

# 基于 EMD-GRNN 和概率统计结合的短期风速预测

朱 亚 孙冬梅 何 响 刘曼曼

(南京工业大学自动化与电气工程学院 南京 211816)

**摘 要** 文中参照风电场原始数据,依据风速的特性,提出了一种基于 EMD-GRNN 和概率统计结合的短期风速预测算法。首先对原始数据进行预处理,然后对原始风速进行经验模态分解(EMD),获得原风速的所有基本模态分量(IMF);接着对各分量数据进行重构得到训练样本和预测样本,利用训练样本训练 GRNN 网络,使网络具备预测能力;最后对各个分量输出的数据进行概率统计。仿真实验表明,与单独的神经网络预测方法相比,结合概率统计的 EMD-GRNN 预测模型,具有更好的预测精度和稳定性。

**关键词** 短期风速预测,经验模态分解,GRNN 网络,概率统计

中图分类号 TP391 文献标识码 A

## Short-term Wind Speed Prediction Based on EMD-GRNN Combination of Probability and Statistics

ZHU Ya SUN Dong-mei HE Xiang LIU Man-man

(School of Automation & Electrical Engineering, Nanjing University of Technology, Nanjing 210009, China)

**Abstract** Referring to raw data of the wind farm and based on the characteristics of wind speed, this article proposed a short-term wind speed prediction algorithm based on EMD-GRNN combination of probability and statistics. The paper firstly preprocessed the original data, then took advantage of empirical mode decomposition (E-MD) on the original wind speed, to get all the basic raw wind modal component (IMF). Next, this paper proceeded to reconstruct the data of each component to get the training samples and forecasting samples and utilized the training sample to train GRNN network to make the network predictive capability. Finally this paper made a probability statistics on the output data of the various components. Simulation results show that the EMD-GRNN prediction model of combination of probability and statistics has good predictive accuracy and stability.

**Keywords** Short-term wind speed prediction, EMD, GRNN network, Probability statistics

风速预测一直以来都是风电场功率平衡的重要组成部分,风速具有明显的非平稳性和非线性<sup>[1]</sup>,风能并网后产生的波动性需要及时通过电网调度来平衡,所以准确预测风速能有效减少风电场对电网的不利影响。一般来说,预测风速的周期越短,预测地方的风速变化越缓慢,预测的误差就越小,预测精度就越高,反之,预测的误差越大,预测精度就越低<sup>[2,3]</sup>。对于短期风速预测,由于传统单一模型的精度提高有限,使得组合模型预测越来越受到人们的青睐。线性预测模型对于线性输入信号的处理鲁棒性很强,但是对于波动较大的非线性输入信号,线性预测模型受到本身的影响有一定的局限性,而非线性预测模型,比如神经网络等其他智能网络,对于非线性信号的处理效果更好。

目前,基于短期风速预测的算法有很多,比如基于 ARIMA、SVM、NN 等;对预测模型的优化算法也有很多,比如 GA、PSO、LS 等。本文则采用基于 EMD 分解和 GRNN 神经网络的预测模型。EMD 分解不受结构的影响,完全由输入信号决定,能够将非平稳的信号转化为平稳信号,而 GRNN 网络能够快速处理大量数据,较 BP 等其他神经网络,优化的参数只有一个平滑参数,所以能够保证优化速度<sup>[4]</sup>。

## 1 EMD-GRNN 预测模型的理论背景

### 1.1 经验模态分解

经验模态分解(Empirical Mode Decomposition, EMD)是 Hung<sup>[5]</sup>等人于 1998 年提出的一种数据处理方法。它是在 HHT(Hilbert-Huang Transform)变换基于时频分析领域的应用中产生的。它是一种直接基于原信号的自适应分解方法而不像小波分解需要依赖小波基函数<sup>[6]</sup>。EMD 分解的核心是任何一个非平稳非线性的信号都是由多个平稳信号叠加而成,所以使用 EMD 方法处理非平稳非线性的数据的效果非常明显。通过对信号分解就能得到信号的基本模态分量(Intrinsic Mode Function, IMF),具体分解过程如图 1 所示。

