ub_i 和 lb_i 分别为搜索空间的上、下限; $r_1 \in [0, 1]$ 。

2) 定义嗅觉强度。蜜獾的嗅觉强度 I_i 受其与猎物之间的距离和猎物的气味强度影响, I_i 越大, 蜜獾移动的越快, 反之越慢。如式(10)所示。

$$\begin{cases} I_i = r_2 \times \frac{s}{4\pi l_i^2} \\ s = (X_i - X_{i+1})^2 \\ l_i = X_{prey} - X_i \end{cases} \quad (10)$$

式中: $r_2 \in [0, 1]$; X_{prey} 为当前已发现的猎物最佳位置; s 为猎物的气味强度; l_i 为猎物与第 i 只獾之间的距离。

3) 更新密度因子。密度因子 ψ 反映了搜索过程中随时间演进的不确定性, 可确保从勘探到开发的平稳过渡, 如式(11)所示。

$$\psi = C \times \exp\left(\frac{-t}{t_{\max}}\right) \quad (11)$$

式中: t 和 $t_{\max}$ 分别为表示当前和最大迭代次数; $C \geq 1$ (通常设置为 2)。

4) 挖掘阶段。在挖掘阶段, 蜜獾沿气味向猎物靠近, 进行位置挖掘并捕获猎物, 运动状况如式(12)所示。

$$X_{new} = X_{prey} + \lambda \times \beta \times I \times X_{prey} + \lambda \times r_3 \times \psi \times l_i \times |\cos(2\pi r_4) \times [1 - \cos(2\pi r_5)]| \quad (12)$$

式中: β 为蜜獾觅食能力, $\beta \geq 1$ (通常设置为 6); r_3 、 r_4 和 r_5 为 0~1 的 3 个不同的随机数; λ 为干扰因子, 由式(13)所示。

$$\lambda = \begin{cases} 1, & r_6 \leq 0.5 \\ -1, & r_6 > 0.5 \end{cases} \quad (13)$$

式中: $r_6 \in [0, 1]$ 。

在挖掘阶段, 蜜獾受猎物的气味强度 s , 蜜獾和猎物之间的距离 l_i , 以及随时间变化的密度因子 ψ 的影响。

5) 采蜜阶段。蜜獾借助导蜜鸟引导定位食物源, 运动状况如式(14)所示。

$$X_{new} = X_{prey} + \lambda \times r_7 \times \psi \times l_i \quad (14)$$

式中: $r_7 \in [0, 1]$; X_{new} 为蜜獾更新后的位置。

在采蜜阶段, 蜜獾搜索过程会受到干扰因子 λ 和密度因子 ψ 的影响。

2.2 多策略改进设计

针对原始 HBA 算法存在初始化阶段分布不够均匀、挖掘阶段和采蜜阶段的布局不平衡以及容易陷入局部最优问题, 对算法进行多策略改进:

1) Kent 混沌映射改进种群初始化。原始 HBA 算法采用均匀随机初始化, 易导致种群多样性不足、分布不均, 过早收敛问题。为解决上述问题, 引入 Kent 混沌映射进行种群初始化。它能够将初始种群映射到一个混沌序列上, 使得种群在搜索空间中更加均匀地分布, 其数学模型如式(15)所示。

$$E_{i+1} = \begin{cases} \frac{E_i}{a}, & 0 < E_i \leq a \\ \frac{1-E_i}{1-a}, & a < E_i < 1 \end{cases} \quad (15)$$

式中: $a \in (0, 1)$, 表示控制参数; E_i 表示当前迭代的 Kent 映射值。

然后通过式(16)将混沌序列映射到相应的解空间中生成初始种群个体。

$$X_i = lb_i + E_i \times (ub_i - lb_i) \quad (16)$$

2) 密度因子改造策略改进挖掘和采蜜阶段布局不平衡。原始 IHBA 算法在蜜獾挖掘和采蜜阶段布局失衡, 导致寻优效果不佳。为此, 采用动态密度因子替代原来的固定密度因子, 具体如式(17)所示。

$$\psi = \left(1 - \frac{t}{t_{max}}\right) \times [\cos(2\pi rand) + 1] \times (2rand - 1) \quad (17)$$

式中: $rand$ 是 $[0, 1]$ 中的随机数。

改进后的密度因子将更好地布局算法的关键环节, 使算法的挖掘阶段和采蜜阶段得以平衡。

3) 小孔成像反向学习策略改进易陷入局部最优。原始 HBA 算法在迭代后期易陷入局部最优, 为此, 引入小孔成

像反向学习策略(图 2)。通过求得当前最优解的反向解, 增大解空间的范围, 增强算法逃离局部最优的能力。




图 2 小孔成像反向学习原理图

Fig. 2 Reverse learning principle diagram of pinhole imaging

结合图 2 可以得出:

$$\frac{h}{H} = \frac{(lb_i + ub_i)/2 - X_{pre}}{X'_{pre} - (lb_i + ub_i)/2} \quad (18)$$

令调节因子 $\theta = h/H$, 得到 X'_{pre} 的表达式:

$$X'_{pre} = \frac{lb_i + ub_i}{2} + \frac{lb_i + ub_i}{2\theta} - \frac{X_{pre}}{\theta} \quad (19)$$

