

DOI: 10.7667/PSPC180251

基于改进乌鸦算法和 ESN 神经网络的短期风电功率预测

琚 焱¹, 祁 林², 刘 帅³

(1. 新乡职业技术学院, 河南 新乡 453000; 2. 河南城建学院, 河南 平顶山 467036;
3. 新能源电力系统国家重点实验室(华北电力大学), 河北 保定 071003)

摘要: 精确的短期风电功率预测对于提升电力系统经济稳定运行十分重要。为了克服传统的神经网络在参数选取中容易受主观因素影响和陷入局部最优的不足, 提出一种基于改进乌鸦算法(ICSA)优化回声状态神经网络(ESN)参数的短期风电功率组合预测方法。在算法寻优初期引入 Lévy 飞行机制增强搜索效率, 而在迭代后期加入高斯函数, 对进化后的全部轨迹进行相应的调整, 保证算法的全局寻优和逐次逼近能力; 通过改进的 CSA 算法对 ESN 神经网络输出层连接权值矩阵进行优化以提高网络的训练效率。最后利用两组实验数据对预测模型进行了有效性验证, 结果表明, 所提算法能有效应对风电功率时序的随机性和不确定性特征, 具有更高的建模精度和更快的收敛速度。

关键词: 乌鸦算法; Lévy 飞行; ESN 神经网络; 高斯函数; 风电功率预测

Short-term wind power forecasting based on improved crow search algorithm and ESN neural network

JU Yao¹, QI Lin², LIU Shuai³

(1. Henan Xinxiang Vocational and Technical College, Xinxiang 453000, China; 2. Henan University of Urban Construction, Pingdingshan 467036, China; 3. State Key Laboratory of Alternate Electrical Power System with Renewable Energy Sources, North China Electric Power University, Baoding 071003, China)

Abstract: Accurate short-term wind power forecasting is important for improving the economic and stable operation of power system. Since it is easy to be affected by subjective factor and fall into local optimum in parameters selecting compared with traditional Neural Network, a novel combination forecasting approach based on Improved Crow Search Algorithm (ICSA) to optimize the parameters of Echo State Network (ESN) neural network is proposed to overcome above inadequacies. The Lévy flight is introduced to increase the searching efficiency at initial stages, and during the later stage of iteration, the Gauss function is added aiming at making an appropriate adjustments for the whole trajectory points after evolution, which can guarantee the ability of global optimization and successive approximation; it chooses optimal the weight values of the hidden layer to enhance the efficiency of neural network training by ICSA algorithm. Finally, effectiveness of the proposed forecasting model is tested on two groups of experimental data, the results show that proposed algorithm can effectively cope with the variability and intermittency of wind power time series, having higher modeling precision and faster convergence speed.

This work is supported by National Natural Science Foundation of China (No. 51677072).

Key words: crow search algorithm (CSA); Lévy flight; ESN neural network; Gauss function; wind power forecasting

0 引言

随着大规模风力发电场的快速增长, 风能作为清洁经济的可再生能源在国内外电力市场中扮演着重要的角色。然而风力这种极不稳定的能源会导致

风电功率时序出现非线性的特点, 给风电系统的稳健带来诸多负面的影响^[1]。因此, 精确可靠的功率预测模型对于保障电网的稳定性和合理规划、调度、控制以及风险评估能力的提高都具有十分重要的意义。基于此国内外众多学者开展了相关研究, 提出了许多新观点、新方法, 主要分为两大类型: 物理统计法和时间序列法。其中物理统计法利用风电场

实际的物理气象信息,所需要参数多、计算量繁琐,精度普遍较低^[2];时间序列法则是利用历史及现时的数据去进行系统辨识和预测,尤其是智能计算已逐渐成为该领域的研究热点。此类方法主要包括 ARIMA 模型法^[3]、GARCH 模型法^[4]、支持向量机法^[5]、混沌理论法^[6]、神经网络法^[7]等。其中,文献[8]利用改进的粒子群算法优化模糊神经网络参数,但模糊神经网络结构层次多,权值参数调整复杂极易陷入局部最优极值。文献[9]利用解析模态分解和改进的布谷鸟算法优化支持向量机参数,该方法利用相空间分解剔除了原始数据的噪声干扰,但如果参数选取不当很可能将有用信息也一并剔除掉。文献[10]将粗糙集理论和主成分分析法相结合对神经网络的输入进行优化,一定程度上提高了预测精度,但是隐含层神经元选取的随机性会导致过拟合或欠拟合问题。文献[11-12]分别采用改进的人工鱼群算法和遗传算法来优化 BP 神经网络的权值和阈值,文献[13]采用粒子群优化算法对最小二乘支持向量机参数进行优化,均能使预测精度有所提高。