通过 EMD 分解,原风速信号被分解成有限个 IMF 和一个余项的叠加,即

$$x(t) = \sum_{i=1}^n c_i(t) + r_n(t) \quad (1)$$

其中,  $x(t)$  为输入信号,  $c_i(t)$  为第  $i$  个 IMF 分量,  $r_n(t)$  为余项(可以看成最后一个 IMF 分量),分解出的 IMF 分量具有两个特点:①由局部极大值构成的上包络和由局部极小值构成的下包络的平均值为零;②极值点(包括极大值与极小值)数

本文受江苏省科技厅工业科学支撑项目(BE2009166)资助。

朱 亚(1990-),男,硕士生,主要研究方向为控制理论与控制工程。

目与零点数目相等或者最多相差一个。

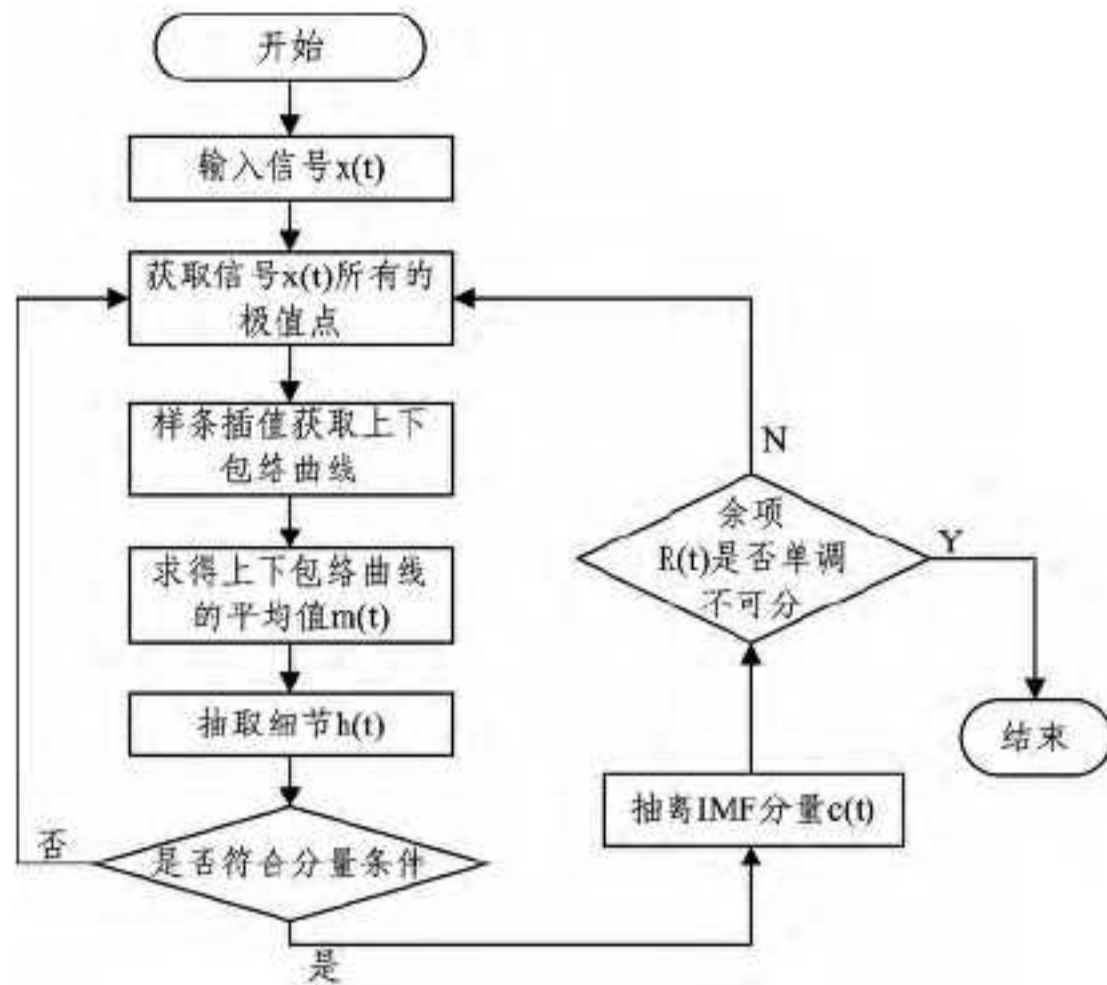


图1 EMD分解过程

### 1.2 广义回归神经网络

广义回归神经网络 (General regression neural network, GRNN) 是由学者 Specht 于 1991 年提出的。GRNN 网络<sup>[5]</sup>属于 RBF 网络的一种, 具有非常强的非线性映射能力和柔性网络结构。其具有很强的容错性和鲁棒性, 在逼近能力与学习速度上相比于 RBF 网络有更强的优势, 网络最终收敛于样本量积聚较多的优化回归面, 其最主要的优点是对于大数据量的收敛速度很快, 计算结果稳定精确, 同时, 当网络的输入与输出确定后, 网络层与层之间的连接权值就已经确定了, 唯一需要确定的参数只有一个平滑参数, 网络的拓扑结构如图 2 所示。




图2 GRNN网络的结构图

GRNN 网络有 4 层结构, 分别是输入层、模式层、求和层以及输出层。网络输入为:

$$X = [x_1, x_2, \dots, x_n]^T$$

网络输出为:

$$Y = [y_1, y_2, \dots, y_k]^T$$

模式层神经元个数等于输入样本个数,  $P_i$  神经元对应的传递函数为:

$$p_i = \exp\left[-\frac{(X - X_i)^T(X - X_i)}{2\sigma^2}\right] \quad i=1, 2, \dots, n \quad (2)$$

