

# 结合小波变换与改进 SSA 优化小波神经网络的电力负荷预测

向东<sup>1</sup>, 赵文博<sup>1</sup>, 王玖斌<sup>2</sup>, 邢岳辉<sup>3</sup>, 张伟<sup>1</sup>, 石灿<sup>1</sup>, 陈柄宏<sup>1</sup>

(1. 华能重庆两江燃机发电有限责任公司, 重庆 400799;

2. 华能重庆分公司, 重庆 401120;

3. 北京中电方大科技有限公司, 北京 100095)

**摘要:** 电力负荷预测是输电网络扩展和规划及合理电力调度的关键手段; 针对电力负荷时间序列的非线性和复杂性特征, 提出结合小波变换与改进麻雀搜索算法优化小波神经网络的电力负荷预测模型 ISSA-WNN; 设计改进麻雀搜索算法 ISSA 对小波神经网络的关键参数初值寻优, 解决梯度调参易陷入局部最优的不足; 对标准麻雀搜索算法 SSA 改进, 引入 Logistic-Tent 混沌种群初始化、发现者/警戒者自适应更新、跟随者可变对数螺旋更新和高斯-柯西混合变异策略提升算法寻优能力; 利用小波变换对电力负荷样本分解与重构, 降低负荷时序的无序性和波动性, 在此基础上构建新的电力负荷预测模型 ISSA-WNN; 实验结果表明, 与标准小波神经网络模型 WNN 和标准麻雀搜索算法优化小波神经网络模型 ISSA-WNN 相比, 预测模型 ISSA-WNN 的平均绝对百分比误差和均方根误差指标值平均可以降低 18.42% 和 21.21%, 其拟合能力更强, 预测性能更加稳定。

**关键词:** 电力负荷预测; 小波神经网络; 小波变换; 麻雀搜索算法; 高斯-柯西变异

## Combining Wavelet Transformed and Improved SSA Optimizing Wavelet Neural Network for Power Load Prediction

XIANG Dong<sup>1</sup>, ZHAO Wenbo<sup>1</sup>, WANG Jiubin<sup>2</sup>, DENG Yuehui<sup>3</sup>,  
ZHANG Wei<sup>1</sup>, SHI Can<sup>1</sup>, CHEN Binghong<sup>1</sup>

(1. Huaneng Chongqing Liangjiang Gas Turbine Power Generation Co., Ltd., Chongqing 400799, China;

2. Huaneng Power International Inc. Chongqing Branch, Chongqing 401120, China;

3. Beijing Leven Electric Technology Co., Ltd., Beijing 100095, China)

**Abstract:** Power load forecasting is a key means for transmission network expansion, planning and reasonable power dispatch. Aimed at the nonlinear and complex characteristics of power load time series, a power load prediction model for combining improved sparrow search algorithm and wavelet neural network (ISSA-WNN) is proposed to optimize wavelet neural network. The improved sparrow search algorithm is designed to optimize the initial value of the key parameters of the wavelet neural network, which can effectively solve the problem that it is easy for the gradient parameter adjustment to fall into the shortage of local optimum. The Logistic-Tent hybrid chaotic population initialization, discoverer or watcher adaptive update, follower variable logarithm spiral update and Gauss-Cauchy hybrid mutation strategy are introduced to improve the optimization ability of the standard sparrow search algorithm. The wavelet transform is used to decompose and reconstruct the power load sample to reduce the disorder and volatility of the load time sequence. On this basis, a new power load prediction model ISSA-WNN is constructed. The experimental results show that compared with the standard WNN model and optimizing SSA-WNN model, the average absolute percentage error and root mean square error index values of the prediction model ISSA-WNN are averagely reduced by 18.42% and 21.21%, respectively, with a stronger fitting ability and more stable prediction performance.

**Keywords:** power load prediction; WNN; wavelet transform; SSA; Gaussian-Cauchy mutation

## 0 引言

电力负荷的精准预测可以保障电力系统的可靠运行及电网安全, 并为电力规划提供有效指导。但电力负荷具有

明显突发性、异构性和多分形性等非线性特征, 精准电力负荷预测是研究人员面临的一大难题<sup>[1]</sup>。目前预测方法主要有: 1) 数学统计方法, 如自回归滑动平均模型 AR-MA<sup>[2]</sup>、差分自回归滑动平均模型 ARIMA<sup>[3]</sup>、线性回归<sup>[4]</sup>

收稿日期: 2023-05-11; 修回日期: 2023-06-27。

基金项目: 四川省教育厅科技项目(20213967)。

作者简介: 向东(1971-), 男, 硕士, 高级工程师。

引用格式: 向东, 赵文博, 王玖斌, 等. 结合小波变换与改进 SSA 优化小波神经网络的电力负荷预测[J]. 计算机测量与控制, 2024, 32(5): 46-52, 59.