乌鸦算法(Crow Search Algorithm, CSA)是一种元启发式群智能算法,它模拟了乌鸦藏食和觅食的社会行为过程^[14]。回声状态网络(Echo State Network, ESN)是一种新型的递归神经网络^[15],其特点是训练过程简单、拥有动态储备池,具备短时记忆功能,在处理非线性系统辨识问题上表现突出。本文在分析原有乌鸦算法局限性的基础上,提出采用 Lévy 飞行搜索策略的不均匀随机游走特性来增强全局搜索能力,在算法迭代后期加入高斯函数,利用函数的惩罚系数进行局部扰动,逐渐减小搜索轨迹的幅度,进而自适应地调整参数,避免被局部极值吸引。最后将改进的乌鸦算法用于优化 ESN 神经网络隐含层神经元和连接权值,从而得到精确的预测结果。

1 乌鸦算法

1.1 标准的乌鸦算法

乌鸦算法(CSA)是由 Askarzadeh 于 2016 年提出的一种新型仿生智能算法,从乌鸦觅食的一系列智能行为受到启发而提出来的。CSA 算法认为乌鸦是一种非常聪明的鸟类,它将自己的食物储藏起来并记住位置,在需要的时候取回;同时,它能够跟踪其他乌鸦,并窃取它们的食物,而被跟踪的乌鸦则会以一定的感知概率,通过随机的空间方位移动来迷惑对方以保护食物^[16]。算法具体描述如下:

设有总数为 N 的乌鸦群体,第 i 只乌鸦在第 k 次迭代的位置为 x_i^k ,食物的藏匿位置(称为记忆值)为

m_i^k 。CSA 算法有两种可能的情形:一种是乌鸦 j 不知道乌鸦 i 在跟踪(即 $r_j \geq p_i^k$),那么乌鸦 i 就可以找到乌鸦 j 的食物藏匿点;另一种情况是乌鸦 j 以一定的概率感知乌鸦 i 在跟踪,从而通过在搜索空间的随机游走来欺骗乌鸦 i ,即乌鸦 i 的位置更新公式为

$$x_i^{k+1} = \begin{cases} x_i^k + r_i \times fl_i^k \times (m_j^k - x_i^k), & r_j \geq p_i^k \\ \text{random position} & \text{otherwise} \end{cases} \quad (1)$$

式中: r_i 、 r_j 为[0,1]之间的随机数; fl_i^k 为乌鸦 i 在第 k 次迭代的飞行步长; p_i^k 为乌鸦 i 在第 k 次迭代的感知概率。

其中飞行步长 fl_i^k 的大小会影响到乌鸦搜索效率,步长设置偏小会加速算法的收敛,但是容易产生“早熟”现象;步长设置偏大有利于跳出局部最优解,但会影响到算法的收敛速度。

1.2 Lévy 飞行策略

Lévy 飞行实际上是一类非高斯随机游走模型,类似于布朗运动的形式。Viswanathan 等在 1996 年首次用来解释动物觅食行为的路径^[17-18],具有短时间内爆发与长时间内静默的特点。虽然没有相关文献指出乌鸦的飞行轨迹是否符合 Lévy 飞行特征,本文认为乌鸦也是以 Lévy 飞行的方式觅食、藏食。

Lévy 飞行方向是任意的,其概率密度分布函数为

$$p_{\alpha,\zeta}(k) = \exp\left[i\eta k - \sigma^\alpha |k|^\alpha \left(1 - i\zeta \frac{k}{|k|} \tan\left(\frac{\pi}{2}\alpha\right)\right)\right] \quad (2)$$

式中: $\alpha \in (0,1) \cup (1,2]$ 是特征指数; ζ 是偏度; η 是位移; σ 是尺度。当 $\alpha = 0.5$ 且 $\zeta = 1$ 时, Lévy 稳定分布概率密度函数服从 Lévy 分布。

Lévy 飞行的方向服从均匀分布,其行走步长服从 Lévy 分布,典型轨迹表现为较小的跳跃组成的集合被较大的跳跃分隔开来且方向多变,随机步长采用式(3)产生。

$$L(\lambda) = \frac{\mu}{|v|^{1/\beta}} \quad (3)$$

式中: $\lambda = 1 + \beta$, $\beta \in (0,2)$; μ 和 v 是服从如下正态分布的随机数。

$$\mu \sim N(0, \delta_\mu^2) \quad (4)$$

$$v \sim N(0, \delta_v^2) \quad (5)$$

$$\delta_\mu = \left\{ \frac{\Gamma(1+\beta)\sin(\pi\beta/2)}{\Gamma[1+\beta/2]\beta 2^{(\beta-1)/2}} \right\}^{1/\beta} \quad (6)$$

