

10-14-2020

A Photovoltaic Power Forecasting Method Based on DA-RKELM Algorithm

Mingqi Wei

1. *School of Mechanical Engineering, Shenyang University, Shenyang 110041, China;*

Tianrui Zhang

1. *School of Mechanical Engineering, Shenyang University, Shenyang 110041, China;*

Xiuxiu Gao

1. *School of Mechanical Engineering, Shenyang University, Shenyang 110041, China;*

Shumei Wang

2. *School of Business Administration, Shenyang University, Shenyang 110041, China;*

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research, Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

A Photovoltaic Power Forecasting Method Based on DA-RKELM Algorithm

Abstract

Abstract: Aiming at the power grid safety problems caused by the fluctuation and randomness of photo-voltaic power generation, *a method for predicting photo-voltaic power generation of a regular nuclear limit learning machine based on the optimization of a dragonfly algorithm was proposed.* Through correlation analysis, the key factors affecting the photo-voltaic power generation are determined, *and the photo-voltaic power prediction model is constructed. Dragonfly algorithm is used to obtain the optimal weight and threshold value of the network, and regularization function and kernel function are introduced based on the standard limit learning machine to avoid the over fitting problem caused by the traditional gradient descent method and enhance the spatial mapping ability of the model.* Simulation experiments show that compared with DA-ELM, PSO-ELM and GA- ELM models, the DA-RKELM prediction model achieve higher prediction accuracy, closer to the actual operating power of photo-voltaic power generation.

Keywords

photo-voltaic power generation, dragonfly algorithm, regular kernel limit learning machine, regular function, kernel function

Recommended Citation

Wei Mingqi, Zhang Tianrui, Gao Xiuxiu, Wang Shumei. A Photovoltaic Power Forecasting Method Based on DA-RKELM Algorithm[J]. Journal of System Simulation, 2020, 32(10): 2041-2051.

基于 DA-RKELM 算法的光伏发电功率预测方法

魏铭琦¹, 张天瑞¹, 高秀秀¹, 王淑梅²

(1. 沈阳大学机械工程学院, 辽宁 沈阳 110041; 2. 沈阳大学工商管理学院, 辽宁 沈阳 110041)

摘要: 针对光伏发电功率具有的波动性和随机性等特点造成的电网安全问题, 提出了一种基于蜻蜓算法优化的正则核极限学习机光伏发电功率预测方法。通过相关性分析确定影响光伏发电功率的关键影响因子, 构建光伏发电功率预测模型; 利用蜻蜓算法获取网络最优的权重和阈值, 在标准极限学习基础上引入正则化函数和核函数以避免传统梯度下降法造成的过拟合问题, 增强模型空间映射能力; 仿真实验表明, 与 DA-ELM、PSO-ELM 以及标准-DA-ELM 模型相比, DA-RKELM 预测模型能达到更高的预测精度, 更贴近光伏发电的实际运行功率。

关键词: 光伏发电; 蜻蜓算法; 正则核极限学习机; 正则函数; 核函数

中图分类号: TM615

文献标识码: A

文章编号: 1004-731X (2020) 10-2041-11

DOI: 10.16182/j.issn1004731x.joss.20-FZ0289

A Photovoltaic Power Forecasting Method Based on DA-RKELM Algorithm

Wei Mingqi¹, Zhang Tianrui¹, Gao Xiuxiu¹, Wang Shumei²

(1. School of Mechanical Engineering, Shenyang University, Shenyang 110041, China;

2. School of Business Administration, Shenyang University, Shenyang 110041, China)

Abstract: Aiming at the power grid safety problems caused by the fluctuation and randomness of photo-voltaic power generation, a method for predicting photo-voltaic power generation of a regular nuclear limit learning machine based on the optimization of a dragonfly algorithm was proposed. Through correlation analysis, the key factors affecting the photo-voltaic power generation are determined, and the photo-voltaic power prediction model is constructed. Dragonfly algorithm is used to obtain the optimal weight and threshold value of the network, and regularization function and kernel function are introduced based on the standard limit learning machine to avoid the over fitting problem caused by the traditional gradient descent method and enhance the spatial mapping ability of the model. Simulation experiments show that compared with DA-ELM, PSO-ELM and GA-ELM models, the DA-RKELM prediction model achieve higher prediction accuracy, closer to the actual operating power of photo-voltaic power generation.

Keywords: photo-voltaic power generation; dragonfly algorithm; regular kernel limit learning machine; regular function; kernel function

引言

传统能源的大量使用导致环境污染和能源匮



收稿日期: 2020-03-25 修回日期: 2020-06-02;
基金项目: 工信部重大专项(201675514), 辽宁省自然科学基金(20180551001);
作者简介: 魏铭琦(1995-), 男, 辽宁阜新, 硕士生, 研究方向为质量预测; 张天瑞(1985-), 男, 河北深州, 博士, 副教授, 研究方向为供应链管理。

乏问题日益严重, 能源和环境可持续发展已经成为世界关注的焦点, 积极发展绿色新能源已经成为全球共识。作为技术较为成熟的可再生能源发电之一, 光伏发电以其独特的优势(污染低, 占地小, 不受地域限制)成为广泛运用的可再生能源之一^[1]。然而, 光伏发电功率由于受到多种气象因子的干扰, 使其具有较强随机性、周期性、间断性和不稳定性等特