通过小孔成像反向学习策略更新后, 引入贪婪规则, 对比反向学习前后解的适应度值, 择优保留。贪婪规则如式(20)所示。

$$X_{pre} = \begin{cases} X'_{pre}, & f(X_{pre}) \geq f(X'_{pre}) \\ X_{pre}, & f(X_{pre}) < f(X'_{pre}) \end{cases} \quad (20)$$

式中: $f(X_{pre})$ 为 X_{pre} 的适应度值; $f(X'_{pre})$ 为 X'_{pre} 的适应度值。

2.3 IHBA 算法流程

IHBA 流程图如图 3 所示。具体步骤如下:

步骤 1) 初始化 IHBA 算法参数: 种群规模 Q 、搜索空间的上下限 ub_i 、 lb_i 、最大迭代次数 t_{max} 等。

步骤 2) 利用 Kent 映射初始化种群, 计算每个个体的适应度值, 并保存初始最优个体及位置。

步骤 3) 用式(10)确定 I_i , 用式(17)更新 ψ 。

步骤 4) 如果 $(0, 1)$ 之间的随机数 < 0.5 , 则根据式(12)更新种群位置, 否则, 使用式(14)更新种群位置。

步骤 5) 重新计算每个个体的适应度值并记录当前最优个体位置, 对其进行小孔成像反向学习。

步骤 6) 计算更新后的适应度值, 并根据贪婪策略择优保留。

步骤 7) 确定是否达到最大迭代次数, 如果是则输出全局最优个体及位置, 否则跳转至步骤 3), 直到迭代结束。

2.4 IHBA 函数性能测试

为了更加直观地表现出 IHBA 的整体性能, 选取 BOA、SMA、HBA、CHBA 作为比较算法, 通过 5 个基准测试函数构建评估体系, 其中, 单峰函数 (F_1 、 F_2 、 F_3) 用于测试算法局部开发精度, 多峰函数 (F_4 、 F_5) 用于验证算法全局勘探能力与逃离局部最优的性能。

5 个基准测试函数的数学表达式、搜索范围、最优解等信息如表 1 所示。




图 3 IHBA 算法流程图
Fig. 3 IHBA algorithm flow chart

为保证对比实验公平性,对比算法参数设置如表 2 所示,种群数量为 30,迭代次数为 500。实验环境为 Win11 操

表 3 基准测试函数测试结果对比

Table 3 Comparison of benchmark test function test results

函数	算法				
	BOA	SMA	HBA	CHBA	IHBA
F_1	5.434×10^{-9}	5.521×10^{-60}	7.655×10^{-72}	2.437×10^{-140}	5.225×10^{-219}
F_2	1.275×10^{-11}	1.170×10^{-135}	2.947×10^{-138}	3.126×10^{-147}	0
F_3	5.917×10^{-9}	1.045×10^{-49}	1.913×10^{-57}	1.919×10^{-81}	1.110×10^{-207}
F_4	3.740×10^{-11}	0	0	0	0
F_5	1.215×10^{-3}	6.392×10^{-4}	1.968×10^{-4}	1.713×10^{-4}	1.652×10^{-4}

图 4 为单模态函数 F_1 和多模态函数 F_4 进行测试的收敛曲线图。由图 4 可知,IHBA 算法的收敛速度和寻优能力都强于 BOA、SMA、HBA 等基础优化算法,同时由于 CHBA 改进策略缺乏对搜索阶段的精细调控,易导致收敛不稳或陷入局部最优,IHBA 在参数自适应调节和搜索方向引导方面更具系统性与稳定性,显著提升了算法的全局寻优能力、收敛速度与解的稳定性,具有较强的优越性。

表 1 基准测试函数
Table 1 Benchmark function

函数表达式	类型	范围	最优解
$F_1 = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $	单峰	$[-10,10]$	0
$F_2 = \sum_{i=1}^n (\sum_{j=1}^i x_j)^2$	单峰	$[-100,100]$	0
$F_3 = \max\{ x_i , 1 \leq i \leq n\}$	单峰	$[-100,100]$	0
$F_4 = \sum_{i=1}^n [x_i^2 - 10\cos(2\pi x_i) + 10]$	多峰	$[-5.12, 5.12]$	0
$F_5 = \sum_{i=1}^n x_i^4 + \text{rand}[0,1)$	多峰	$[-1.28, 1.28]$	0

作系统,基于 Intel Core i5-12400F 处理器、16 GB 内存、NVIDIA GeForce RTX4060 的硬件平台。

表 2 参数设置
Table 2 Parameter setting

算法	参数
BOA	$c=0.01, \alpha=0.1, p=0.8$
SMA	$z=0.03$
HBA	$\beta=6, C=2$

基准测试函数测试结果如表 3 所示。由表 3 可知, IHBA 算法在 5 个基准测试函数均表现优秀,表明 Kent 混沌映射、密度因子改造和小孔成像反向学习策略对 HBA 算法的改进对 HBA 算法的种群多样性、挖掘阶段和采蜜阶段间的平衡以及如何避免局部最优问题上的改进能够提升算法的寻优性能。