式中: Γ 是标准的 Gamma 函数; $\delta_v = 1$ 。

1.3 算法改进

由上述分析可知, CSA 算法只需要关心两个参数: 飞行步长 fl_i^k 和感知概率 p_i^k , 且算法简单易于实现。其中乌鸦的位置是采用随机选取的方法进行初始化, 在迭代过程中步长参数如果选取不当很可能造成乌鸦在局部最优解附近游走而无法跳出的局面。受 Lévy 飞行机制启发, 将 CSA 算法中乌鸦 i 的位置公式更新为

$$x_i^{k+1} = \begin{cases} x_i^k + r_i [fl_i^k \oplus L(\lambda)](m_j^k - x_i^k), & r_j \geq p_i^k \\ \text{random position} & \text{otherwise} \end{cases} \quad (7)$$

式中, \oplus 为点对点乘法运算符。

这样, 将 Lévy 飞行因子加入到位置更新, 使乌鸦 i 在迭代初期产生大的跳跃空间, 有利于拓展搜索范围。在迭代后期, 为了保持算法的持续逼近效果, 引入高斯函数的调整机制对仍然具有寻优能力的乌鸦进行较小的轨迹纠正, 而对于基本停止的乌鸦进行较大的轨迹调整, 重新发布到解空间中继续寻优, 对式(7)进行如下修正:

$$x_i^{k+1} = \begin{cases} x_i^k + r_i [fl_i^k \oplus L(\lambda)](m_j^k - x_i^k)h_i(k), & r_j \geq p_i^k \\ \text{random position} & \text{otherwise} \end{cases} \quad (8)$$

式中, $h_i(k)$ 为引入的高斯函数^[19], 如式(9)所示。

$$h_i(k) = e^{-\frac{[m_j^k - x_i^k]^2}{2\sigma^2(k)}}, \quad m_j^k \neq x_i^k \quad (9)$$

$$\sigma^2(k) = \sigma_0^2 e^{-\frac{k}{\tau}} \quad (10)$$

式中, σ_0 和 τ 为常数。这样, 迭代前期由于 Lévy 飞行机制的跳跃作用, 对接近全局最优值的乌鸦轨迹进行较大幅度的调整; 后期随着 k 的递增, 高斯函数变陡, 调整幅度趋于平稳, 实现了训练后期持续逼近能力。

改进的乌鸦算法流程的伪代码如下:

Start

initialize the crows (x_i^0, m_j^0, p_i^0), flock N

evaluate the fitness:= $f^k(x)$

while (termination condition = false)

do

for ($k=1$ to number of max iteration)

for ($i=1$ to number of dimensions)

define fl_i^k, p_i^k of all crows

random select a crow j

if $r_j > p_i^k$

$x_i^{k+1} = x_i^k + r_i [fl_i^k \oplus L(\lambda)](m_j^k - x_i^k)h_i(k)$

else

```

update  $x_i^{k+1}$  with random
endif
increase  $i$ 
endfor
evaluate the fitness:=  $f^k(x)$ 
increase  $k$ 
endfor
if  $f^k(x) < f^{k-1}(x)$ 
update memory  $m_j^{k+1} = x_i^{k+1}$ 
endif
end do
end

```

2 ESN 神经网络

回声状态网络 ESN 是一种特殊的动态递归神经网络, 由 Jaeger 等于 2001 年提出, 与传统的采用梯度下降学习算法相比, ESN 网络学习过程简单、调节参数少, 非常适用含有随机噪声、非平稳时间序列的建模, 网络结构如图 1 所示。

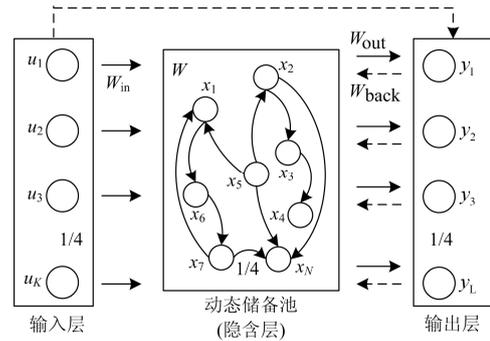


图 1 ESN 神经网络结构图

Fig. 1 Structure of ESN neural network

从图 1 可以看出, ESN 神经网络由输入层、动态储备池(Dynamic Reservoir, DR)、输出层组成。其中动态储备池是网络的核心部分, 它是由大量的、随机和以稀疏方式连接的隐含层神经元组成(一般取值为 50~1 000 之间), 故其具有短时记忆功能。