点,这在一定程度上存在恶化电网运行水平指标的风险^[2-4]。因此,采用适当的预测方法对光伏发电的输出功率进行预测,是解决以上问题的有效措施。

目前,国内外已有大量学者采用各种理论和模型对光伏发电功率进行预测。De 等^[5]以影响光伏发电功率的气象因素作为输入变量来预测光伏发电功率,构建多元回归预测模型,但预测精确度较差;高阳等^[6]运用支持向量回归模型对样本数据进行划分,在此基础上建立基于 ARMA 的光伏发电功率预测模型,但该方法的预测精准度有待提高;Muhammad 等^[7]提出了一种基于随机森林算法光伏发电功率短期预测模型,改模型的预测间隔较短,因此不适用于长时间的光伏发电功率预测;黄予春等^[8]采用改进的 KFCM 聚类方法对样本数据进行分类处理,构建基于支持向量回归模型的预测模型,仿真结果表明该方法可用于不同天气的短期光伏发电预测。上述预测方法均基于回归理论构建预测模型,模型的预测精度和数据处理能力需要进一步提升。人工智能算法因其强大的数据处理及非线性处理能力被应用于光伏发电预测中,王晓兰等^[9]对基于季节和天气类型对样本进行划分,在利用人工神经网络 ANN 对光伏发电功率进行预测,但该方法对数据的处理能力不强;张雨金等^[10]利用 K 均值算法对样本集进行聚类分析,提出了一种基于支持向量的短期光伏发电功率预测方法,以气象因子和系统电流电压的因子作为模型输入变量,实现短期光伏发电功率预测;于群、张立影、刘俊等^[11-13]分别构建了基于 BP 神经网络的光伏发电功率预测模型,仿真结果表明 BP 神经网络可以实现光伏发电功率预测,但以上预测方法的可靠性受网络敏感参数影响较大。针对单一神经网络算法的局限性,学者们开始关注基于组合优化的光伏发电功率预测方法,主要的研究方向是采用元启发式算法对网络的权重和阈值进行寻优。张彩庆等^[14]为提升光伏发电功率的稳定性,利用相似日理论确定特征向量,建立了基于蝙蝠算法优化的最小二乘法支持向量机短期光伏输出功率预测模型;王育飞等^[15]考虑到小波神经

网络初始值敏感性不足的缺陷,提出一种搜索能力更强的双模式布谷鸟搜索算法对小波神经网络的参数进行优化,对光伏发电功率进行预测。

此外,遗传算法^[16]、人工蜂群算法^[17]和粒子群算法^[18]作为常用参数优化方法已被应用于光伏发电功率预测领域,预测结果显示,权重和阈值优化后的神经网络的预测性能明显优于未经优化的单一神经网络。现有预测方法虽然取得了一定效果,但其预测精度和收敛速度仍有待提升,且现有预测模型多为短期预测模型。

极限学习机(extreme learning machine, ELM)作为一种新型前馈神经网络学习方法,其优势在于涉及参数少、学习速度快、泛化性能强。丁华等^[19]将极限学习机用于采煤机功率预测,并将该模型的预测效果与支持向量机预测模型的输出结果进行对比,其结果表明了极限学习机在预测上的优越性。蒋建东等^[20]提出了一种基于粒子群算法参数优化的 ELM 光伏发电功率预测模型,并将其与 PSO-BP 预测模型的预测效果进行对比,其结果表明,PSO-ELM 具有更精确稳定的预测效果。本文提出一种蜻蜓算法优化的正则核极限学习机的光伏发电功率预测方法,该方法融合了 ELM 所需样本少、训练误差小和运行速度快等特点。同时拉格朗日函数和核函数的引入进一步加强模型的空间映射能力,避免数据过拟合等问题。蜻蜓算法具有涉及参数少、运算过程简单、收敛速度快等优势目前已被广泛地应用于参数优化问题。因此,本文采用蜻蜓算法对正则核极限学习机的权值和偏置值进行优化,构建一种蜻蜓-正则核极限学习机(Dragonfly algorithm regular kernel learning machine, DA-RKELM)光伏发电功率预测模型,并通过对比实验验证模型的有效性。

1 光伏发电的影响因素及相关性分析

1.1 光伏电池一般模型

光伏电池的电流和单位面积下光伏输出功率的计算公式分别如公式(1)~(2)所示:

$$I = I_L - I_D e^{\left(\frac{V + IR_S}{nT}\right) - 1} - \frac{V + IR_S}{R_{sh}} \quad (1)$$

$$P_s = \zeta SI[1 - 0.005(T - 25)] \quad (2)$$

式中: I 为电流; I_L 为光电流, 其值由太阳辐照强度决定; I_D 为二极管反向饱和电流, 其值受到串联电池数量 n 以及电池温度 T 的影响; V 为电压; R_S 为串联电阻; R_{sh} 为并联电阻; ζ 为光伏列阵的转换效率; S 为光伏列阵表面的等效光照强度。公式(1)~(2)中不可控的因素主要是太阳辐照强度和温度, 其他值都为可控因素, 可以通过人为调整使其处于最优。太阳辐照和温度属于气象因子, 且气象因子之间是相互影响的, 因素本文初步选定环境湿度、风速太阳辐照强度、大气温度、组件温度、和气压作为光伏发电功率的影响因子。

1.2 相关性分析

正为了进一步确定影响光伏发电功率的关键影响因子, 采用相关系数衡量各气象因子对光伏发电功率的影响。当相关系数 ρ_{XY} 的绝对值越接

近于 1, 表示该气象因子对光伏发电的影响程度越高, 接近 0 时, 表示该气象因子对光伏发电的影响越低, 为 0 时表示 2 个变量各自独立互不影响。

(X, Y) 是一个二维随机变量, 其中 X 表示与光伏发电功率有关的气象因子即辐照强度、环境温度、风速和湿度; Y 表示光伏发电功率。 $\text{cov}(X, Y)$ 表示 X 和 Y 的协方差, 其表达式为:

$$\text{cov}(X, Y) = E[X - E(X)]E[Y - E(Y)] \quad (3)$$

当 2 个随机变量的方差 $D(X)$ 和 $D(Y)$ 不等于零时, 变量 X 和 Y 的相关系数 ρ_{XY} 可表示为:

$$\rho_{XY} = \frac{\text{cov}(X, Y)}{\sqrt{D(X)}\sqrt{D(Y)}} \quad (4)$$

选取某光伏电站春、夏、秋、冬各一天的光伏发电功率作为研究对象, 采样时间为 05:30-20:15, 按照时间序列每 15 min 记录一次光伏电站的实际输出功率, 每天一个进行 60 次采样, 同时获取对应时刻下各气象因子数据。各季节某一天中的样本数据如图 1 所示, 光伏发电功率与各气象因子的相关系数如表 1 所示。