和滤波模型<sup>[5]</sup>等。对于这类线性模型,模型过多依赖于参数假设检验,在精确刻画电力负荷非线性动态演变问题上有一定困难。且随着电网复杂性的增加,电力负荷特征已超出传统泊松分布或 Markov 分布,模型本身无法准确描述电力负荷混沌特征,预测模型理论不足,预测误差偏大。

2) 机器学习/深度学习法<sup>[6-7]</sup>。该方法以数据驱动,并结合学习算法构建非线性系统的预测能力。如文献 [8] 结合自适应学习速率和动量因子改进 BP 神经网络模型,进行电力负荷预测。文献 [9] 结合聚类和支持向量机构建电力负荷预测模型。文献 [10] 结合自适应差分进行算法优化小波神经网络建立电力负荷预测模型。文献 [11] 利用改进灰狼算法优化长短期记忆人工神经网络实现电力负荷预测。机器学习模型与传统统计模型相比,虽然预测精度具有明显提升,但也有不足。神经网络<sup>[12]</sup>的结构难以确定,极易导致模型早熟,降低预测精度。支持向量机虽然需要样本数少,但模型优化也与关键参数配置密切相关。灰度理论适用性较为有限,在样本变化不剧烈时预测精度尚可,但对随机性较高的数据适用性较差。小波神经网络是基于小波分析和小波变换的新型分层人工神经网络,利用非线性小波基函数替换常规 Sigmoid 函数,能够有效避免网络结构的盲目性和出现局部极点的缺陷,其学习能力也强于支持向量机模型,且训练过程得到了极大简化。

引入智能优化算法对学习算法超参调优,可以提高预测模型性能,如布谷鸟算法<sup>[13]</sup>、粒子群算法<sup>[14]</sup>、蝙蝠算法<sup>[15]</sup>等。然而,智能算法本身寻优机制也存在不足,如早熟收敛、易得到局部极值点等,这使得结合智能算法的电力负荷预测在性能上还有提升空间。同时,由于实际应用的复杂性,根据无免费午餐定理,在有限空间内,并不存在一种智能算法可普适于解决所有优化问题。解决实际问题还需提出性能更优的算法并克服已有算法固有不足的基础上进行实证分析。

麻雀搜索算法 SSA 是 2020 年由东华大学的 Xue 和 Shen 两位学者设计的一种新型智能优化算法<sup>[16]</sup>,其模型简单、可调参数少、寻优性能极佳,已被广泛应用在机器学习模型优化<sup>[17]</sup>、图像分割<sup>[18]</sup>、频谱分配<sup>[19]</sup>等。然而,SSA 算法与同类智能优化算法一样,在求解复杂多维优化问题时依然容易出现全局收敛精度差、易得局部最优及搜索性能不稳定的不足。本文将提出一种结合改进麻雀搜索算法优化小波神经网络与小波变换的电力负荷预测模型。利用改进麻雀搜索算法对小波神经网络关键参数初值调优,解决预测模型对初始参数的敏感性问题。并融合多种改进策略提高 SSA 算法的寻优精度。通过实验研究,证明改进模型能有效提高电力负荷预测精度。

## 1 麻雀搜索算法 SSA

SSA 算法中的种群角色可分为发现者、跟随者和警戒者。发现者是种群领导者,负责为整个种群提供觅食和搜索方向,具有较强全局搜索能力。发现者位置更新方式为:

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

式中,  $x_{i,j}(t)$  为迭代  $t$  次时麻雀  $i$  的  $j$  维位置信息,  $j=1, 2, \dots, d$ ,  $T_{\max}$  为最大迭代次数,  $\alpha \in (0, 1]$  为随机量,  $R_2$ 、 $ST$  为预警值和安全值,  $R_2 \in [0, 1]$ ,  $ST \in [0.5, 1]$ ,  $Q$  为服从正态分布的随机量,  $L$  为  $1 \times d$  的矩阵,元素均为 1。若  $R_2 < ST$ , 表明种群环境安全,发现者可以广泛搜索;  $R_2 \geq ST$ , 表明种群内有捕食者,发现者需要飞到其它安全区域。

跟随者追随发现者作局部搜索,跟随者位置更新方式为:

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

式中,  $x_{p,j}(t)$  为发现者最优位置,  $x_{\text{worst},j}(t)$  为全局最差位置,  $A$  为  $1 \times d$  矩阵且元素随机赋值 1 或 -1,  $A^+ = A^T(AA^T)^{-1}$ 。  $i > n/2$ , 表示适应度较差的跟随者  $i$  未得到食物,需到其他区域觅食。

麻雀在捕食的同时也有可能遭遇天敌的,此时一部分麻雀会作为警戒者及时发现危险并向其他个体发出警报,以使得种群作出反捕食行为。警戒者位置更新方式为:

$$x_{i,j}(t+1) = \begin{cases} x_{i,j}(t) + \beta |x_{i,j}(t) - x_{\text{best},j}(t)|, f_i > f_g \\ x_{i,j}(t) + K \cdot \frac{|x_{i,j}(t) - x_{\text{worst},j}(t)|}{(f_i - f_{\text{worst}}) + \xi}, f_i = f_g \end{cases} \quad (3)$$

式中,  $x_{\text{best},j}(t)$  为当前全局最优位置,  $\beta$  为步长控制系数,为服从均值为 0 且方差为 1 的正态分布随机数,  $K$  为随机量,  $K \in [-1, 1]$ , 控制个体飞行方向和步长,  $f_i$  为个体  $i$  适应度,  $f_g$ 、 $f_{\text{worst}}$  分别为当前全局最优适应度和最差适应度,  $\xi$  为极小常量。若  $f_i > f_g$ , 表明个体处于边界位置,未警戒保护;若  $f_i = f_g$ , 表明处于中间位置的个体意识到危险,需要相互靠拢降低被捕食风险。 $x_{\text{best},j}(t)$  为种群安全区域。