3 短期电力负荷预测

3.1 短期电力负荷预测模型构建

基于 2.4 节测试结果,利用 IHBA 算法对 BiGRU-Attention 模型中的初始学习率、隐藏层神经元个数和正则化参数进行寻优,将 BiGRU-Attention 模型的预测值和实际值的均方根误差作为适应度函数,IHBA-BiGRU-Attention




图 4 测试函数收敛曲线

Fig. 4 Convergence curve of test function

预测模型结构如图 5 所示。

3.2 短期电力负荷预测方法流程

基于本文 1.2 和 3.1 节,基于 MPSR 和 IHBA-BiGRU-Attention 的短期电力负荷预测方法流程如图 6 所示,具体如下:

1)数据准备:选取短期电力负荷数据及其影响因素数据。

2)特征优选与 MPSR:通过 Spearman 相关性分析筛选出与电力负荷相关性强的影响因素,与电力负荷序列组成多变量时间序列;然后通过 Wolf 法判定混沌特性后,利用 C-C 法计算每个时间序列的延迟时间和嵌入维数,得到重构后的多变量相空间。

3)IHBA-BiGRU-Attention 模型构建:根据 2.2 节,利用 Kent 混沌映射、密度因子改造和小孔成像反向学习策略对 HBA 算法进行多策略改进(即 IHBA),通过 IHBA 优化 BiGRU 网络的超参数,融合注意力机制强化电力负荷突变时刻特征权重,构建 IHBA-BiGRU-Attention 预测模型。

4)方法测试:将澳大利亚和新加坡某地区的电力负荷数据分别划分为训练集与测试集,归一化处理后进行方法测试,验证模型的有效性。




图 5 IHBA-BiGRU-Attention 模型结构

Fig. 5 IHBA-BiGRU-Attention model structure

5)工程应用:基于国内南方某地区的实际数据开展工程应用,验证所提方法的实用性。

6)方法评价:采用均方根误差 (root mean squared error, RMSE)、平均绝对误差 (mean absolute error, MAE)、平均绝对百分比误差 (mean absolute percentage error, MAPE)和决定系数(r-square, R^2)指标评价本文方

法预测的精准度。其中, $RMSE$ 、 MAE 、 $MAPE$ 越小,模型预测值越接近真实值,预测精度越高, R^2 越接近 1,拟合效果越好, R^2 越接近 0,拟合效果越差,各指标计算公式为:

$$RMSE = \sqrt{\frac{\sum_{i=1}^L (\tilde{y}_i - y_i)^2}{L}} \quad (21)$$




图 6 基于 MPSR 和 IHBA-BiGRU-Attention 的短期电力负荷预测流程

Fig. 6 Short-term power load forecasting process based on MPSR and IHBA-BiGRU-Attention

$$MAE = \frac{\sum_{i=1}^L |\tilde{y}_i - y_i|}{L} \quad (22)$$

$$MAPE = \frac{1}{L} \sum_{i=1}^L \left| \frac{\tilde{y}_i - y_i}{y_i} \right| \times 100\% \quad (23)$$

$$R^2 = 1 - \frac{\sum_{i=1}^L (y_i - \tilde{y}_i)^2}{\sum_{i=1}^L (y_i - \bar{y}_i)^2} \quad (24)$$

式中: L 为测试样本数; y_i 为样本点 i 对应的实际值; $\tilde{y}_i$ 为样本点 i 对应的预测值; $\bar{y}_i$ 为样本点平均值。

4 实验分析

4.1 数据描述

为验证所提方法有效性,选取两种典型气候公开数据集进行实验。数据集 1 为新加坡某地区 2008 年 6 月 1 日~2008 年 10 月 28 日数据(热带气候),包含电力负荷、温度、湿度、风速、气压和电价等影响因素,采样周期为 1 h,即日采样 24 次,共 3 600 组数据。数据集 2 为澳大利亚新南威尔士州 2009 年 1 月 1 日~2009 年 3 月 31 日数据(温带气候),包含电力负荷、干球温度、露点温度、湿球温度、湿度和电价等影响因素,采样周期为 30 min,即日采样 48 次,共

4 320 组数据。两数据集均按 9:1 的比例划分为训练集和测试集(电力负荷值单位:MW),两数据集历史数据分别如图 7 和 8 所示。




图 7 原始数据(数据集 1)

Fig. 7 Raw data (data set 1)

为消除不同数据源间的量纲差异,利用式(25)进行归一化。

$$\tilde{x}_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (25)$$

式中: x_i 为原始时间序列; $x_{\max}$ 、 $x_{\min}$ 代表该时间序列中的最大值、最小值; $\tilde{x}_i$ 为归一化后对应的时间序列。

4.2 特征优选

为实现特征优选,降低输入特征维度,根据式(1)计算




图 8 原始数据(数据集 2)

Fig. 8 Raw data(data set 2)

电力负荷与各影响因素的相关系数,结果分别如图 9 和 10 所示。为确保优选特征与电力负荷的强关联性,设定 $|\rho| > 0.5$ 。根据图 9 和 10,数据集 1 选择温度、湿度、风速与电价 4 个影响因素,与电力负荷序列构成 5 维多变量时间序列;数据集 2 中选择干球温度、湿球温度与电价 3 个影响因素,与电力负荷序列构成 4 维多变量时间序列。




图 9 相关性分析(数据集 1)

Fig. 9 Correlation analysis (data set 1)