图 1 不同季节光伏发电功率输出情况

Fig1. Power output of photo-voltaic power generation in different seasons

表 1 各气象因子与光伏输出功率的相关系数
Tab. 1 Correlation coefficient between meteorological factors and photovoltaic output power

气象因子	相关系数
辐照强度	0.783
环境温度	0.559
组件温度	0.588
湿度	-0.383
风速	0.064 1
气压	0.047 7

图 1 中由于春夏秋冬的温度和湿度上的区别

导致光伏电站输出功率存在较大差别, 春季曲线的最大输出功率为 10.39, 夏季曲线的最大输出功率为 12.52, 秋季曲线的输出峰值为 8.94, 冬季曲线的输出峰值为 5.95, 夏季某一天中的光伏发电功率远高于其他 3 个季节某一天中的光伏发电功率。同时, 由于抽样的随机性和光伏电站所处的地理位置, 使得春夏秋冬某一天中的日照时长上没有体现出明显的差别, 表现出一定的偶然性, 但在进行模型训练时会选取多组样本进行训练, 因此, 以上结果不会不影响模型的预测效果。

由表 1 数据可知,辐照强度与光伏发电输出功率相关性最强,其次是环境温度和组件温度,最后是湿度。风速和气压与光伏发电输出功率的相关性均小于 0.1,说明风速和气压对光伏发电功率的影响十分微弱,可以忽略不计。根据相关性分析可知辐照强度、环境温度、组件温度和湿度是影响光伏发电功率的关键影响因子。此外,由于光伏发电功率表现出明显的时序性,因此,在进行功率预测是应将 t-1 时、t-2 时和 t-3 时的光伏输出功率也作为特征输入向量。

2 光伏发电功率预测模型构建

2.1 光伏电池一般模型

极限学习机(extreme learning machine, ELM)是黄广斌等^[21]基于广义逆矩阵理论提出的一类性能优良的新型单隐层前向型网络。极限学习机(extreme learning machine, ELM)结构如图 2 所示。




图 2 ELM 网络结构模型
Fig. 2 ELM network structure model

ELM 工作原理如下:ELM 为单隐层网络结构,网路参数包括:输入节点数 N 、隐层节点数 K 、输出节点数 M 和网络阈值 b_j 对于 n 的任意样本集 $(\mathbf{X}_i, \mathbf{Y}_i)$, 其中 $x_i = [x_{i1}, x_{i2}, \dots, x_{iN}]^T \in R$; $y_i = [y_{i1}, y_{i2}, \dots, y_{im}]^T \in R$ 。

一般极限学习机的函数模型如下所示:

$$f_{ELM}(\mathbf{x}) = \sum_{i=1}^k \beta_i h(\mathbf{w}_i \mathbf{x}_j + b_i) = y_j, j = 1, 2, \dots, n \quad (5)$$

式中: $\mathbf{w}_i = [w_{i1}, w_{i2}, \dots, w_{iN}]^T$ 为输入权向量,通过随

机选择连接输入 i_{th} 的隐藏神经元, $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{ik}]^T$ 输出权向量连接 i_{th} 处输出神经元; b_i 为在 i_{th} 神经元处的阈值; $h(x)$ 为节点激活函数。公式(5)的列矩阵表达形式为:

$$\mathbf{G}\beta = \mathbf{Y} \quad (6)$$

$$\mathbf{G} = \begin{bmatrix} h(w_1 x_1 + b_1) & \dots & h(w_k x_1 + b_k) \\ h(w_1 x_2 + b_1) & \dots & h(w_k x_2 + b_k) \\ \vdots & \dots & \vdots \\ h(w_1 x_n + b_1) & \dots & h(w_k x_n + b_k) \end{bmatrix}_{NK} \quad (7)$$

$$\beta = [\beta_1^T + \beta_2^T + \beta_3^T \dots \beta_k^T]_{KM}^T \quad (8)$$

$$\mathbf{Y} = [\mathbf{Y}_1^T + \mathbf{Y}_2^T + \mathbf{Y}_3^T \dots \mathbf{Y}_k^T]_{KM}^T \quad (9)$$

式中: \mathbf{G} 为隐层节点输出矩阵; T 为网络期望输出值。在网络训练过程中,为降低计算量和运行时间,隐层节点数往往会小于 N , 即 $K < N$ 。为使等式(6)成立,需要引入最小范数最小二乘解 $\hat{\beta}$ 来代替该线性系统的解,因此可以用 $\hat{\beta}$ 代替 β 。ELM 通过寻求最优的网络参数 $\hat{\beta}$ 以使得模型输入参数和输出期望值之间的误差最小,即:

$$\text{Min} E(\beta) = \|\mathbf{Y}_i - \mathbf{X}_i\| =$$

$$\text{Min}_{\beta} \|\mathbf{G}(w_1 \dots w_m, b_1 \dots b_m, x_1 \dots x_N) \beta - \mathbf{Y}\| = \|\mathbf{G}(w_1 \dots w_K, b_1 \dots b_K, x_1 \dots x_N) \hat{\beta} - \mathbf{Y}\| \quad (10)$$

根据 Moor-Penrose 广义逆理论,输出 β 。

$$\hat{\beta} = (\mathbf{G}^T \mathbf{G})^{-1} \mathbf{G}^T \mathbf{Y} \quad (11)$$