设 n 时刻, 网络输入向量 $\mathbf{u}(n)$ 、储备池状态向量 $\mathbf{x}(n)$ 、输出向量 $\mathbf{y}(n)$ 分别为

$$\begin{cases} \mathbf{u}(n) = [u_1(n), u_2(n), \dots, u_K(n)]^T \\ \mathbf{x}(n) = [x_1(n), x_2(n), \dots, x_N(n)]^T \\ \mathbf{y}(n) = [y_1(n), y_2(n), \dots, y_L(n)]^T \end{cases} \quad (11)$$

则神经网络的状态更新方程和输出更新方程分别为

$$\mathbf{x}(n+1) = f(\mathbf{W}_{in}\mathbf{u}(n+1) + \mathbf{W}\mathbf{x}(n) + \mathbf{W}_{back}\mathbf{y}(n)) \quad (12)$$

$$\mathbf{y}(n+1) = f^{out}(\mathbf{W}_{out}\mathbf{u}(n+1), \mathbf{x}(n), \mathbf{y}(n)) \quad (13)$$

式中: f 是隐含层内部神经元的激活函数, 一般取

sigmoid 或 tanh 函数; f^{out} 是输出层的激活函数, 一般取为线性函数; W_{in} 是 $N \times K$ 的矩阵, 表示输入层到隐含层的连接权值; W 是 $N \times N$ 的矩阵, 表示隐含层(状态储备池)内部神经元的连接权值; W_{out} 是 $L \times (K + N + L)$ 的矩阵, 表示隐含层到输出层的连接权值; W_{back} 是 $N \times L$ 的矩阵, 表示输出层反馈回隐含层的连接权值。

ESN 神经网络参数中, 只有隐含层到输出层的连接权值需要通过学习算法进行调整, 其他各层的连接权值在训练初期通过随机赋予初值就已经固定下来保持不变。为了使 ESN 网络具有短时记忆功能(即保证网络的回声特性), 必须使动态储备池 DR 保持 1% ~ 5% 的稀疏度, 且其权值矩阵 W 的谱半径 γ 小于 1。

3 基于 ICSA-ESN 的短期功率预测模型

标准的 ESN 神经网络是通过最小二乘法来求解 W_{out} , 使期望输出和实际输出的均方误差最小, 这是一种线性回归方法, 其最优值的求解过程并不具备自我调整能力, 如果谱半径和储备池的稀疏度选择不当极易陷入局部最优。文献[20-21]分别采用和声搜索算法(HS)和粒子群算法(PSO)对 ESN 神经网络的参数选择方式进行了一些改进, 取得了比单一网络更好的建模效果。

本文将改进的乌鸦算法引入到 ESN 神经网络参数 W_{out} 的寻优过程, 提出一种基于 ICSA-ESN 的风机短期功率预测模型, 该模型通过计算乌鸦群体的适应值, 更新乌鸦的位置以及个体与群体的最优位置, 自适应的调整 ESN 神经网络谱半径 γ 、储备池 DR 的数值, 并将全局最优参数值返回给模型进行修正, 最终得到最优权值矩阵 W_{out} , 模型的算法流程如图 2 所示。

Step1: 初始化 ICSA 的种群大小、参数维数、最大迭代次数 $Maxiter$ 、飞行步长、感知概率, 随机生成记忆值, 按式(8)生成初始种群。

Step2: 初始化 ESN 神经网络结构、动态储备池 DR 数量、谱半径、随机生成 W_{in} 、 W 、 W_{back} 矩阵, 确定目标函数。

Step3: 将预处理过的训练样本数据输入神经网络, 根据式(14)计算乌鸦当前的适应度值。

Step4: 根据 ICSA 算法步骤, 更新乌鸦位置, 计算乌鸦的个体最优位置和全局最优位置。

Step5: 更新 DR 数量和谱半径 γ 。

Step6: 比较乌鸦个体新位置处的适应值和其历史最优适应值, 若更优则将当前位置设为个体历史最优位置。

Step7: 比较种群当前适应值和全局历史最优值, 若当前适应值更优, 则将当前位置设为群体的全局历史最优位置。

Step8: 判断是否满足终止条件 $fit < \varepsilon$ (ε 为设定的误差函数的阈值)或迭代次数达到 $Maxiter$, 满足则算法结束, 全局历史最优位置为 ESN 神经网络的输出权值矩阵 W_{out} , 并利用优化的网络参数进行训练及预测。否则返回 Step3。