## 2 混合多种策略改进的麻雀搜索算法 ISSA

### 2.1 Logistic-Tent 混合混沌种群初始化

混沌系统同时具有随机性、遍历性和规律性特征,混沌已广泛应用在优化问题中。对于 SSA 算法而言,种群初始化是以随机方式进行,生成的个体分布难免出现重复覆盖、空间未遍历的不足,这不利于算法有效寻优。利用混沌映射可以确保生成多样性更好的初始种群,从而改进算法的全局搜索能力,提升搜索精度。目前,较为常用的混沌模型包括 Logistic 混沌和 Tent 混沌模型。图 1 是 Logistic 混沌映射图,可见,Logistic 混沌映射的迭代序列分布均匀性较差。 $u=4$  时,序列分布接近  $0 \sim 1$  区域,且映射混沌序

列值主要分布在两个端点区域,中间区域分布极少。若最优解落入中间区域,算法容易在偏离最优解的区域内循环迭代,得到局部最优。Tent 混沌映射较 Logistic 混沌具有更好的混沌扰动特性,其分布密度更加均匀。为了生成均匀性和遍历性更好的初始种群,改进算法设计 Logistic-Tent 混合混沌映射序列初始化策略,结合 Logistic 序列具有一定强度全局遍历性但后期深度搜索能力较弱,Tent 序列混沌扰动性更强的特点,生成初始麻雀种群分布。具体混沌映射公式为:

$$x_{n+1} = \begin{cases} [ux_n(1-x_n) + \frac{4-u}{2}x_n] \bmod(1), x_n < 0.5 \\ [ux_n(1-x_n) + \frac{(4-u)(1-x_n)}{2}x_n] \bmod(1), x_n \geq 0.5 \end{cases} \quad (4)$$

式中,  $x_n$  为第  $n$  次迭代的混沌值,  $u \in [0, 4]$ , mod 为取模运算符。图 2 是 Logistic-Tent 混合混沌映射序列分布,显然,生成初始个体分布具备更好的均匀性。

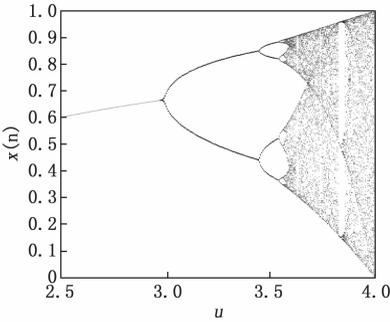


图 1 Logistic 混沌映射

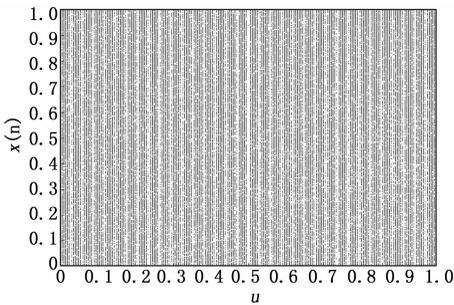


图 2 Logistic-Tent 混合混沌映射

### 2.2 发现者/警戒者自适应更新

SSA 算法中,发现者起到引领整个种群搜索的作用,很大程度决定种群能否找到最优解。由于算法迭代早期,发现者将向着种群内最优个体的方向移动,这样在迭代后期容易收敛到局部最优解。为此,改进算法在发现者位置更新中融入自适应权重机制,定义自适应权重系数为:

$$\omega(t) = \frac{1}{(t+1)^{(\alpha-\beta)^t}} \left( 1 - \frac{\alpha t^\alpha}{T_{\max}^\alpha} - \frac{\beta t^\beta}{T_{\max}^\beta} \right) \quad (5)$$

式中,系数  $\alpha=0.7, \beta=0.3$ 。 $\omega(t)$  曲线趋势如图 3 所示。可见,  $\omega(t)$  将在  $[0, 1]$  范围内随着迭代呈非线性递减。

迭代早期,  $\omega(t)$  的衰减速度将由快转慢,有利于算法全局搜索,以更快的速度向较优个体或最优个体逼近;迭代后期,  $\omega(t)$  的衰减速度缓慢降低,有利于局部精细开发,提升整体寻优能力。则改进算法的发现者位置更新公式为:

$$x_{i,j}(t+1) = \begin{cases} x_{i,j}(t) \cdot \exp\left(\frac{-i}{\alpha T_{\max} \omega(t)}\right) \cdot s, R_2 < S \\ x_{i,j}(t) + Q \cdot L, R_2 \geq S \end{cases} \quad (6)$$

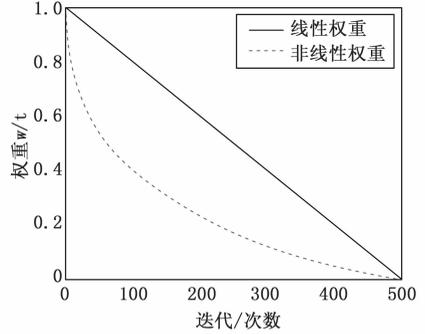


图 3 权重值变化曲线

警戒者是 SSA 算法不可缺少的角色,代表种群社会习性的预警能力。SSA 算法将警戒者数量固定设置为种群规模的 10%~20%。然而,由于发现者、跟随者群体的位置及其适应度都在不断变化,固定的警戒者并不能充分发挥其在种群中的预警作用。算法迭代早期,种群进行全局搜索的要求更高,应配置更多警戒者竞争最优位置,迫使作为精英个体的发现者、跟随者提升自身搜索能力;而迭代中后期,配置更少警戒者既能保留一定局部极点的跳离机制,又可减少对最优解的频繁干扰。基于此考虑,将警戒者数量在种群中的比例 SD 设置为迭代次数的函数,将其定义为:

$$SD(t) = 20 \times \frac{e^{\frac{t}{T}-1}}{e^{\frac{t}{T}-1} + 1} \quad (7)$$

### 2.3 跟随者螺旋更新

SSA 算法中,跟随者随发现者位置更新自身位置,其搜索模式具有一定盲目性,没有利用自身的主动搜索性能。为了使跟随者在迭代前后期更快速更高效地搜索和提高对未知区域的探索能力,引入针对跟随者的可变对数螺旋更新机制,具体定义为:

$$x_{i,j}(t+1) = \begin{cases} Q \cdot \exp\left(\frac{x_{\text{worst},j}(t) - x_{i,j}(t)}{i^2}\right) \cdot s, i > \frac{n}{2} \\ x_{p,j}(t+1) + |x_{i,j}(t) - x_{p,j}(t+1)| \cdot A^+ \cdot L, i \leq \frac{n}{2} \end{cases} \quad (8)$$

其中:  $s$  表示螺旋曲线干涉系数,如图 4 所示,定义为:

$$s = e^{b(t)r} \cdot \cos(2\pi r) \quad (9)$$

$$b(t) = k - \frac{t}{T_{\max}} \quad (10)$$

其中:  $r \in [-1, 1]$  为随机量,  $b(t)$  为螺旋因子,

常量  $k$  取 4。

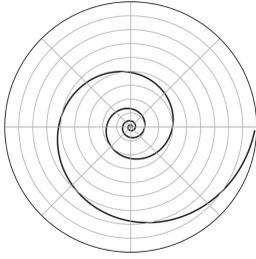


图4 对数螺旋曲线搜索

SSA 算法寻优过程中, 迭代早期跟随者应扩大搜索范围在发现者牵引下搜索更多适应度更高的解, 迭代晚期应收缩搜索范围减少搜索时间, 加快算法收敛在最优解。对数螺旋曲线很好地实现了早期扩张和后期收缩的跟随者搜索模式。同时, 螺旋因子  $b(t)$  设置为随迭代变化的可变系数, 可以确保: 迭代早期,  $b(t)$  值更大, 跟随者搜索范围更大, 解的质量更具多样性; 迭代晚期,  $b(t)$  值减小, 跟随者快速收缩搜索范围, 增强局部精细开发能力, 提升收敛精度。

## 2.4 高斯-柯西混合变异

对于 SSA 算法, 随着种群迭代, 种群个体会逐步逼近最优解, 这会导致种群个体逐渐失去多样性, 算法早熟收敛而生成不具普遍性的最优解。高斯变异一种局部搜索能力较强的算子, 可以在算法迭代中后期加快种群收敛速度。而柯西变异则是一种全局搜索能力更强的算子, 可在整个迭代时期内有效降低种群多样性的缺失。为了提升 SSA 算法的搜索精度和收敛速度, 设计一种高斯-柯西混合变异策略, 在算法迭代早期, 为了扩大搜索范围, 利用柯西变异算子强大的全局搜索能力保持种群多样性; 算法迭代后期, 则利用高斯变异算子更强大的局部开发能力加快算法收敛。个体变异方式定义为:

$$X_{i,j}(t+1) = X_{i,j}(t)[1 + \beta\gamma G(0, \sigma^2) + (1 - \gamma)C(0, \sigma^2)] \quad (11)$$

$$\sigma = \begin{cases} 1, f(X_{best}) < f(X_i) \\ \exp\left(\frac{f(X_{best}) - f(X_i)}{|f(X_{best})|}\right), f(X_{best}) \geq f(X_i) \end{cases} \quad (12)$$

其中:  $X_{i,j}(t)$ 、 $X_{i,j}(t+1)$  分别指迭代  $t$  时的原始个体和迭代  $t+1$  时的混合变异个体,  $G(0, \sigma^2)$  为服从高斯分布的高斯算子,  $C(0, \sigma^2)$  为服从柯西分布的柯西算子,  $\eta$  表示用于控制变异算子权重的因子, 定义为:

$$\eta = \frac{t}{T_{max}} \quad (13)$$

可见, 变异因子  $\eta$  呈线性递增趋势。迭代前期, 柯西变异权重更大, 可以进行更广泛的全局搜索; 迭代后期, 高斯变异权重变大, 柯西变异权重变小, 算法开始偏向于局部开发, 加快算法收敛。同时, 在生成变异个体后, 需要比较变异前后个体适应度, 并择优保留适应度更优的个

体至下一代种群中, 提升种群优质个体比例。

以下是 ISSA 算法的详细执行步骤。

步骤 1: 设置种群规模  $N$ , 最大迭代次数  $T_{max}$ , 麻雀发现者比例 PD 和警戒者比例 SD, 搜索维度  $D$ ;

步骤 2: 设置迭代  $t=0$ , 并利用 Logistic-Tent 混合混沌映射序列生成初始化种群;

步骤 3: 计算麻雀个体适应度, 确定最优解  $x_{best}$  及其适应度  $f(x_{best})$ 、最差解  $x_{worst}$  及其适应度  $f(x_{worst})$ , 并计算种群平均适应度  $f_{avg}$ ;

步骤 4: 在个体适应度大于等于种群平均适应度的种群内, 以比例 PD 选择发现者个体;

步骤 5: 计算自适应权重  $\omega(t)$ , 并根据式 (6) 更新发现者个体位置;

步骤 6: 确定跟随者个体, 计算螺旋曲线干涉系数  $s$ , 并根据式 (8) 更新跟随者个体位置;