其中,  $X$  为输入样本,  $X_i$  为第  $i$  个神经元对应的学习样本,  $\sigma$  为平滑参数。

求和层包括两类神经元, 第一类用于算术求和, 第二类用于加权求和。计算公式分别如下:

$$S_D = \sum_{i=1}^n P_i \quad (3)$$

$$S_{N_j} = \sum_{r=1}^n y_{rj} P_i, \quad j=1, 2, \dots, k \quad (4)$$

输出层的神经元数目等于学习样本中输出向量的维数  $k$ , 第  $j$  个神经元的输出为:

$$y_j = \frac{S_{N_j}}{S_D}, \quad j=1, 2, \dots, k \quad (5)$$

### 1.3 概率统计<sup>[8]</sup>

事件的概率说明了事件发生的可能性大小。统计大量随机事件便能发现事件的规律。古典概率通常指的是验前概率。古典概率基本的特点是可知、准确、无需验证。通常来说如果构成事件  $A$  的基本事件有  $a$  个, 不构成  $A$  的基本事件有  $b$  个, 则  $A$  事件发生的概率为:

$$P(A) = \frac{a}{a+b} \quad (6)$$

### 1.4 短期风速预测算法

本文的短期风速预测的时间间隔为 30min。实验所用到的数据来源于近两年风电场原数据, 根据风速的季节性变化规律<sup>[9]</sup>选取夏季 8 月和冬季 1 月部分数据作为实验的原始数据, 来对预测模型的预测精度和稳定性进行研究分析。夏季 8 月份部分原始风速时间序列如图 3 所示; 冬季 1 月份部分原始风速时间序列如图 4 所示。




图3 夏季原始风速时间序列




图4 冬季原始风速时间序列

基于 EMD-GRNN 和概率统计的短期风速预测算法主要分为 5 个部分, 包括数据预处理、EMD 分解、数据重构与分组、GRNN 网络训练与预测和数据统计与分析, 实验流程如图 5 所示。



图5 实验流程

实验具体步骤主要有: ①数据预处理: 原始风电场数据采集时间间隔为 1s, 依次间隔 30 分钟取一个风速值, 共取 330 个值, 然后将数据进行归一化处理; ②EMD 分解: 将风速时间序列进行 EMD 分解, 获取原风速对应的所有 IMF 分量; ③数据重构与分组: 实验预测利用前 4 个小时的风速(共 8 个点),