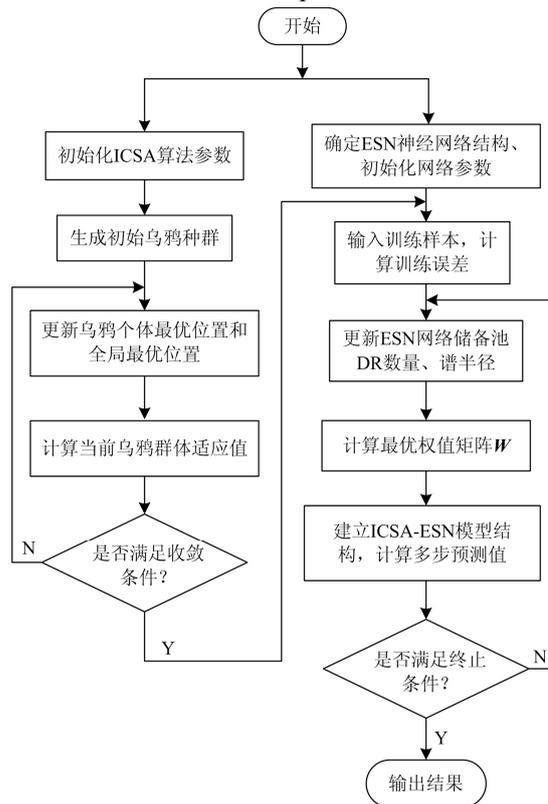


图 2 算法流程图

Fig. 2 Flowchart of algorithm

其中, 目标函数的适应值 fit 选择均方误差函数。

$$fit = \frac{1}{M} \sum_{k=1}^M [y(k) - \hat{y}(k)]^2 \quad (14)$$

式中: $y(k)$ 为 k 时刻 ESN 神经网络的输出值; \hat{y} 为模型的期望输出; M 为训练样本集的个数。

4 实例仿真与分析

为验证提出的 ICSA-ESN 网络模型对短期风电功率的建模能力, 分别选取爱尔兰风电场 2016 年 1、2 月和 6、7 月两组风机发电功率数据为研究对象, 不考虑风速、温度等自然物理条件对数值的影响关系, 对 3 月 1 日和 8 月 1 日 24 h 内的功率进行预测, 即利用 5 760 组数据作为训练样本, 96 组数据作为测试样本, 采样周期设置为 15 min, 对所建模型进

行拟合和检验。

4.1 数据处理与建模仿真

将训练数据输入到模型当中，经过计算得到的超前 1 步预测值是未来 15 min 的数据，将该预测值作为实际值与历史值构成新的时间序列，再次利用模型进行超前 2 步预测，如此反复训练直到达到 96 步，即得到该天 24 h 的预测值。

为了便于数据的直观分析和网络训练，将原始输出功率除以该风电场额定功率，得到序列的标么值(无单位百分百纲量)，利用该标么值进行建模。其中，风电场额定装机容量为 2 446 MW，模型的具体仿真实验参数设置如表 1 所示。

表 1 仿真实验初始参数设置

Table 1 Initial parameters of simulation experiment

参数名称	参数值
乌鸦种群规模	50
感知概率	0.4
飞行步长	2
最大迭代次数	100
参数维数	3
ESN 网络结构	1-250-1
谱半径	0.6

4.2 结果分析

为了体现本文所提 ICSA-ESN 模型的有效性，同时构建了传统的 BP 神经网络、ESN 神经网络以及基于粒子群优化的 BP 神经网络(PSO-BP 模型)3 种建模方法作为对比，最大允许误差设置为 $\varepsilon=10^{-5}$ ，经仿真计算分别得到爱尔兰风电场 2016 年 3 月 1 日和 8 月 1 日的风电功率预测曲线如图 3、图 4 所示，其中 3 月 1 日的预测误差对比曲线和各算法的适应值曲线如图 5、图 6 所示。

对于预测效率的评价，传统的神经网络算法均采用形如式(15)的平均百分比误差 e_{MAPE} 作为预测误差函数，本文借用信息理论中的 Kullback-Leibler 距离方法，定义相对熵 E 来对网络输出值和期望值接近程度进行度量，如式(16)所示。

$$e_{MAPE} = \frac{1}{M} \left| \frac{o(k) - d(k)}{o(k)} \right| \times 100\% \quad (15)$$

$$E = \sum_{k=1}^M \left\{ d(k) \ln \frac{d(k)}{o(k)} + [1 - d(k)] \ln \frac{1 - d(k)}{1 - o(k)} \right\} \quad (16)$$