通过 Moor-Penrose 广义逆理论求解输出层参数的最小范数二乘解,可以有效避免了传统梯度算法的局部极值问题,但该方法容易导致过拟合现象,从而影响 ELM 预测模型的泛化能力,同时网络结构的稳定随着样本容量的扩大而减弱。为解决以上问题,本文提出了一种基于拉格朗日函数的正则化极限学习机(Regularized Extreme Learning Machine, RELM),以增强 ELM 的泛化能力和可控性。因此输出权向量 β 可进一步表示为:

$$\arg \text{Min}_{\beta_n} = \arg \text{Min}_{\beta_n} \left[\frac{1}{2} \|\beta_n\|^2 + \frac{1}{2} \mu \|\varepsilon^2\| \right] \quad (12)$$

$$\sum_{i=1}^k \beta_i h(\mathbf{w}_i \cdot \mathbf{x}_j + b_i) - y_j = \varepsilon_j \quad (13)$$

优化问题的相应拉格朗日函数:

$$L(\lambda, \varepsilon, \beta) = \frac{1}{2} \|\beta^2\|^2 + \frac{\mu}{2} \|\varepsilon^2\|^2 - \lambda(\mathbf{G}\beta^2 - y - \varepsilon) \quad (14)$$

$\lambda = [\lambda_1, \lambda_2, \dots, \lambda_n]$ 为拉格朗日乘子, 令将 λ 和 β 的偏导数等于零, 可得网络最优参数:

$$\hat{\beta} = \left(\frac{1}{\mu} + \mathbf{G}^T \mathbf{G} \right)^{-1} \mathbf{G}^T \mathbf{Y} \quad (15)$$

考虑特征映射函数 G 未知的情形, 此时需核函数引入到 RELM 中, 以增强高维隐层特征空间的映射能力, 定义核矩阵为:

$$\Omega_{ELM} = \mathbf{G}\mathbf{G}^T = K(x_i, x_j) \quad (16)$$

引入核函数的网络输出模型为:

$$\mathbf{Y} = \mathbf{G}\hat{\beta} = \mathbf{G} \left(\frac{1}{\mu} + \mathbf{G}^T \mathbf{G} \right)^{-1} \mathbf{G}^T \mathbf{Y} = \begin{bmatrix} K(x, x_1) \\ K(x, x_2) \\ \vdots \\ K(x, x_N) \end{bmatrix} \left(\frac{1}{\mu} + \mathbf{G}^T \mathbf{G} \right)^{-1} \mathbf{Y} \quad (17)$$

本文选用径向基核函数, 其表达式为:

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (18)$$

式中: σ 为内核函数参数。

2.2 蜻蜓算法

蜻蜓算法 (Dragonfly algorithm, DA) 是 Seyedali Mirjalili 提出的一种群体智能算法^[22]。DA 模拟了自然界中蜻蜓的静态(狩猎)和动态(迁移)蜂群行为。在静态群(探索阶段)中, 蜻蜓成群结队, 在小范围内来回飞行, 以捕猎其他飞行的猎物, 例如蝴蝶和蚊子^[23]。静态运动的主要特征是飞行路线中的局部运动和突变。然而, 在动态群(开发阶段)中, 大量的蜻蜓使群在一个方向上长距离迁移。静态和动态群集行为类似于对元启发式优化的探索和利用。蜻蜓算法中个体行文要遵循的主要原则是: 分离、对其、内聚、食物吸引和排敌原则。

(1) 分离原则, 即个体为了避免与其他邻居个体发生碰撞而遵循的机制。

(2) 对齐原则, 即个体根据速度匹配其他临近的个体, 对齐表示个体与相邻其他个体的速度匹配。

(3) 内聚原则, 即种群的归属感, 个体试图接近自己的所属群体。

(4) 食物吸引原则, 即食物对蜻蜓的吸引力, 使得蜻蜓不断向食物靠近, 食物表示当前最优解。

(5) 排敌原则: 即蜻蜓对天敌的排斥力, 天敌表示当前最劣的解。

以上 5 种原则决定了蜻蜓个体步长向量($\Delta\mathbf{X}$)更新公式:

$$\Delta\mathbf{X}_{t+1} = (sS_i + aA_i + cC_i + fF_i + eE_i) + w\Delta\mathbf{X}_t \quad (19)$$

式中: S_i 为分离因子; A_i 为对齐因子; C_i 为内聚度因子; F_i 为食物因子; E_i 为天敌因子; s, a, c, f, e 分别为以上各因子的权重; w 为惯性权重; t 为迭代次数。以上 5 种行为因子的数学表达式分别如公式(20)~(24)所示:

$$S_i = -\sum_{j=1}^N X - X_j \quad (20)$$

$$A_i = \frac{\sum_{j=1}^N V_j}{N} \quad (21)$$

$$C_i = \frac{\sum_{j=1}^N X_j}{N} - X \quad (22)$$

$$F_i = X^+ - X \quad (23)$$

$$E_i = X^- + X \quad (24)$$

式中: X 为当前个体的位置; X_j 为 X 位置的第 j 个相邻个体; N 为相邻个体的数目; V_j 为第 j 个相邻个体的速度; X^+ 为食物的位置; X^- 为敌人位置。在连续搜索空间中蜻蜓通过将步向量添加到当前的位置。然而, 在二进制搜索空间中, 应使用以下方程式:

$$X_{t+1} = \begin{cases} -X_t, & r < T(\Delta\mathbf{X}_{t+1}) \\ X_t, & r \geq T(\Delta\mathbf{X}_{t+1}) \end{cases} \quad (25)$$

式中: r 是 $[0, 1]$ 范围内的随机数式, “-” 表示取反运算, $T(\Delta\mathbf{X}_{t+1})$ 计算如公式(26)所示:

$$T(\Delta\mathbf{X}) = \left| \frac{\Delta\mathbf{X}}{\sqrt{\Delta\mathbf{X}^2 + 1}} \right| \quad (26)$$