预测下一个 30 分钟内(第 9 个点)的平均风速。首先对各分量数据截取重构成  $320 \times 8$  的数据,其中 270 组作为训练样本,50 组作为预测样本。然后截取原始风速对应的风速数据,共 320 组。其中 270 组作为训练样本输出。④GRNN 网络训练与预测,当 GRNN 网络输入与输出矩阵确定以后,网络的连接权值都已经确定,只需要通过训练获得网络的  $\sigma$  平滑参数。将 IMF 各分量的训练数据依次导入各自 GRNN 网络并训练网络。分别导入各 IMF 分量对应的预测矩阵,按照高频到低频的顺序,首先对第一个 IMF 分量进行预测,输出误差与预测值,然后对下一个 IMF 分量进行预测,同时利用上一个分量的误差进行修正,并输出本分量对应的误差及预测值,依次训练与预测直至余项对应 GRNN 网络输出预测值及误差,最后,利用原风速直接进行 GRNN 网络训练与预测,输出预测值与误差。网络训练与预测流程如图 6 所示。

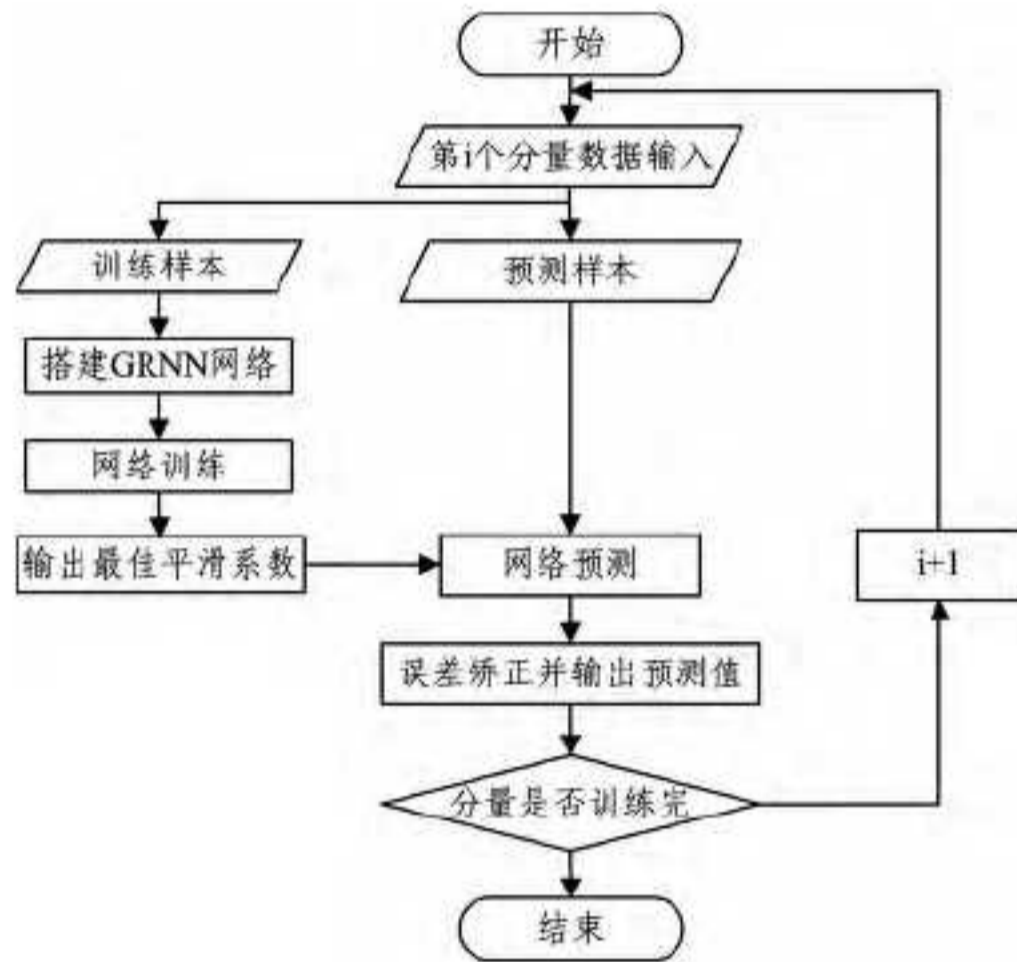


图 6 GRNN 训练与预测流程

⑤ 概率统计与分析,根据上一次预测值各分量的概率值,计算出本次的预测值。预测第一个时间点的概率各个 IMF 分量均等,即为  $\frac{1}{m}$ ,同时确定本次离真实值最接近的分量编号,各个分量的概率相应改变作为下一次预测值计算当中各分量的系数,对应分量的概率则增加为  $\frac{2}{m+1}$ ,其余分量的概率则变为  $\frac{1}{m+1}$ ,依次类推,直至所有预测点统计完为止,第  $j$  个时间点的预测值的计算如式(7)所示:

$$YC(j) = \sum_{i=1}^m P(i, j-1) y(i, j), j=1, 2, \dots, n \quad (7)$$