式中： $d(k)$ 和 $o(k)$ 分别为归一化后期望输出和实际输出； E 反映的是 $d(k)$ 和 $o(k)$ 变量之间的“距离”尺度(即相似度)。

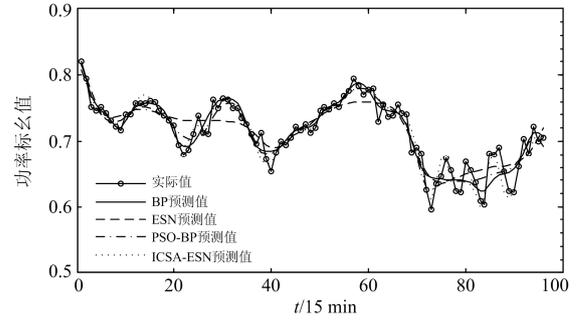


图 3 3月1日功率预测曲线

Fig. 3 Power prediction curve on March 1

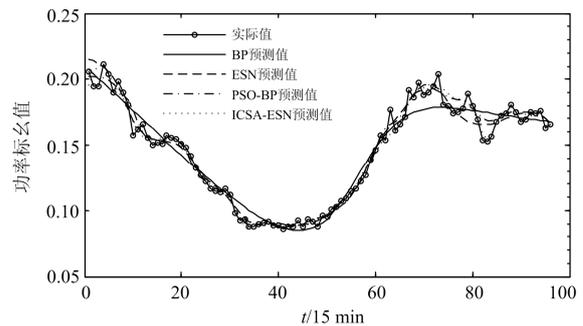


图 4 8月1日功率预测曲线

Fig. 4 Power prediction curve on August 1

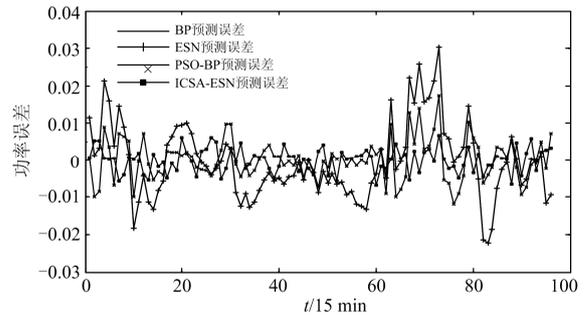


图 5 3月1日的预测误差对比曲线

Fig. 5 Comparison curve of prediction error on March 1

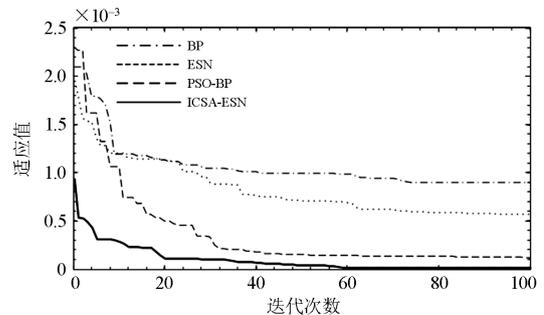


图 6 各算法的适应值曲线

Fig. 6 Fitness curve of each algorithms

各预测方法的评价指标如表 2 所示。

表 2 各预测方法的评价指标

Table 2 Evaluation indexes of each prediction method

模型	$e_{MAPE} / \%$	$E / 10^{-4}$
BP 神经网络	14.120 2	3.164 3
ESN 神经网络	13.664 1	1.143 6
PSO-BP 网络	11.237 2	0.468 9
ICSA-ESN 网络	7.328 5	0.298 3

直观判断预测模型建立的是否合理主要观察其跟踪实际曲线变化的趋势, 从图 3—图 5 和表 2 可以看出, 这四种方法都有较好的拟合实际功率曲线能力, 但是在 8 月 1 日的预测曲线中, BP 神经网络出现了过拟合现象, 曲线显得过于平滑。而改进的 BP 和 ESN 神经网络都能够将预测误差控制在 11.2372% 和 7.3285%, 低于传统的 BP 和 ESN 神经网络算法, 均在可接受范围之内, 效果较为理想。

在相对熵指标方面, 本文提出的 ISCA-ESN 神经网络模型则表现出比 PSO-BP 神经网络更为优秀的结果, 达到了四种模型的最低值 2.983×10^{-5} , 可见该算法的预测精度更高。