步骤 7: 计算比例 SD, 以 SD 确定警戒者个体, 并根据式 (3) 更新警戒者个体位置;

步骤 8: 根据式 (11) 对种群个体进行高斯-柯西混合变异, 生成  $N$  个新个体, 并择优保留生成新的种群信息;

步骤 9: 判断算法是否已迭代  $T_{max}$  次, 若是, 输出全局最优解且算法终止; 否则, 返回步骤 3 循环执行, 并更新迭代  $t=t+1$ 。

## 3 结合小波变换与 ISSA-WNN 的电力负荷预测模型

### 3.1 电力负荷时间序列小波变换与重构

小波变换是在多尺度逼近理论基础上设计的多分辨率分析方法, 可将原始信号分解为子特征时域分量和。利用小波变换对电力负荷时序进行分解, 可以降低电力负荷时序的波动性和无序性, 减少预测模型的不确定性。对于电力负荷  $f(x)$  的小波分解, 其实质是将原始信号  $f(x)$  从高分辨率分解到低分辨率的过程, 即从  $j+1$  多尺度至  $j$  尺度逐步分解, 最终目标是将含有综合信息的原始样本序列分解为  $J+1$  组具有不同特征的序列, 表示为  $D_{j-1}$ ,  $D_{j-2}$ , ...,  $D_0$ ,  $A_0$ 。具体分解方式可表示为:

$$\begin{cases} A_j = \frac{\sqrt{2}}{2} \sum_k A_{j+1,k} h_{k-2n} \\ D_j = \frac{\sqrt{2}}{2} \sum_k A_{j+1,k} g_{k-2n} \end{cases} \quad (14)$$

其中:  $j$ 、 $k$  分别对应小波尺度参数和平移参数,  $A_j$ 、 $D_j$  分别为近似信号和细节信号, 前者反映样本趋势, 后者反映原始序列时频的随机波动,  $h_{k-2n}$ 、 $g_{k-2n}$  分别对应低通、高通正交小波传递系数。

小波重构是小波分解的逆过程。电力负荷预测, 需要将不同频率序列分量的预测值重构为最终预测值, 定义为:

$$A_{j+1} = \frac{\sqrt{2}}{2} \left( \sum_k A_{j,k} h_{n-2k} + \sum_k D_{j,k} g_{n-2k} \right) \quad (15)$$

由此可见, 重构序列由两部分构成: 一是由  $j$  尺度层反映趋势的低频分量  $\{A_j\}$  恢复至  $j+1$  尺度层, 二是由  $j$  尺

度层反映细节的高分量  $\{D_j\}$  恢复至  $j+1$  尺度层。针对电力负荷时序的小波分解与重构过程可表示为图 5。

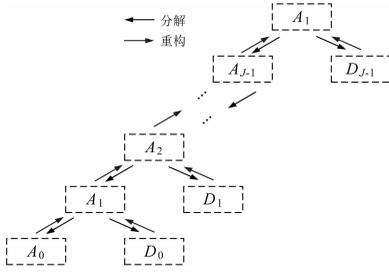


图 5 电力负荷样本小波分解与重构

### 3.2 电力负荷预测模型 ISSA-WNN

小波神经网络 WNN<sup>[20]</sup> 结合了小波分析多尺度分析能力和神经网络非线性自学习能力，尤其对于非线性特征明显的电力负荷预测具有更好的拟合能力。WNN 模型为：

$$y_k = \sum_{j=1}^J \omega_{jk} \varphi\left(\frac{\sum_{i=1}^I \omega_{ij} x_i - b_j}{a_j}\right), k = 1, 2, \dots, K \quad (16)$$

其中： $I$ 、 $J$ 、 $K$  分别为网络输入层、隐含层和输出层的节点数， $\omega_{ij}$ 、 $\omega_{jk}$  分别对应隐含层和输出层的权值， $k$  为输出层个数。具体 WNN 网络结构如图 6 所示。

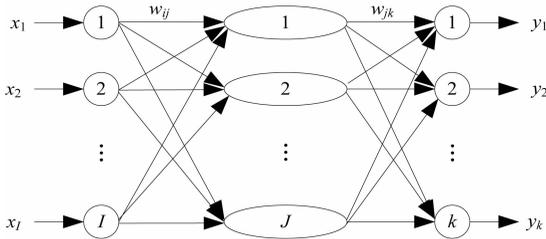


图 6 小波神经网络模型

令  $X = (x_1, x_2, \dots, x_I)$  为网络输入， $Y = (y_1, y_2, \dots, y_K)$  为网络输出，则隐含层节点  $j$  输出为：

$$h(j) = h_j\left(\frac{\sum_{i=1}^I \omega_{ij} x_i - b_j}{a_j}\right), j = 1, 2, \dots, J \quad (17)$$

其中： $h_j$  为小波基函数， $a_j$ 、 $b_j$  为小波基函数伸缩因子和平移因子。采用 Morlet 母小波基函数，公式为：

$$y = \cos(1.75x) e^{-0.5x^2} \quad (18)$$

WNN 输出层为：

$$y(k) = \sum_{j=1}^J \omega_{jk} h_j, k = 1, 2, \dots, j \quad (19)$$

WNN 模型中隐含层权值  $\omega_{ij}$ 、输出层权值  $\omega_{jk}$  以及小波基函数伸缩因子  $a_j$  和平移因子  $b_j$  一般利用误差反向传播，以梯度下降法更新，但其梯度变化方向限制了参数进化方向。本文将利用 ISSA 算法对 WNN 的参数进行寻优，提高电力负荷预测精度。