2.3 基于 DA-RKELM 的光伏发电功率预测模型

RKELM 的网络参数会严重影响网络的输出结果,为此本文引入蜻蜓算法对输入权重 w 、输出权重 β 和网络阈值 b 进行优化。其中蜻蜓个体的每个个体位置代表一组网络参数即 $X = (\omega, \beta, b)$, 蜻蜓初始位置即初始参数,将训练集的平均绝对误差 (mean absolute error, MAE) 作为适应度函数。利用蜻蜓算法进行多次迭代寻优,获得的最优个体的位置即 ELM 的最优网络参数。

基于蜻蜓算法优化的正则核极限学习机的流程如图 3 所示。

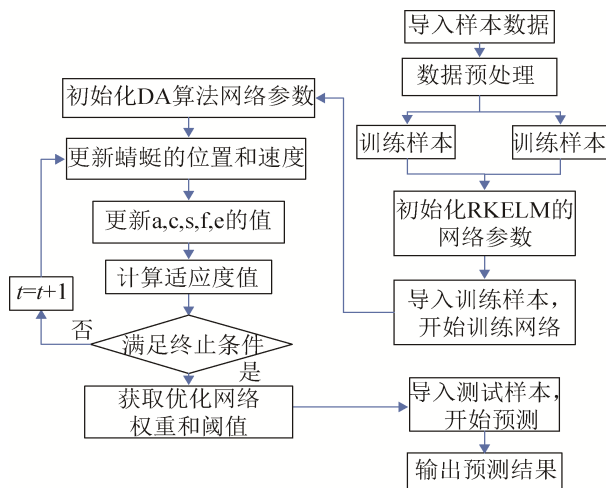


图 3 DA-RKELM 流程图
Fig. 3 DA-RKELM flow chart

基于 DA-RKELM 的光伏发电功率预测具体流程如下所示:

step 1: 选取样本数据 (X_i, Y_i) , 包括光伏发电功率、辐照强度、环境温度、组件温度和湿度、 $t-1$ 刻的输出功率、 $t-2$ 刻的输出功率、 $t-3$ 刻的输出功率;

step 2: 对样本数据进行归一化处理, 并对训练样本和测试样本进行划分;

step 3: 开始训练网络, 导入训练样本, 确定输入节点个数, 和输出节点个数;

step 4: 蜻蜓算法参数设置: 总群规模、空间维度、分离权重 s 、对齐权值 a 、衔接权重 c 、食物

因子 f 、敌人因子 e 、是惯性权重 w 、个体位置 X 和步长 ΔX , 并以初始权重和阈值作为个体的初始位置, 即 $X = (\omega, \beta, b)$, 空间维数对应待优化参数的个数, 即空间纬度取值为 3;

step 5: 根据公式(20)~(24)计算步长向量, 基于公式(19)和(25)更新个体位置;

step 6: 将更新的蜻蜓的个体位置赋值给 w 、 β 和 b ;

step 7: 计算适应度值, 即: 平均绝对误差 (MAE), 当其满足输出条件时, 输出当前个体位置上的权重和阈值; 反之即, 令 $t=t+1$, 然后返回至 step 5;

step 8: 将最优的一组参数网络创建最优的 RKELM 模型, 对测试样本进行预测。

3 仿真实验与结果分析

本文建立基于蜻蜓算法优化正则核极限学习机预测模型, 对光伏发电功率进行仿真预测。以某实际光伏电站为研究对象, 从 2016 年的历史数据中随机抽取 6 天的数据作为训练样本, 其中包括光伏电站的实测数据和相关气象因子数据, 共计 $10 \times 60 = 600$ 组数据, 以春夏秋冬各一天的历史数据作为测试样本。辐照强度、环境温度、组件温度和湿度等数据单位和数量级存在明显的差异。因此, 采用归一化方法对以上数据进行处理以提高数据处理的灵活性。将以上 4 个影响因子参数线性归一化处理至区间 $[0, 1]$ 上, 归一化计算表达式为:

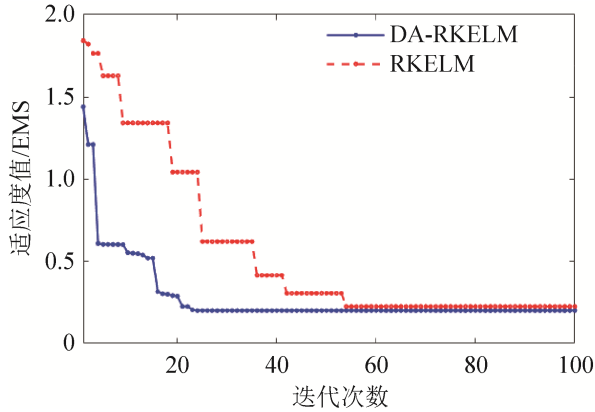
$$X(t) = \frac{x(t) - x_{\min}(t)}{x_{\max}(t) - x_{\min}(t)} \quad (27)$$

式中, $x(t)$ 为需要进行归一化的数据; $X(t)$ 为处理后的数据; $x_{\min}(t)$ 和 $x_{\max}(t)$ 分别为该组数据集合中的极小值和极大值。

(1) 算法优化效果评价

为验证蜻蜓算法对网络参数的优化效果, 本文将 RKELM 模型和基于蜻蜓算法优化的 DA-RKELM 模型的预测效进行对比对比。蜻蜓总

群规模为 30, 最大迭代次数为 100, s 、 a 、 c 、 f 、 e 和 w 均设为线性递减权, 取值范围为[0.3, 0.9]。模型输出结果如图 4 所述。