图 10 相关性分析(数据集 2)

Fig. 10 Correlation analysis (data set 2)

4.3 相空间重构

根据本文 1.2 节和 4.2 节,首先,利用 Wolf 法分别计算数据集 1(5 维时序:温度、湿度、风速、电价、负荷)、数据集 2(4 维时序:干球温度、湿球温度、电价、负荷)的最大

Lyapunov 指数,若均 > 0 ,表明两数据集均具备混沌特性,满足相空间重构前提;然后,通过 C-C 法计算各特征时间序列的延迟时间 τ 和嵌入维数 d ,结果如表 4 所示。

表 4 多维变量时间序列的最大 Lyapunov 指数、延迟时间和嵌入维数

Table 4 The maximum Lyapunov exponent, delay time and embedding dimension of multivariate time series

数据集	特征时间序列	最大 Lyapunov 指数	延迟时间 τ	嵌入维数 d
数据集 1	温度	0.054 8	4	9
	湿度	0.042 3	5	8
	风速	0.168 3	7	6
	电价	0.071 0	4	9
	电力负荷	0.063 3	4	3
数据集 2	干球温度	0.018 5	15	5
	湿球温度	0.033 1	38	3
	电价	0.172 8	13	3
	电力负荷	0.013 7	10	8

MPSR 的嵌入维度为各时间序列一元相空间重构的维数总和,因此,数据集 1 嵌入维度为 35,数据集 2 嵌入维度为 19。两数据集的多变量相空间矩阵分别为:

$$P_1 = \begin{bmatrix} x_{1,36} & x_{1,32} & \cdots & x_{1,4} & \cdots & x_{5,36} & x_{5,32} & x_{5,28} \\ x_{1,37} & x_{1,33} & \cdots & x_{1,5} & \cdots & x_{5,37} & x_{5,33} & x_{5,29} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ x_{1,3600} & x_{1,3596} & \cdots & x_{1,3568} & \cdots & x_{5,3600} & x_{5,3596} & x_{5,3592} \end{bmatrix} \quad (26)$$

$$P_2 = \begin{bmatrix} x_{1,77} & x_{1,62} & \cdots & x_{1,17} & \cdots & x_{4,77} & x_{4,67} & \cdots & x_{4,7} \\ x_{1,78} & x_{1,63} & \cdots & x_{1,18} & \cdots & x_{4,78} & x_{4,68} & \cdots & x_{4,8} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ x_{1,4320} & x_{1,4305} & \cdots & x_{1,4260} & \cdots & x_{4,4320} & x_{4,4310} & \cdots & x_{4,4250} \end{bmatrix} \quad (27)$$

通过将相空间矩阵中的各相点依次连接,可完整刻画电力负荷整体演变趋势,进而充分挖掘电力负荷与外界影响因素在时间上的耦合特性。

4.4 不同寻优算法对比分析

为了验证 IHBA 结合 BiGRU-Attention 模型在短期电力负荷预测中的寻优性能,根据 4.3 节,将重构相空间作为预测模型输入,在相同实验条件下,对比 BOA、SMA、HBA、CHBA4 种寻优算法对 BiGRU 的初始学习率,隐藏层神经元个数和正则化参数寻优效果。其中,种群数为 10,最大迭代次数为 50,BiGRU 激活函数为 Selu,优化器为 Adam,迭代次数为 150,初始学习率的搜索范围为 $[10^{-3}, 10^{-1}]$,隐藏层神经元个数的搜索范围为 $[1, 50]$,正则化参数的搜索范围为 $[10^{-4}, 10^{-2}]$,5 种算法对 BiGRU 超参数的寻优结果如表 5 所示。

利用 4 种优化算法找到的超参数最优值分别优化预

表 5 各优化算法的寻优结果

Table 5 The optimization results of each optimization algorithm

数据集	优化算法	初始学习率	隐藏层神经元个数	正则化参数
数据集 1	BOA	1.1×10^{-3}	31	5.9×10^{-3}
	SMA	9.4×10^{-3}	36	3.3×10^{-3}
	HBA	9.9×10^{-3}	21	1.3×10^{-4}
	CHBA	8.7×10^{-3}	25	6.1×10^{-4}
	IHBA	9.2×10^{-3}	23	4.4×10^{-4}
数据集 2	BOA	1.5×10^{-3}	27	6.1×10^{-3}
	SMA	1.8×10^{-3}	30	2.8×10^{-3}
	HBA	2.0×10^{-3}	26	3.5×10^{-4}
	CHBA	1.7×10^{-3}	29	8.2×10^{-4}
	IHBA	2.1×10^{-3}	28	5.6×10^{-4}

测模型,分别对 4.1 节数据集 1、2 进行测试,结果如图 11 和 12 所示,评价指标如表 6 所示。




图 11 不同优化算法预测曲线(数据集 1)

Fig. 11 Different optimization algorithms predict curves(data set 1)




图 12 不同优化算法预测曲线(数据集 2)

Fig. 12 Different optimization algorithms predict curves(data set 2)