图 6 的适应值曲线也可以看出, 四种模型的适应值均随着迭代步数的增加而减小到趋于稳定, 其中 ICSA-ESN 网络模型的收敛速度比 PSO-BP 网络模型更快, 在第 40 步的时候目标函数适应值即已趋于平稳, 这是由于 ICSA 算法在迭代中增加了 Lévy 飞行策略, 更加贴近于真实的鸟群寻优过程, 增强了局部搜索的随机性, 对未知的非线性系统具有良好的系统辨识和预测能力。

5 结论

风力发电由于受到风速、温度、气压等物理因素的影响, 呈现出高度复杂的、非线性特征, 难以用精确的数学模型进行表达。在分析了乌鸦局限性的基础上, 从仿生原理入手, 提出一种改进的乌鸦算法, 对回声状态网络(ESN)参数进行优化, 并将其应用到短期风电功率的预测当中, 取得了良好的效果, 取得了如下结论:

1) 针对乌鸦算法在高维空间优化时过早收敛、缺乏变异机制的不足, 提出采用 Lévy 飞行行为搜索策略来更为真实地模拟乌鸦捕食行为, 并将高斯惩罚函数引入到算法当中, 取代原算法的位置更新方式, 有效避免了局部极值的吸引。

2) 提出将改进的乌鸦算法用于 ESN 神经网络的训练中, 通过迭代来优化 ESN 网络动态储备池数量和谱半径参数, 最终得到输出权值矩阵, 与传统

静态神经网络相比, 该算法不使用梯度信息, 进一步提升了预测模型的寻优能力。

3) 分别选取两组爱尔兰风电场实测功率数据, 利用 ICSA-ESN 网络模型对未来 24 h 的功率进行预测, 并以平均百分比误差和相对熵为评价指标, 算例结果表明, 对比其他三种算法, 本文提出的组合模型具有更快的收敛速度和更高的预测精度。