4 DA-RKELM 和 RKELM 算法的预测效果对比
Fig. 4 Comparison of prediction results of da-rkelm and rkelm algorithms

根据图 4 的可知, DA-RKELM 模型在 $t=25$ 时, 获得最优的适应的值, 与未引入蜻蜓算法优化的 RKELM 模型的预测效相比, 基于蜻蜓算法优化的 DA-RKELM 预测模型的收敛速度和寻优能力更强, 这是由于蜻蜓算法的引入使得 DA-RKELM 模型能在更少的迭代次数下, 快速的寻得最优的网络参数, 在提高寻优速度的同时, 也进一步提升了寻优质量。

(2) 算法预测效果评价

为验证 DA-RKELM 算法的有效性, 以 DA-ELM、PSO-ELM 和 GA-ELM 作为对比算法, 对光伏发电功率进行预测。设定以上算法网络结构的输入层和输出层的节点个数为 7 和 1, 初始权重和阈值随机产生, 最大迭代次数为 100, 种群规模为 30。其具体预测结果如图 5~8 所示, 各算法模型仿真实验的适应度值变化如图 9 所示。




图 5 春季光伏发电功率预测结果
Fig. 5 Power prediction results of photovoltaic power generation in spring




图 6 夏季光伏发电功率预测结果
Fig. 6 Power prediction results of photovoltaic power generation in summer

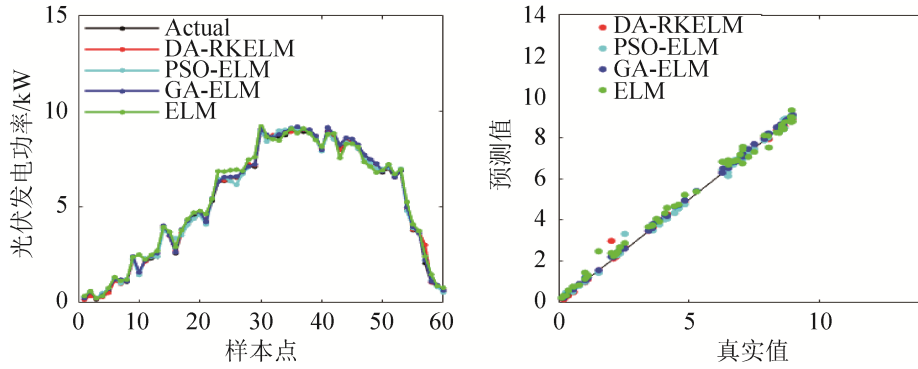


图7 秋季光伏发电功率预测结果

Fig. 7 Power prediction results of photovoltaic power generation in autumn

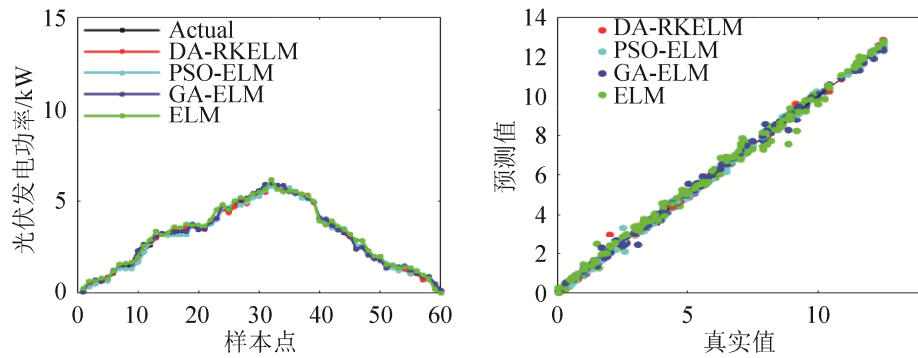


图8 冬季光伏发电功率预测结果

Fig. 8 Power prediction results of photovoltaic power generation in winter

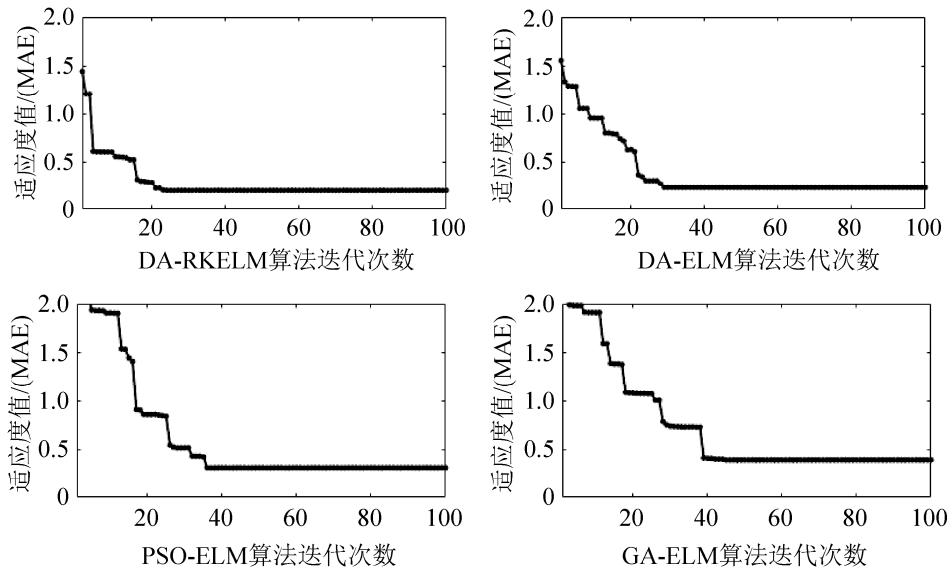


图9 预测模型适应度值随迭代次数的变化曲线

Fig. 9 Change curve of fitness value of prediction model with number of iterations