由图 11 和 12 可知,IHBA 优化的模型预测曲线与实际负荷曲线最为吻合,能准确地拟合电力负荷时间序列变化,展现了最优预测性能,表明其寻优精度优于其他 4 种优化算法。由表 6 可进一步得到,在数据集 1 中,相较于 BOA 和 SMA, IHBA 优化后的 RMSE 分别下降了 44.739% 和 36.536%, MAE 分别降低了 48.056% 和 40.410 5, MAPE 分别降低了 0.623% 和 0.459%, 同时 R^2 分别提高了 1.7% 和 1.2%, 表明 IHBA 优化算法在降低预测误差和提高拟合度方面表现优异。与 HBA 相比, IHBA 优化后的 RMSE 降低了 26.118%, MAE 降低了 34.438%, MAPE 降低了 0.352%, R^2 提高了 0.7%, 证明了 Kent 混沌映射、密度因子改造和小孔成像反向学习等策略的有效性。与 CHBA 相比, IHBA 优化后的 RMSE 降低了 9.372%, MAE 降低了 10.720%, MAPE 降低了 0.078%, R^2 提高了 0.2%, 体现了 IHBA 具有更强的稳定性和全局搜索能力。在数据集 2 中, IHBA 优化模型同样处于领先, 其 RMSE 为 136.441 MW, MAE 为 87.668 MW,

表 6 不同优化算法评价指标

Table 6 Evaluation indexes of different optimization algorithms

数据集	模型	RMSE/MW	MAE/MW	MAPE/%	R^2
数据集 1	MPSR-BOA-BiGRU-Attention	97.438	72.982	1.273	0.976
	MPSR-SMA-BiGRU-Attention	84.843	63.620	1.109	0.981
	MPSR-HBA-BiGRU-Attention	72.880	57.825	1.002	0.986
	MPSR-CHBA-BiGRU-Attention	59.413	42.463	0.728	0.991
	MPSR-IHBA-BiGRU-Attention	53.845	37.911	0.650	0.993
数据集 2	MPSR-BOA-BiGRU-Attention	215.726	162.446	2.015	0.977
	MPSR-SMA-BiGRU-Attention	183.298	128.290	1.603	0.983
	MPSR-HBA-BiGRU-Attention	156.609	105.961	1.316	0.988
	MPSR-CHBA-BiGRU-Attention	143.539	95.306	1.152	0.990
	MPSR-IHBA-BiGRU-Attention	136.441	87.668	1.067	0.991

MAPE 为 1.067%, R^2 为 0.991。综上, IHBA 优化算法能有效优化 BiGRU 超参数, 显著提升短期电力负荷预测精度, 证明了多策略改进的先进性。

4.5 消融实验

为量化评估 IHBA、MPSR、Attention 对本文所提方法整体预测性能的独立贡献, 在一致实验环境下, 设计 3 组

消融模型:1)消融 IHBA 的 MPSR-BiGRU-Attention 模型;2)消融 MPSR 的 IHBA-BiGRU-Attention 模型;3)消融 Attention 机制的 MPSR-IHBA-BiGRU 模型。分别对 4.1 节数据集 1、2 进行实验,结果如图 13 和 14 所示,评价指标如表 7 所示。




图 13 消融实验预测曲线(数据集 1)

Fig. 13 Ablation experiment prediction curve(data set 1)




图 14 消融实验预测曲线(数据集 2)

Fig. 14 Ablation experiment prediction curve(data set 2)

由图 13 和 14 可知,本文方法(MPSR-IHBA-BiGRU-Attention)对电力负荷波峰、波谷的预测最高且整体趋势一致,无明显偏差或波动。表 7 进一步表明,消融 IHBA 后,两数据集的 RMSE、MAE 和 MAPE 均明显增加, R^2 明显下降,表明 IHBA 通过自适应优化 BiGRU 超参数,有效

表 7 消融实验评价指标

Table 7 Evaluation index of ablation experiment

数据集	模型	RMSE/MW	MAE/MW	MAPE/%	R^2
数据集 1	MPSR-BiGRU-Attention	163.684	133.516	2.307	0.931
	IHBA-BiGRU-Attention	151.646	116.895	2.034	0.941
	MPSR-IHBA-BiGRU	127.068	97.022	1.697	0.958
	MPSR-IHBA-BiGRU-Attention	53.845	37.911	0.650	0.993
数据集 2	MPSR-BiGRU-Attention	383.280	318.531	3.815	0.927
	IHBA-BiGRU-Attention	354.757	281.255	3.531	0.937
	MPSR-IHBA-BiGRU	306.921	238.532	2.997	0.953
	MPSR-IHBA-BiGRU-Attention	136.441	87.668	1.067	0.991

提高预测精度。消融 MPSR 后,预测性能有所下降, RMSE、MAE 和 MAPE 上升, R^2 降低,证明 MPSR 通过挖掘电力负荷和影响因素的时间耦合特性,为预测模型提供高质量特征输入,进而提高模型预测精度。消融 Attention 机制后,也导致模型预测性能下降,验证 Attention 机制通过动态分配时序权重,强化关键信息提取,从而提高模型的预测性能。

4.6 不同模型对比分析

为进一步验证本文所提方法的优势,将其与文献[11]提出的 MSCNN-BiGRU-Attention、文献[12]提出的 CEEMDAN-GRU-SCN、文献[17]提出的 CEEMDAN-HBA-BiGRU-SelfAttention、文献[13]提出的 XGB-Informer 和文献[23]提出的 ICEEMDAN-PE-IDBO-Informer 等当前较为先进的 5 种模型进行对比研究,同样基于 4.1 节两数据集开展实验,评价指标如表 8 所示,可视化对比如图 15 和 16 所示。