利用改进 ISSA 算法迭代寻优小波神经网络的两个最优初始权值及伸缩因子和平移因子，输出代表最优 WNN 个体元素的麻雀个体，并赋值于 WNN，构建预测模型 ISSA-WNN，实现电力负荷预测。具体步骤如下。

1) 截获某时段内电力负荷数据样本，针对样本时序进行小波变换，进行样本时序多层时-域分解；

2) 构建电力负荷预测模型 ISSA-WNN，利用小波变换对电力负荷序列分解，生成高频分量  $D_{j-1}$ 、 $D_{j-2}$ 、...、 $D_0$  和低频分量  $A_0$ ，并划分训练样本和测试样本。输入训练样本至 ISSA-WNN 作模型训练，得到 WNN 优化权值和因子；

3) 输入测试样本验证 ISSA-WNN 预测性能，将预测分量结果进行小波重构并生成最终电力负荷预测值，并与实测值作比较分析，评估预测精度和误差情况。

注：模型训练过程中，需要依次将低频分量  $A_0$  和各高频分量  $D_{j-1}$ 、 $D_{j-2}$ 、...、 $D_0$  输入模型，经模型计算后得到各自相应的输出数据，最后将分量预测子结果经小波重构生成电力负荷数据的最终预测值，并进行误差评估。

如图 7 是基于 ISSA-WNN 的完整电力负荷预测模型，图示左侧结构为混合改进麻雀搜索算法的执行过程，图示右侧结构则为优化的小波神经网络对电力负荷的预测过程。

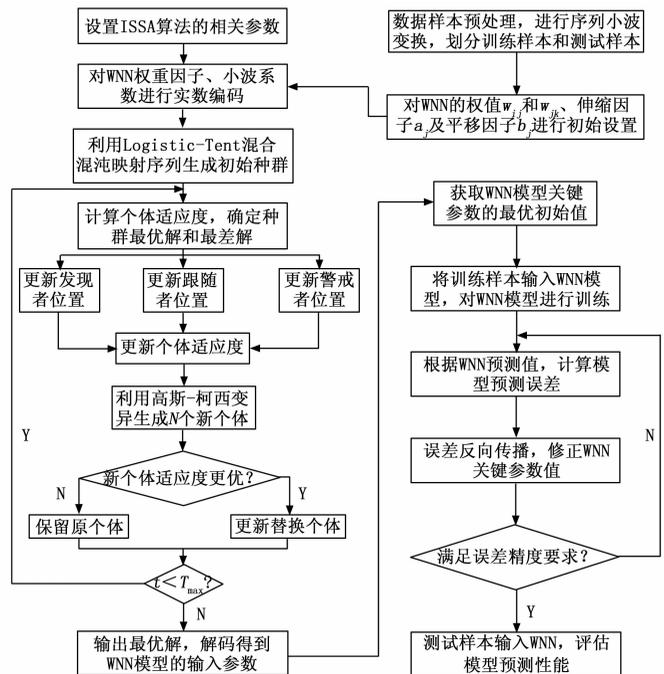


图 7 ISSA-WNN 电力负荷预测模型

## 4 实验分析

### 4.1 环境配置

在 MATLAB 2017b 软件平台上开展实验分析，硬件配置为 Intel (R) Core i7 3.2 GHz CPU 和 8 GB RAM，操作系统为 Window 10 Pro。利用某地区的电力负荷数据开展实证研究。采样频率设置为 10 分钟，总共采集样本点 380 个，将前 350 个样本点作为模型的训练样本，后 30 个样本点进行拟合测试。ISSA-WNN 算法的相关参数中，设置种群规模  $N=30$ ，最大迭代次数  $T_{max}=500$ ，WNN 的权重因子学习率设为 0.05，两个小波系数的学习率设为 0.01，模型总共训练 100 次，最小目前误差精度  $E_r$  设为 0.000 1。鉴于电力负荷本身自相似和长相关性特征，同时电力负荷数据都

是以具体时间序列记录, 为了提高模型训练效率, 将时序一维变量重新构造为多维变量, 具体方法是: 用前 4 个时序数据作为输入, 第 5 时序数据作为输出。因此, 在小波神经网络拓扑结构上, 利用过去 4 个时序节点  $(t-3, t-2, t-1, t)$  的电力负荷样本作为输入层数据, 即输入层节点数  $I=4$ 。隐含层节点数利用经验公式  $J = (I+k)^{1/2} + \kappa$  计算,  $\kappa$  为调节因子。经过误差分析, 隐含层节点数为 6 时误差最小。输出层单元数  $K=1$ , 以单步方式输出下一时序  $t+1$  的电力负荷预测值。

### 4.2 实验分析

电力负荷时间序列可视为一种多频率序列组合, 对原始电力负荷序列进行小波分解可以提取各频率序列隐藏特征, 对各频率序列建模预测, 再将不同频率序列预测值进行小波重构, 得到最终电力负荷预测结果。而小波分解层次对电力负荷预测精度和速度具有重要影响, 若分解层数过大, 会导致预测序列过多, 降低模型学习和预测效率; 若分解层数过少, 会导致各频率序列包含过多干扰信号, 忽略了部分时序隐藏特征而降低预测精度。为此, 需先为预测模型确定最优小波分解层数。