由适应度函数变化可知, 以上算法均在50代以内完成权重和阈值的寻优, 通过对比发现DA-RKELM模型可以获得更优的适应度值, 其初

始适应度值为1.442、最终适应度值为0.195均优于DA-ELM、PSO-ELM和GA-KLM, 同时其寻优的速度更快, 通过25次迭代即可完成训练, 这是

由于 RELM 将数据映射到高维空间后, 采用蜻蜓算法优化使得模型将会以更快的速度达到最优, 大大提升模型的预测效率。

各算法模型仿真实验的适应度值变化如图 9 所示。

为进一步评估预测模型的性能, 并使得各预测模型之间可以相互比较, 采用均方根误差(RMSE)、平均误差百分比(MAPE)和平均绝对误差(MAE), 对以上各预测模型的预测精确的进行评价。假设样本的数量为 N 预测值为 f_i , 真实值为 F_i 。

$$MAE = \frac{1}{N} \sum_{i=1}^N |f_i - F_i| \quad (28)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (f_i - F_i)^2} \quad (29)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{f_i - F_i}{F_i} \right| \times 100\% \quad (30)$$

通过对测试样本进行 10 次运行计算, 得到各优化算法下的误差均值和波动情况。预测误差结果具体数据如表 2 所示。根据表 2 数据结果可知 DA-RKELM 预测模型的均方根误差、平均相对百分比误差、平均绝对误差均小于其他 3 种模型。以平均误差百分比衡量, 其准确率高达 90.96%, 相对于 DA-ELM、PSO-ELM 和 GA-ELM 预测模型其准确率提高了 4.39%、7.11%、12.47%。通过计算各误差指标的标准偏差可以看出, 该算法的稳定性较强, 这是由于正则函数和核函数的引入增强了模型的稳定性和可控性。

表 2 各预测模型预测误差结果对比

Tab. 2 Comparison of prediction error results of each prediction model

评价指标	DA-RKELM		DA-ELM		PSO-ELM		GA-ELM	
	Mean	SD	Mean	SD	Mean	SD	Mean	SD
MAE	0.194 5	0.009 9	0.64	0.036 0	0.312 9	0.056 1	0.396 25	0.043 4
RMSE	0.074 5	0.023 7	0.185 7	0.046 0	0.160 6	0.083 4	0.190 9	0.810
MAPE	9.04%	0.073 7	13.43%	0.034 7	16.15%	0.034 68	21.51%	0.065 2

4 结论

本文在分析光伏发电一般原理的基础上, 采用相关性分析确定影响光伏发出力的关键气象因子为: 辐照强度、环境温度、组件温度和湿度。在标准 ELM 算法的基础上引入正则化函数和核函数, 提出一种基于蜻蜓算法优化的正则核极限学习机预测模型, 并将其应用于光伏发电功率预测, 给光伏发电系统提供决策参考。基于某光伏电站的历史运营数据进行仿真实验, 其结果表明:

(1) 蜻蜓算法的寻优能力优于粒子群算法和遗传算法, 能在较短时间内搜索到较优的网络输出权重 β 、输入权重 w 和阈值 b 。

(2) 采用平均绝对误差、均方根误差和平均误差百分比对各预测模型的预测结果进行评价, 其结果表明, 引入正则函数和核函数的 DA-RKELM 模

型的稳定性、泛化能力和空间映射能力均优于 DA-ELM 模型、PSO-ELM 模型和 GA-ELM 模型, 能够实现最优特征组合, 具有良好的预测效果。

(3) 将 DA-RKELM 模型应用与光伏发电功率预测, 极大的提升了光伏功率的预测精度, 有利于促进光伏发电的安全与平稳运行。

参考文献:

- [1] Feng L, Zhang J N, Li G J, et al. Cost reduction of a hybrid energy storage system considering correlation between wind and PV power[J]. Protection and Control of Modern Power Systems (S2397-2617), 2016, 1(1): 86-94.
- [2] Ramakrishna R, Scaglione A. A comprehensive sensing framework for the analysis of solar Photo-Voltaic power[C]. Signals, Systems and Computers, 2016, Asilomar Conference on. IEEE. USA: IEEE, 2016: 308-312.