由表 8 可知,对于数据集 1,相较于 5 种对比模型,本

表 8 不同模型评价指标

Table 8 Evaluation index of ablation experiment

数据集	模型	RMSE/ MW	MAE/ MW	MAPE/ %	R^2
数据集 1	文献 [11]	80.454	62.424	1.075	0.983
	文献 [12]	73.053	56.187	0.968	0.986
	文献 [17]	72.065	54.581	0.941	0.987
	文献 [13]	64.918	47.806	0.817	0.989
	文献 [23]	58.336	42.183	0.721	0.991
	本文方法	53.845	37.911	0.650	0.993
数据集 2	文献 [11]	184.560	134.608	1.640	0.983
	文献 [12]	172.671	121.983	1.502	0.985
	文献 [17]	168.244	112.748	1.352	0.986
	文献 [13]	154.478	101.653	1.237	0.988
	文献 [23]	149.511	96.994	1.180	0.989
	本文方法	136.441	87.668	1.067	0.991




图 15 评价指标雷达图(数据集 1)

Fig. 15 Radar chart of evaluation index(data set 1)




图 16 评价指标雷达图(数据集 2)

Fig. 16 Radar chart of evaluation index(data set 2)

文所提方法的 RMSE 分别降低了 33.074%、26.293%、25.283%、17.057%、7.699%，MAE 分别降低了 39.269%、32.527%、30.542%、20.698%、10.127%，MAPE 分别降低了 0.425%、0.318%、0.291%、0.167%、0.071%， R^2 分别提高了 1.0%、0.7%、0.6%、0.4%、0.2%。对于数据集 2，所提方法同样展现出优越的预测性能，RMSE 为 136.441 MW，MAE 为 87.668 MW，MAPE 为 1.067%， R^2 为 0.991，均优于对比模型。图 15 和 16 可

以更直观地看出本文方法 4 个评价指标均优于 5 种对比方法，充分证明其在提升预测精度方面的优越性。究其原因，主要在于 MPSR 对电力负荷动态耦合特性的挖掘、IHBA 对预测模型超参数的高效优化，以及 Attention 机制对关键时序特征的强化，三者协同突破了单一模型或传统组合方法的性能瓶颈。

4.7 工程应用

为检验本文所提方法的工程实用性，以国内某地区电力负荷数据为研究对象，进行应用性验证。选取该地区 2024 年 4 月 1 日~2024 年 5 月 15 日共 45 天的多维数据，包括电力负荷、平均温度、最高温度、最低温度、湿度和风速等影响因素，采样周期为 15 min，日采集 96 组数据，如图 17 所示。数据集按 9:1 划分为训练集和测试集，将本文方法与已进行工程应用的 ES-LSTM^[24]、IWOA-BiLSTM-Attention^[25]、改进 BOHB 与集成学习^[26]等方法进行对比，结果如图 18 所示，评价指标如表 9 所示。




图 17 实际数据

Fig. 17 Actual data




图 18 预测曲线

Fig. 18 Prediction curve

表 9 工程应用评价指标

Table 9 Evaluation index of engineering application

模型	RMSE/MW	MAE/MW	MAPE/%	R^2
ES-LSTM	2 733.990	2 131.710	6.815	0.901
IWOA-BiLSTM-Attention	2 147.243	1 789.458	6.114	0.939
改进 BOHB 与集成学习	1 640.319	1 319.293	4.388	0.964
MPSR-IHBA-BiGRU-Attention	695.726	460.034	1.523	0.994

由图 18 可知,本文所提方法预测值与实际值高度吻合,整体误差控制在工程允许范围内;表 9 进一步表明,本文方法的 RMSE 为 695.726 MW,MAE 为 460.034 MW,MAPE 为 1.523%, R^2 为 0.994,均优于 4 种对比模型。这表明本文方法不仅在理论测试中表现优异,更能适配实际电网复杂工况,具有良好的工程应用价值,可为电网调度、备用容量配置提供可靠决策支持。

5 结 论

针对短期电力负荷预测影响因素多、负荷数据呈现非线性、非平稳性,导致传统短期电力负荷预测模型精度低、工程适配性差的问题,提出一种基于 MPSR 和 IHBA-BiGRU-Attention 的短期电力负荷预测方法,通过新加坡、澳大利亚和国内南方某区域工程验证,结合多组对比实验,得出以下结论:

1) MPSR 充分挖掘了电力负荷与影响因素的时间耦合特性,提升了模型对电力负荷数据非线性、非平稳性的理解能力。对比实验结果表明,引入 MPSR 后,数据集 1、2 的 RMSE 分别下降了 64.493%和 61.540%,MAE 分别降低了 67.568%和 68.830%,MAPE 分别降低了 1.384%和 2.464%, R^2 分别提高了 5.2%和 5.4%,显著提高了预测精度。