参考文献

- [1] 刘波, 贺志佳, 金昊. 风力发电现状与发展趋势[J]. 东北电力大学学报, 2016, 36(2): 7-13.
LIU Bo, HE Zhijia, JIN Hao. A review of chaos theory in power system load prediction[J]. Journal of Northeast Dianli University, 2016, 36(2): 7-13.
- [2] CATALAO J, POUSINHO H, MENDES V. Hybrid intelligent approach for short-term wind power forecasting in Portugal[J]. IET Renewable Power Generation, 2011, 5(3): 251-257.
- [3] JIANG Yu, CHEN Xingying, YU Kun, et al. Short-term wind power forecasting using hybrid method based on enhanced boosting algorithm[J]. Journal of Modern Power System and Clean Energy, 2017, 5(1): 126-133.
- [4] 陈昊, 万秋兰, 王玉荣. 基于厚尾均值广义自回归条件异方差族模型的短期风电功率预测[J]. 电工技术学报, 2016, 31(5): 91-98.
CHEN Hao, WAN Qiulan, WANG Yurong. Short-term wind power forecast based on fat-tailed generalized autoregressive conditional heteroscedasticity in mean type model[J]. Transactions of China Electrotechnical Society, 2016, 31(5): 91-98.
- [5] 刘爱国, 薛云涛, 胡江鹭, 等. 基于 GA 优化 SVM 的风电功率超短期预测[J]. 电力系统保护与控制, 2015, 43(2): 90-95.
LIU Aiguo, XUE Yuntao, HU Jianglu, et al. Ultra-short-term wind power forecasting based on SVM optimized by GA[J]. Power System Protection and Control, 2015, 43(2): 90-95.
- [6] 张宜阳, 卢继平, 孟洋洋, 等. 基于经验模式分解和混沌相空间重构的风电功率短期预测[J]. 电力系统自动化, 2012, 36(5): 24-28.
ZHANG Yihang, LU Jiping, MENG Yangyang, et al. Wind power short-term forecasting based on empirical mode decomposition and chaotic phase space reconstruction[J]. Automation of Electric Power Systems, 2012, 36(5): 24-28.
- [7] 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. DOI: 10.1186/s41601-016-0016-y.
- [8] 师彪, 李郁侠, 于新花, 等. 基于改进粒子群-模糊神经网络的短期电力负荷预测[J]. 系统工程理论与实践, 2010, 30(1): 158-166.
SHI Biao, LI Yuxia, YU Xinhua, et al. Short-term load forecasting based on modified particle swarm optimizer and fuzzy neural network model[J]. Systems Engineering Theory and Practice, 2010, 30(1): 158-166.
- [9] 李燕青, 袁燕舞, 郭通. 基于 AMD-ICSA-SVM 的超短期风电功率组合预测[J]. 电力系统保护与控制, 2017, 45(14): 113-120.
LI Yanqing, YUAN Yanwu, GUO Tong. Combination ultra-short-term prediction of wind power based on AMD-ICSA-SVM[J]. Power System Protection and Control, 2017, 45(14): 113-120.
- [10] 尹东阳, 盛义发, 蒋明结, 等. 基于粗糙集理论-主成分分析的 Elman 神经网络的短期风速预测[J]. 电力系统保护与控制, 2014, 42(11): 46-50.
YIN Dongyang, SHENG Yifa, JIANG Mingjie, et al. Short-term wind speed forecasting using Elman neural network based on rough set theory and principal components analysis[J]. Power System Protection and Control, 2014, 42(11): 46-50.
- [11] 张颖超, 王雅晨, 邓华, 等. 基于 IAFSA-BPNN 的短期风电功率预测[J]. 电力系统保护与控制, 2017, 45(7): 58-63.
ZHANG Yingchao, WANG Yachen, DENG Hua, et al. IAFSA-BPNN for wind power probabilistic forecasting[J]. Power System Protection and Control, 2017, 45(7): 58-63.
- [12] 李松, 刘力军, 解永乐. 遗传算法优化 BP 神经网络的短时交通流混沌预测[J]. 决策与控制, 2011, 26(10): 1581-1585.
LI Song, LIU Lijun, XIE Yongle. Chaotic prediction for short-term traffic flow of optimized BP neural network based on genetic algorithm[J]. Control and Decision, 2011, 26(10): 1581-1585.
- [13] 叶小岭, 顾荣, 邓华, 等. 基于 WRF 模式和 PSO-LSSVM 的风电场短期风速订正[J]. 电力系统保护与控制, 2017, 45(22): 48-54.
YE Xiaoling, GU Rong, DENG Hua, et al. Modification technology research of short-term wind speed in wind farm based on WRF model and PSO-LSSVM method[J]. Power System Protection and Control, 2017, 45(22): 48-54.
- [14] ALMOATAZ Y, ABDELAZIZ A, AHMED F. A novel approach based on crow search algorithm for optimal selection of conductor size in radial distribution networks[J]. Engineering Science and Technology, 2017, 20: 391-402.
- [15] BABINEC S, POSPICHAL J. Modular echo state neural networks in time series prediction[J]. Computing and Informatics, 2011, 30: 321-334.
- [16] SAYED G, HASSANIEN A, AZAR A. Feature selection via a novel chaotic crow search algorithm[J]. Neural Computing and Applications, 2017(1): 1-18.
- [17] VISWANATHAN G M, AFANSYEV V, BULDYREV S, et al. Lévy flights search patterns of wandering albatrosses[J]. Nature, 1996, 381: 13-15.
- [18] 费腾, 张立毅, 陈雷. 混合 Levy 变异与混沌变异的改进人工鱼群算法[J]. 计算机工程, 2016, 42(7): 146-15.
FEI Teng, ZHANG Liyi, CHEN Lei. Improved artificial fish swarm algorithm mixing Levy mutation and chaotic mutation[J]. Computer Engineering, 2016, 42(7): 146-152.
- [19] 张迅, 王平, 邢建春, 等. 基于高斯函数递减惯性权重的粒子群优化算法[J]. 计算机应用研究, 2012, 29(10): 3710-3712.
ZHANG Xun, WANG Ping, XING Jianchu, et al. Particle swarm optimization algorithms with decreasing inertia weight based on Gaussian function[J]. Application Research of Computers, 2012, 29(10): 3710-3712.
- [20] 温润, 谭丽. 结合 HS 算法与 ESN 算法的光伏发电短期出力预测[J]. 计算机科学, 2017, 44(6): 226-231.
WEN Run, TAN Li. Short-term power forecasting for photovoltaic generation based on HS-ESN[J]. Computer Science, 2017, 44(6): 226-231.
- [21] 乔俊飞, 李瑞祥, 柴伟, 等. 基于 PSO-ESN 神经网络的污水 BOD 预测[J]. 控制工程, 2016, 23(4): 463-467.
QIAO Junfei, LI Ruixiang, CHAI Wei, et al. Prediction of BOD based on PSO-ESN neural network[J]. Control Engineering of China, 2016, 23(4): 463-467.

收稿日期: 2018-03-10; 修回日期: 2018-04-27

作者简介:

琚 焱(1983—), 男, 通信作者, 硕士研究生, 讲师, 研究方向为电气自动化; E-mail: 2440802220@qq.com

祁 林(1983—), 男, 博士研究生, 讲师, 研究方向为建筑电气及其自动化;

刘 帅(1990—), 男, 硕士研究生, 研究方向为电力系统分析与控制。

(编辑 张爱琴)