- [3] Philip J, Jain C, Kant K, et al. Control and implementation of a standalone solar photo-voltaic hybrid system[J]. IEEE Transactions on Industry Applications (S0093-9994), 2016, 52(4): 3472-3479.
- [4] Sharma D, Mishra S, Nanda J. Micro-grid operation and control of Photo-Voltaic power with canal based small hydro power plant[C]. Region 10 Conference. IEEE, 2017: 1289-1293.
- [5] De G M G, Congedo P M, Malvoni M. Photovoltaic power forecasting using statistical methods: impact of weather data[J]. IET Science Measurement & Technology (S1751-8822), 2014, 8(3): 90-97.
- [6] 高阳, 张碧玲, 毛京丽, 等. 基于机器学习的自适应光伏超短期出力预测模型[J]. 电网技术, 2015, 39(2): 307-311.
Gao Yang, Zhang Biling, Mao Jingli, et al. Machine Learning-Based Adaptive Very-Short-Term Forecast Model for Photovoltaic Power[J]. Power System Technology, 2015, 39(2):307-311.
- [7] Muhammad W A, Monjur M, Yacine R. Tree-based ensemble methods for predicting PV power generation and their comparison with support vector regression[J]. Energy (S0360-5442), 2018, 164: 465-474.
- [8] 黄予春, 曹成涛, 顾海. 基于 IKFCM 与多模态 SSO 优化 SVR 的光伏发电短期预测[J]. 电力系统保护与控制, 2018, 46(24): 96-103.
Huang Yuchun, Cao Chengtao, Gu Hai. Short-term photovoltaic power generation forecasting scheme based on IKFCM and multi-mode social spider optimization SVR[J]. Power System Protection and control, 2018, 46(24): 96-103.
- [9] 王晓兰, 葛鹏江. 基于相似日和径向基函数神经网络的光伏阵列输出功率预测[J]. 电力自动化设备, 2013, 33(1): 100-103.
Wang Xiaolan, Ge Pengjiang. Output Power Prediction of Photovoltaic Array Based on Similar Day and Radial Basis Function Neural Network[J]. Electric Power Automation Equipment, 2013, 33(1): 100-103.
- [10] 张雨金, 杨凌帆, 葛双冶, 等. 基于 Kmeans-SVM 的短期光伏发电功率预测[J]. 电力系统保护与控制, 2018, 46(21): 118-124.
Zhang Yujin, Yang Lingfan, Ge Shuangzhi, et al. Short-term photovoltaic power forecasting based on Kmeans algorithm and support vector machine[J]. Power System Protection and control, 2018, 46(21): 118-124.
- [11] 于群, 朴在林, 胡博. 基于 EEMD 和 BP 神经网络的短期光伏功率预测模型[J]. 电网与清洁能源, 2016, 32(1): 132-137.
Yu Qun, Pu Zailin, Hu Bo. A Hybrid Model for Short-Term Photovoltaic Power Forecasting Based on EEMD-BP Combined Method[J]. Power System and Clean Energy, 2016, 32(1): 132-137.
- [12] 张立影, 孟令甲, 王泽忠. 基于双层 BP 神经网络的光伏电站输出功率预测[J]. 电测与仪表, 2015, 52(11): 31-35.
Zhang Liying, Meng Lingjia, Wang Zezhong. Output Power Prediction of Photovoltaic Power Station Based on Double Layer BP Neural Network[J]. Electrical Measurement & Instrumentation, 2015, 52(11): 31-35.
- [13] 刘俊, 王旭, 郝旭东, 等. 基于多维气象数据和 PCA-BP 神经网络的光伏发电功率预测[J]. 电网与清洁能源, 2017, 33(1): 122-129.
Liu Jun, Wang Xu, Hao Xudong, et al. Photovoltaic Power Forecasting Based on Multidimensional Meteorological Data and PCA-BP Neural Network[J]. Power System and Clean Energy, 2017, 33(1): 122-129.
- [14] 张彩庆, 郑强. SKBA-LSSVM 短期光伏发电功率预测模型[J]. 电力系统及其自动化学报, 2019, 31(8): 86-93.
Zhang Caiqing, Zheng Qiang. SKBA-LSSVM Short-term Forecasting Model for PV Power Generation[J]. Proceedings of the CSU-EPSCA, 2019, 31(8): 86-93.
- [15] 王育飞, 付玉超, 薛花. 计及太阳辐射和混沌特征提取的光伏发电功率 DMCS-WNN 预测法[J]. 中国机电工程学报, 2019, 39(增 1): 63-71.
Wang Yufei, Fu Yuchao, Xue Hua. DMCS-WNN Prediction Method of Photovoltaic Power Generation by Considering Solar Radiation and Chaotic Feature Extraction[J]. Proceeding of the CSEE, 2019, 39(S1): 63-71.
- [16] 刘沛汉, 袁铁江, 梅生伟, 等. 基于遗传算法优化神经网络的光伏电站短期功率预测[J]. 水电能源科学, 2016, 34(1): 211-214.
Liu Peihan, Yuan Tiejiang, Mei Shengwei, et al. Short term Power Prediction of Photovoltaic Power Station Based on Neural Network Optimized by Genetic Algorithm[J]. Water Resources and Power, 2016, 34(1): 211-214.
- [17] 王文锦, 戚佳金, 王文婷, 等. 基于人工蜂群优化极限学习机的短期负荷预测[J]. 电测与仪表, 2017, 54(11): 32-35.
Wang Wenjin, Qi Jiajin, Wang Wenting, et al. Short-term load forecasting based on with artificial bee improved extreme learning machine[J]. Electrical Measurement & Instrumentation, 2017, 54(11): 32-35.

- [18] 宗宸生, 郑焕霞, 王林山. 改进粒子群优化 BP 神经网络粮食产量预测模型[J]. 计算机系统应用, 2018, 27(12): 204-209.
Zong Chensheng, Zheng Huanxia, Wang Linshan. Grain Yield Prediction Based on BP Neural Network Optimized by Improved Particle Swarm Optimization[J]. Computer Systems & Applications, 2018, 27(12): 204-209.
- [19] 丁华, 常琦, 杨兆建, 等. 基于极限学习机的采煤机功率预测算法研究[J]. 煤炭学报, 2016, 41(3): 794-800.
Ding Hua, Chang Qi, Yang Zhaojian, et al. Research on the algorithm of shearer power prediction based on extreme learning machine[J]. Journal of China Coal Society, 2016, 41(3): 794-800.
- [20] 蒋建东, 余泮, 董存, 等. 基于 PSO 与 ELM 组合算法的短期光伏发电功率预测模型[J]. 郑州大学学报, 2019, 51(3): 120-126.
Jiang Jiandong, Yu Peng, Dong Cun, et al. Short Term Photovoltaic Power Prediction Model Based on PSO and ELM Combined algorithm[J]. Journal of Zhengzhou University, 2019, 51(3): 120-126.
- [21] Huang G B, Zhu Q Y, Siew C K. Extreme Learning Machine: Theory and Applications[J]. Neuro Computing (S0925-2312), 2006, 70(1): 489-501.
- [22] Mirjalili S. Dragonfly algorithm: a new meta-heuristic optimization technique for solving single-objective, discrete, and multi-objective problems[J]. Neural Computing & Applications (S0941-0643), 2016, 27(4): 1053-1073.
- [23] Sree R K S, Murugan S. Memory based Hybrid Dragonfly Algorithm for Numerical Optimization Problems[J]. Expert Systems with Applications (S0957-4174), 2017, 83(1): 63-78.