

[电力负荷]

基于改进蜣螂算法优化的电力负荷生长曲线预测模型

文/虞子萱¹ 缪乐颖² 冯国明³ 沈健³ 沈林辉³

1. 国网浙江省电力有限公司建德市供电公司; 2. 国网浙江省电力有限公司; 3. 中能聚创(杭州)能源科技有限公司

提出一种基于改进蜣螂优化算法的电力负荷生长曲线预测模型,旨在提高电力负荷预测的准确性和通用性。改进的蜣螂优化算法通过引入混沌数、Chebyshev混沌映射、黄金正弦策略和莱维飞行策略,增强算法的全局搜索能力和收敛速度。通过与基于粒子群优化的电力负荷灰色预测模型比较,验证所提模型在预测准确度上的优势。实例分析表明,改进的蜣螂优化算法在电力负荷预测中具有快速收敛能力和高预测准确度。最后,得出结论, IDBOLM作为一种稳健且有效的预测模型,对于电力系统运行和规划具有重要的参考价值。

精确预测电力负荷对于保障电力供应、电网的稳定运作以及推动国家经济发展具有关键性的作用^[1]。当前的电力负荷预测技术主要分为统计分析和机器学习两大类。以时间序列分析为代表的统计方法因其原理简洁而受到青睐,但在处理波动剧烈的非线性电力负荷数据时,其预测效果并不理想。而随机森林、支持向量机等机器学习技术能够捕捉电力负荷与相关因素之间的非线性联系,对处理波动性大的非线性数据更为有效。不过,这些方法在建立模型时对所选样本的依赖性较强^[2]。近几年,许多学者使用深度学习预测方法来进行电力负荷预测^[3]。许多研究人员也开始利用 Transformer 结构来进行电力负荷预测^[4-6]。但是上述方法仍然存在提取的特征质量不够高,以及对于序列有效信息的关注不够充分等问题^[7]。这些方法为电力负荷预测的研究提供了有力的工具,但都存在着各自的缺陷。

S曲线,也即生长曲线,起初增长较为缓慢,随后在某些条件的驱动下,增长速度在某个阶段会显著加快,直至接近某一上限后增长速度再次减慢,最终停止增长。正是由于这种特性,生长曲线

被广泛应用于多个领域,包括生物学、电力负荷预测以及地基沉降预测等。

生长曲线一般形式为

$$y(t) = \frac{1}{1 + b \exp(-kt)} \quad (1)$$

式中,参数 b 和 k 是需要确定的两个关键变量。

通过精确计算生长曲线模型中的这两个参数,可以有效提升模型的拟合度和预测的准确性。考虑到模型参数与误差之间呈现出明显的非线性特征,本文采用一种改进版的蜣螂优化算法来寻找最优参数,该算法以其出色的全局搜索能力和快速的收敛速度而著称。基于这种改进算法,本文构建一种电力负荷生长曲线预测模型。实际测试的数据显示,该模型在提升预测准确度方面表现出色。

改进的蜣螂优化算法

1. 蜣螂优化算法

蜣螂优化算法^[8] (Dung Beetle Optimizer, DBO) 是一种新型的智能优化方法,它主要模拟了蜣螂的五种核心行为:滚球、旋转、交配、觅食和

盗窃。

传统的蜣螂优化算法的初始解是随机产生的，使得种群多样性不足，寻优效果有限，收敛速度不快。为改善这一问题，使用混沌数来替代原算法中的随机变量，以实现更全面的搜索。

2. Chebyshev混沌映射

Chebyshev混沌映射是一种常用的混沌映射，其在非线性动力系统和密码学等领域中具有广泛应用。本文加入Chebyshev混沌映射方法，使种群初始拥有随机性、非周期性等特性，其数学表达式为

$$x_{k+1} = \cos(k \cos^{-1}(x_k)) \quad (2)$$

式中， x_{k+1} 为第 $k+1$ 代混沌序列的值； x_k 为第 k 代混沌序列的当前值； k 为当前迭代次数。

3. 黄金正弦策略

正弦函数上的点都可以通过黄金正弦算法进行遍历，引入黄金分割系数到位置更新中，旨在对局部区域进行充分的探索，既可以让滚球蜣螂的局部开发能力和全局搜索达到更好的平衡，也能够提升蜣螂算法的收敛速率和解的精确度。在应用黄金正弦法则后，滚球蜣螂的位置更新公式为

$$x_i(t+1) = x_i(t) |\sin(r_1)| - r_2 \sin(r_1) |c_1 X^* - c_2 x_i(t)| \quad (3)$$