2) 融合 Kent 混沌映射、密度因子改造和小孔成像反向学习策略,提出一种多策略改进 HBA 算法(IHBA),解决了原始 HBA 算法在初始化阶段分布不均、挖掘阶段与采蜜阶段不平衡以及易陷入局部最优的问题。将其与 BOA、SMA、HBA 和 CHBA 算法进行比较实验,IHBA 寻优性能优于 4 种比较算法。基于此,构建 IHBA-BiGRU-Attention 组合预测模型,将其与 BOA-BiGRU-Attention、SMA-BiGRU-Attention、HBA-BiGRU-Attention 和 CHBA-BiGRU-Attention 4 种组合模型进行对比实验,两数据集的 RMSE 分别为 53.845、136.441 MW,MAE 分别为 37.911、87.668 MW,MAPE 分别为 0.650%、1.067%, R^2 分别为 0.993、0.991,均优于其他 4 种优化预测模型。

3) 消融实验结果表明,MPSR、IHBA、BiGRU、Attention 协同作用,提升了组合模型预测性能。

4) 本文预测方法与 MSCNN-BiGRU-Attention、CEEMDAN-GRU-SCN、CEEMDAN-HBA-BiGRU-SelfAttention、XGB-Informer、ICEEMDAN-PE-IDBO-Informer 5 种较为先进组合模型对比实验结果表明,本文方法在两数据集的 RMSE、MAE、MAPE、 R^2 均最优,预测精度最高。

5) 利用 Spearman 特征优选,再进行 MPSR,然后利用 IHBA-BiGRU-Attention 模型开展电力负荷预测,实验结果表明,该预测方法普适性强,可为电网供需研判、调度决策等提供参考。

参考文献

[1] 鄢化彪,李东丽,黄绿娥,等. 基于模态分解和误差

修正的短期电力负荷预测[J]. 电子测量技术, 2025, 48(5): 92-101.

YAN H B, LI D L, HUANG L E, et al. Short-term electric load forecasting based on mode decomposition and error correction [J]. Electronic Measurement Technology, 2025, 48(5): 92-101.

[2] XING Q Y, HUANG X J, WANG J ZH, et al. A novel multivariate combined power load forecasting system based on feature selection and multi-objective intelligent optimization [J]. Expert Systems with Applications, 2024, 244: 122970.

[3] 曾进辉,苏旨音,肖锋,等. 基于生成对抗网络和 EMD-ISSA-LSTM 的短期电力负荷预测[J]. 电子测量技术, 2024, 47(20): 92-100.

ZENG J H, SU ZH Y, XIAO F, et al. Short-term power load forecasting based on generative adversarial networks and EMD-ISSA-LSTM [J]. Electronic Measurement Technology, 2024, 47(20): 92-100.

[4] WANG Y G, HAO Y, ZHAO K X, et al. Stochastic configuration networks for short-term power load forecasting [J]. Information Sciences, 2025, 689: 121489.

[5] LI W W, SHI Q, LI D, et al. Multi-stage optimization forecast of short-term power load based on VMD and PSO-SVR[J]. Electric Power, 2022, 55(8): 171-177.

[6] 张淑清,要俊波,张立国,等. 基于改进深度稀疏自编码器及 FOA-ELM 的电力负荷预测[J]. 仪器仪表学报, 2020, 41(4): 49-57.

ZHANG SH Q, YAO J B, ZHANG L G, et al. Power load forecasting based on improved deep sparse auto-encoder and FOA-ELM[J]. Chinese Journal of Scientific Instrument, 2020, 41(4): 49-57.

[7] 程明,翟金星,马骏,等. 基于迁移学习的 CNN-GRU 短期电力负荷预测方法[J]. 武汉大学学报(工学版), 2024, 57(6): 812-820.

CHENG M, ZHAI J X, MA J, et al. Transfer learning based CNN-GRU short-term power load forecasting method[J]. Engineering Journal of Wuhan University, 2024, 57(6): 812-820.

[8] 唐竹,肖宇航,郭淳,等. 基于 CEEMDAN 模态分解和 TCN-BiGRU 的短期电力负荷预测[J]. 智慧电力, 2024, 52(12): 59-64,72.

TANG ZH, XIAO Y H, GUO CH, et al. Short-term electricity load forecasting based on CEEMDAN decomposition and TCN-BiGRU Model [J]. Smart Power, 2024, 52(12): 59-64,72.

[9] 夏梦,于惠钧. 基于 VMD-IOOA-BiGRU 模型及误差补偿的短期电力负荷预测[J]. 科学技术与工程, 2025, 25(27): 11642-11650.

XIA M, YU H J. Short-term power load forecasting based on VMD-IOOA-BiGRU model and error compensation [J]. Science Technology and Engineering, 2025, 25(27): 11642-11650.