为了更好地对模型预测性能进行比较, 先引入平均绝对百分比误差  $M_{MAPE}$  和均方根误差  $M_{RMSE}$  指标。指标定义为:

$$M_{MAPE} = \frac{1}{M} \sum_{i=1}^M \frac{|x'(i) - x(i)|}{x(i)} \quad (20)$$

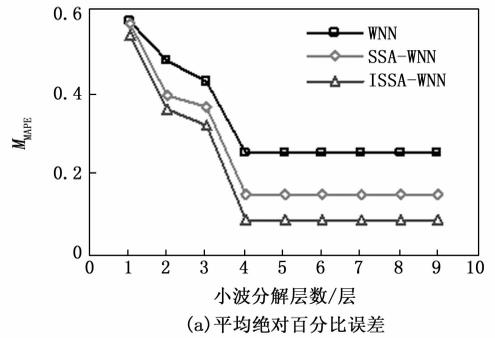
$$M_{RMSE} = \sqrt{\frac{1}{M} \sum_{i=1}^M (x'(i) - x(i))^2} \quad (21)$$

其中:  $M$  是测试样本总数,  $x(i)$ 、 $x'(i)$  分别为第  $i$  个时序电力负荷的实测值和预测值。 $M_{MAPE}$  反映模型预测值与实际值间的误差实际情况,  $M_{RMSE}$  反映预测值误差的集中和分散程度。

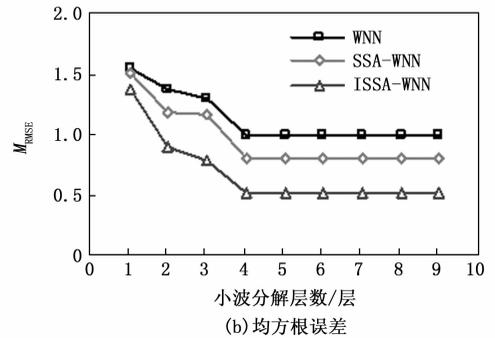
如图 8 是在不同分解层数下不同模型预测精度的变化情况, 3 种预测模型分别是标准小波神经网络模型 WNN、标准 SSA 算法优化的 WNN 模型 ISSA-WNN 与本文提出的 ISSA-WNN 模型。结合两个指标的变化情况看, 分解层数过小时, 误差较大, 但随着分解层数增加, 误差逐步下降, 当分解层数为 4 时, 两个指标基本趋于稳定状态。

结合图 8 的测试结果, 实验将原始电力负荷时间序列利用 db4 算法进行小波分解, 将样本点划分为高频分量  $D_0/D_1/D_2$  和低频分量  $A_0$  等 4 个时频分量, 实现原始电力负荷时间序列的小波分解。原始电力负荷样本及其小波分解得到的 4 个分量结果如图 9 所示。

将电力负荷样本数据进行小波变换, 将训练样本输入 ISSA-WNN 模型训练, 分别进行提前 10 min、20 min 和 40 min 的电力负荷预测, 数据的拟合性能如图 10 所示, 相关残差指标如表 1 所示。根据图 10 可知, ISSA-WNN 模型对于电力负荷的预测值与实测值的总体趋势是基本一致的。当电力负荷值出现较大起伏时, 模型预测精度相对较低, 起伏较小时, 预测精度极高。3 种情况中, 10 min 间隔预测精度最佳, 数据拟合度最好。相对而言, 40 min 提前预测



(a) 平均绝对百分比误差



(b) 均方根误差

图 8 确定小波分解的最优层数

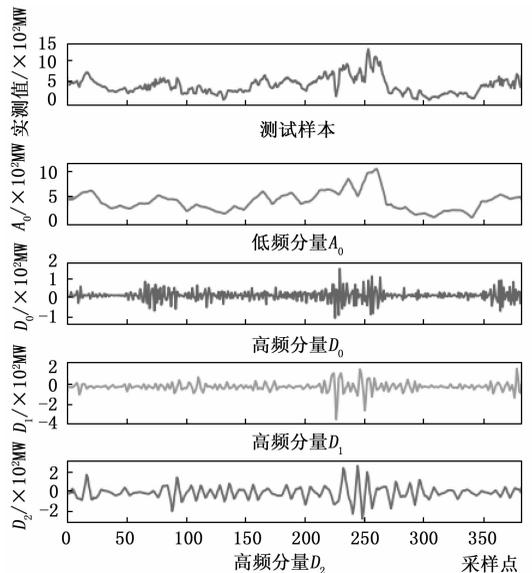


图 9 测试样本及其小波分解结果

时间间隔的数据拟合程度不如 10 min 和 20 min, 这说明随着时间间隔的增加, 样本时序性和自相关性呈弱化趋势, 这也符合实际情况。以 40 min 提前预测时间间隔为标准, 10 min 和 20 min 的预测结果在平均绝对百分比误差指标上分别可以降低 32.45% 和 11.96%, 在均方根误差指标上分别可以降低 27.39% 和 8.39%。