式中， $x_i(t+1)$ 为第 i 只蜣螂更新后的位置信息； $x_i(t)$ 为第 i 只蜣螂的当前位置信息； X^* 为当前最优解； $r_1 \in (0, 2\pi]$ 的随机数； $r_2 \in (0, \pi]$ 的随机数； c_1 和 c_2 为引入黄金分割数后得到的系数为

$$\begin{cases} c_1 = a\tau + b(1-\tau) \\ c_2 = a(1-\tau) + b\tau \end{cases} \quad (4)$$

式中， τ 取值为 $(1-\sqrt{5})/2$ 的黄金分割数； a 、 b 初始值设置为 $-\pi$ 和 π ，随后 a 和 b 随着目标变化而改变。

4. 莱维飞行策略

在更新盗窃蜣螂的位置时，蜣螂依据当前最佳解来调整自己的位置，这可能导致一旦最佳解陷入局部最优，整个算法就会停滞不前。因此，存在算法陷入局部最优的风险。

结合短程和长程飞行策略，Levy飞行优化了对解空间的全面探索，从而增强算法的全局搜索性能。而使用Levy飞行策略进行位置更新使得蜣螂搜索更广泛，此时盗窃蜣螂的位置更新公式变为

$$x_i(t+1) = X^b + Sg(|x_i(t) - X^*| + |x_i(t) - X^b|) \oplus L(\lambda) \quad (5)$$

式中， $\oplus$ 表示点乘； $L(\lambda)$ 为服从Lévy分布的步长。

电力负荷生长曲线预测模型

1. 模型的建立

在时间序列分析领域，用于电力负荷预测的生长曲线模型的函数表达式为 $y(t) = \frac{1}{1 + b \exp(-kt)}$ ，这种模型本质上是一个非线性方程。使用传统方法处理这类方程时，计算过程复杂，泛化能力有限，且容易受到人为因素的影响。这些因素都可能导致预测结果出现较大偏差，难以获得全局最优的解。

蜣螂优化算法是一种基于群体智能的全面优化策略，它以强大的全局搜索能力、对经验参数的低依赖性、无需函数连续性或可微性以及快速的收敛速度而著称。在本文中，采用较为稳健的最小一乘法原则，构建一个改进版的蜣螂优化算法，用于电力负荷生长曲线的预测模型（IDBOLM），公式为

$$\min f(b, k) = \sum_{i=1}^m \left| y(t_i) - \frac{1}{1 + b \exp(-kt_i)} \right| \quad (6)$$

当式（6）达到其最小值时，相应的参数组 b 和 k 即为最优解，这些参数可以通过实际观测数据 $(t_i, y(t_i))$ 确定。

2. 模型的求解

模型求解流程如下：

- 1) 初始步骤。对蜣螂群体的位置和速度进行随机初始化。
- 2) 适应度评估。根据蜣螂的行为计算每个个体的适应度。
- 3) 个体最优更新。比较每个蜣螂的适应度与其历史最佳位置pbest的适应度，若当前适应度更佳，则更新pbest。
- 4) 全局最优更新。比较每个蜣螂的适应度与当前全局最佳位置gbest的适应度，若当前适应度更佳，则更新gbest。
- 5) 迭代判断。若未满足终止条件（如达到预设的适应度阈值或迭代次数达到itermax），则回到步骤2。
- 6) 结果输出。最终输出达到全局最优的适应度值。

模型求解结果如图1所示。




图1 3种模型的寻优曲线

由图1可以看出, IDBO算法具有较强的快速收敛能力, 在第21次迭代时收敛, 且其最低适应度值为0.007 1, DBO算法和SSA算法分别收敛于0.029 6和0.033 2, 收敛准确度与IDBO算法相比较差。综

上可知, IDBO算法改进后收敛速度更快, 并且准确度也更高, 证明本文选用该算法的合理性。

电力负荷预测的实例分析

为证实本文提出的模型的实用性, 采用浙江省某城市的四种典型电力负荷序列作为测试样本, 这些数据列在表1中。表1所展示的按年份编号排列的数据被用作评估模型性能的基础数据集。