[10] 高展鹏,易文俊,管军,等. 基于 TCN-BiGRU-Attention 模

- 型的弹丸发射点预测[J]. 电子测量与仪器学报, 2025, 39(10): 79-89.
- GAO ZH P, YI W J, GUAN J, et al. Projectile launch point prediction based on TCN-BiGRU-Attention model [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39 (10): 79-89.
- [11] 李科, 潘庭龙, 许德智. 基于 MSCNN-BiGRU-Attention 的短期电力负荷预测[J]. 中国电力, 2025, 58(6): 10-18.
- LI K, PAN T L, XU D ZH. Short-term power load forecasting based on MSCNN-BiGRU-Attention [J]. Electric Power, 2025, 58(6): 10-18.
- [12] SUN J, MA K X, ZHAO H Y. Short-term power load hybrid forecasting using GRU and SCN [J]. Energy and Buildings, 2025, 347: 116372.
- [13] 俞胜, 孙可, 蔡华, 等. 结合极端梯度提升决策树与改进 Informer 的短期电力负荷预测方法[J]. 中国电力, 2025, 58(10): 195-205.
- YU SH, SUN K, CAI H, et al. Short-term power load forecasting method combining extreme gradient boosting decision tree and improved Informer [J]. Electric Power, 2025, 58(10): 195-205.
- [14] MA J, CAO X B, YANG X, et al. A short-term load forecasting method for integrated regional energy systems based on multivariate phase space reconstruction [J]. International Journal of Thermofluids, 2025, 30: 101472.
- [15] WANG Y G, ZHAO K X, YUE H, et al. Short-term wind power prediction using a novel model based on butterfly optimization algorithm-variational mode decomposition-long short-term memory [J]. Applied Energy, 2024, 366: 123313.
- [16] LIU W, FAN H, CUI Y P, et al. An optimized power load forecasting algorithm based on VMD-SMA-LSTM [J]. Energy Science & Engineering, 2025, 13(6): 3243-3253.
- [17] 朱婷, 颜七笙. 基于 CEEMDAN 和 HBA-BiGRU-SelfAttention 的短期负荷预测[J]. 南京信息工程大学学报, 2025, 17(4): 478-493.
- ZHU T, YAN Q SH. Short-term power load prediction based on CEEMDAN and HBA-BiGRU-SelfAttention [J]. Journal of Nanjing University of Information Science & Technology, 2025, 17 (4): 478-493.
- [18] 袁媛, 赵鹏举, 代晓文, 等. 融合多策略改进蜜獾优化算法及其应用[J]. 机械设计与制造, 2025(8): 134-139.
- YUAN Y, ZHAO P J, DAI X W, et al. Integrating multi strategy improved honey badger optimization algorithm and its application [J]. Machinery Design & Manufacture, 2025(8): 134-139.
- [19] 金秀章, 赵大勇, 赵术善, 等. 基于相空间重构-深度学习的燃煤电厂主汽温预测模型[J]. 中国电机工程学报, 2025, 45(10): 3924-3934.
- JIN X ZH, ZHAO D Y, ZHAO SH SH, et al. Prediction model of main steam temperature of coal-fired power plant based on phase space reconstruction-deep learning [J]. Proceedings of the CSEE, 2025, 45(10): 3924-3934.
- [20] HU SH T, XU X F, LI M D, et al. Incremental forecaster using C-C algorithm to phase space reconstruction and broad learning network for short-term wind speed prediction [J]. Engineering Applications of Artificial Intelligence, 2024, 128: 107461.
- [21] 李斌, 王幸之, 王志鹏. 基于 CPO 的 IFMD-BiTCN-BiGRU-AT 断路器寿命预测方法研究[J]. 电子测量与仪器学报, 2025, 39(10): 255-268.
- LI B, WANG X ZH, WANG ZH P. IFMD-BiTCN-BiGRU-AT remaining usable life prediction method for circuitbreakers based on CPO [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(10): 255-268.
- [22] HASHIM F A, HOUSSEIN E H, HUSSAIN K, et al. Honey badger algorithm: New metaheuristic algorithm for solving optimization problems [J]. Mathematics and Computers in Simulation, 2022, 192: 84-110.
- [23] 于多, 曹焱, 王海荣, 等. 基于 ICEEMDAN-PE 和 IDBO-Informer 组合模型的短期负荷预测[J]. 中国电力, 2025, 58(6): 19-32.
- YU D, CAO Y, WANG H R, et al. Short-term load forecasting based on a combined ICEEMDAN-PE and IDBO-Informer model [J]. Electric Power, 2025, 58(6): 19-32.
- [24] WANG Y N, WANG X W. A hybrid power load forecasting model based on evolutionary strategy and long short term memory [J]. Energy Reports, 2025, 14: 845-853.
- [25] 韩林, 陈聪磊, 任旭洋, 等. 基于改进 LSTM 的短期负荷预测及其调峰优化模型研究[J]. 自动化与仪器仪表, 2025(6): 300-304.
- HAN L, CHEN C L, REN X Y, et al. Research on short term load forecasting and peak shaving optimization model based on improved LSTM [J]. Automation & Instrumentation, 2025(6): 300-304.
- [26] 项佳宇, 王晓冰, 李冰, 等. 改进贝叶斯优化与集成学习短期负荷预测模型[J]. 电力系统及其自动化学报, 2025, 37(9): 34-44.
- XU J Y, WANG X B, LI B, et al. Short-term load forecasting model based on improved Bayesian optimization and ensemble learning [J]. Proceedings of the CSU-EPSA, 2025, 37(9): 34-44.

作者简介

于春雨(通信作者), 博士, 副教授, 主要研究方向为系统可靠性综合及预测。

E-mail: yuchunyu@qut.edu.cn

高健玮, 硕士研究生, 主要研究方向为电力负荷预测。

E-mail: 1052431983@qq.com