表 1 预测指标表明

预测时长间隔/min	$M_{MAPE}$	$M_{RMSE}$
10	0.086 7	0.51
20	0.109 2	0.69
40	0.128 9	0.82

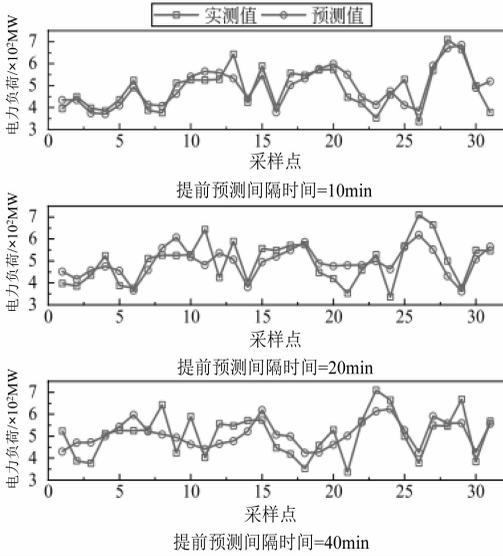


图 10 不同预测时长下数据拟合情况

如图 11 是 3 种预测时间间隔下的拟合残差情况。可见，3 种情况下的平均拟合误差总体偏小。拟合误差的箱体面积大小呈现递增趋势，表明预测值与实测值间的偏离度也将随着预测时间间隔的增加而增加，同时也会出现个别异常点。

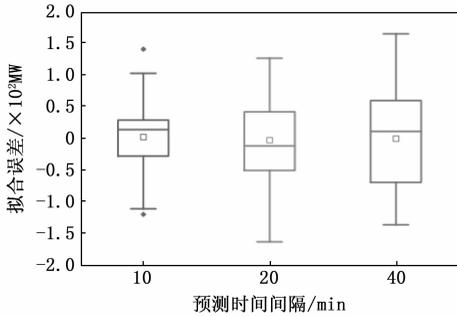


图 11 不同预测时长下数据拟合误差分布箱形图

在标准支持向量机模型 SVM、BP 神经网络模型 BPNN、小波神经网络 WNN、标准 SSA 算法优化 WNN 模型 SSA-WNN 与 ISSA-WNN 模型之间进行纵横向预测性能的对比，5 种算法均利用小波神经网络对原始电力负荷样本序列进行高低频分量分解与重构，将预测时间间隔设为 10 min，数据拟合情况如图 12，性能指标如表 2。根据 5 种模型的预测结果，本文提出的 ISSA-WNN 的平均绝对百分比误差和均方根误差值均是所有模型中最小的。同时，利用智能优化算法对 WNN 进行参数调优，明显可以提高模型的预测精度。在标准小波神经网络模型基础上，ISSA-WNN 和 ISSA-WNN 的平均绝对百分比误差分别可以降低 9.18% 和 27.65%，均方根误差分别可以降低 12.64% 和 29.78%，这表明智能算法的参数调优解决了 WNN 单独进行电力负荷预测时的参数依赖性问题，提高了模型的预测精确性。此外，在 SSA 算法基础上，ISSA 算法融入的多重改进机制，从种群初始化结构、个体的全局寻优能力以及

有效摆脱局部最优解问题上提高了算法的寻优能力，相较 ISSA-WNN 能够显著增强 WNN 权值、伸缩因子及平移因子的个体优越性，进而提高模型的拟合精度。

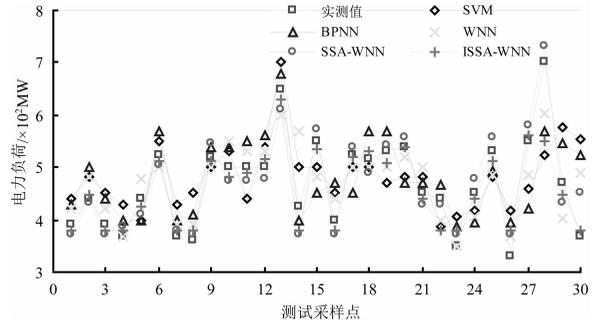


图 12 不同模型预测对比

表 2 预测指标表现

预测模型	$M_{MAPE}$	$M_{RMSE}$
SVM	0.153 6	0.83
BPNN	0.140 2	0.79
WNN	0.120 2	0.75
ISSA-WNN	0.106 5	0.66
ISSA-WNN	0.086 7	0.51

### 5 结束语

本文提出了一种结合改进 SSA 算法优化小波神经网络与小波变换的电力负荷预测方法。首先混合多种策略对 SSA 算法进行综合改进，然后利用改进 SSA 搜索 WNN 的参数初值，配置最优参数提升模型学习能力，在此基础上构建一种新型电力负荷预测模型。以实际采集的电力负荷数据样本验证了预测模型的性能，结果表明改进模型在预测电力负荷上的平均绝对百分比误差和均方根误差指标值均更小，数据拟合能力更强，达到了预期效果。

### 参考文献:

- [1] ZHAO C, WAN C, SONG Y, et al. Optimal Nonparametric Prediction Intervals of Electricity Load [J]. IEEE Transactions on Power Systems, 2020, 23 (9): 1-10.
- [2] LIU N, HU Y, AI X. Research on Power Load Forecasting Based on Random Forest Regression [J]. IOP Conference Series: Earth and Environmental Science, 2019, 252 (3): 1-8.
- [3] SUGANYADEVI M V, BABULAL C K. Support Vector Regression Model for the prediction of Loadability Margin of a Power System [J]. Applied Soft Computing Journal, 2014, 24 (5): 304-315.
- [4] 杨 召, 徐姣新. 基于分位数回归平均的电力负荷统计建模与预测 [J]. 计算机应用与软件, 2021, 38 (11): 98-103.
- [5] 崔和瑞, 穆玉佩, 彭 旭. 基于 HP 滤波的 SARIMA 中期电力负荷预测 [J]. 华北电力大学学报 (自然科学版), 2016, 43 (4): 79-86.

(下转第 59 页)