表1 模型测试负荷数据

年份	居民负荷	行政办公用户负荷	商业商务负荷	一类工业负荷
1	0.455 753 274	0.685 119	0.536 883	0.747 561
2	0.543 526 772	0.768 951	0.632 928	0.834 747
3	0.628 677 841	0.835 813	0.719 463	0.896 009
4	0.70 652 143	0.88 619	0.792 292	0.936 294
5	0.773 914 632	0.922 542	0.850 153	0.961 641
6	0.829 565 203	0.947 965	0.89 405	0.977 149

生长曲线预测结果如图2所示。




图2 生长曲线预测结果

对各模型进行了后验差和相对误差比率的评价，具体结果详见表2。根据表2的数据，可以看到，在对表1列出的四种电力负荷数据序列进行预测时，本研究提出的IPSOLM模型在后验检验中表现优异，其后验差值均优于PSOGM模型。在四组测试数据中，IPSOLM模型的相对误差相较于PSOGM模型有显著降低，预测值与实际值的吻合度极高，显示出极高的精确度。

表2 模型预测结果和误差

模型	负荷	参数		后验差 比值 (%)	相对误差 (%)
		b	k		
IDBOLM	居民负荷	1.698	0.352	0.000 7	$-3.514 5 \times 10^{-5}$
	行政办公 用户负荷	0.703	0.425	0.000 8	$5.677 9 \times 10^{-5}$
	商业商务 负荷	1.283	0.397	0.000 5	$3.457 2 \times 10^{-5}$
	一类工业 负荷	0.576	0.534	0.002 1	$4.671 7 \times 10^{-6}$
PSOLM	居民负荷	3.348 6	0.389 28	0.695 3	0.003 5
	行政办公 用户负荷	1.570 2	0.510 02	0.427 6	0.011 7
	商业商务 负荷	1.570 2	0.510 02	0.190 6	0.100 6
	一类工业 负荷	1.223 2	0.414 12	2.402 8	-19.67 8

结束语

电力负荷预测对于电力系统的运营管理和战略规划至关重要，随着电力市场的不断发展，对负荷预测的精确度要求也在不断提升。IDBOLM预测模型有效地解决传统预测方法中存在的计算复杂性和人为因素影响的问题，它不依赖于待优化函数的连续性或可微性，展现出强大的全局优化能力，是一种理想的预测工具。该模型的预测结果显示，其在电力负荷预测方面具有高可靠性、精确度和广泛的适用性，作为一个稳定而有效的预测工具，具有重要的实用参考价值。EA

(收稿日期：2024-11-17)

参考文献

[1] 钱育树，孔钰婷，黄聪．电力负荷预测研究综述[J]．四川电力技术，2023，46(4)：37-43+58.

[2] 任建吉，位慧慧，邹卓霖，等．基于CNN-BiLSTM-Attention的超短期电力负荷预测[J]．电力系统保护与控制，2022，50(8)：108-116.

[3] Azeem A, Ismail I, Jameel S M, et al. Electrical Load Forecasting Models for Different Generation Modalities: A Review[J]. IEEE Access, 2021(9): 142239-142263.

[4] Zhou H, Zhang S, Peng J, et al. Informer: Beyond Efficient Transformer for Long Sequence Time-Series Forecasting[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35(12): 11106-11115.

[5] Zhou T, Ma Z, Wen Q, et al. Fedformer: Frequency enhanced decomposed transformer for long-term series forecasting[C]//International conference on machine Learning. PMLR, 2022: 27268-27286.

[6] Wu H, Xu J, Wang J, et al. Autoformer: Decomposition transformers with auto-correlation for long-term series forecasting[J]. Advances in neural information processing Systems, 2021(34): 22419-22430.

[7] 顾家辉，杨镜非．基于抽样卷积交互网络和改进Informer的多元负荷预测方法[J]．电气自动化，2023，45(2)：109-111+115.

[8] 刘杰，从兰美，夏远洋，等．基于DBO-VMD和IWOA-BiLSTM神经网络组合模型的短期电力负荷预测[J]．电力系统保护与控制，2024，52(8)：123-133.