其中,  $YC(j)$  为第  $j$  个时间点的预测值;  $P(i, j-1)$  为第  $j-1$  个时间点、第  $i$  个分量对应的概率;  $y(i, j)$  为第  $i$  个分量、第  $j$  个时间点的预测值。

## 2 仿真与分析

### 2.1 误差指标

选定科学的误差指标很重要。这里选择常用的平均绝对百分误差(MAPE)和均方根误差(RMSE)作为性能指标。它们的计算公式如下:

$$MAPE = \frac{1}{N} \left[ \sum_{i=1}^N \left| \frac{v_i - y_i}{v_i} \right| \times 100\% \right] \quad (8)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (v_i - y_i)^2} \quad (9)$$

其中,  $N$  是预测样本总数;  $v_i$  是原始风速值;  $y_i$  是预测风速值。

### 2.2 结果分析

利用原风速时间序列进行预测,并对预测数据结合概率进行统计,同时获取各预测曲线误差,计算曲线对应 MAPE 值(%)和 RMSE 值( $(m \cdot s^{-1})^2$ )。夏季原风速 GRNN 网络预测值、各分量 GRNN 预测值的平均值和通过 EMD-GRNN 结合概率统计方法得到的预测曲线如图 7 所示,冬季各方法风速预测曲线如图 8 所示,各曲线对应的 MAPE 值与 RMSE 值如表 1 所列。

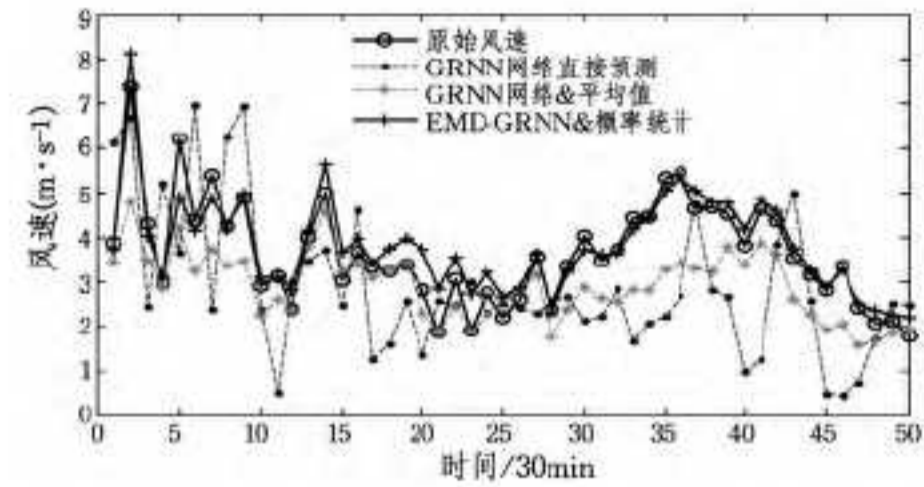


图 7 夏季各预测曲线

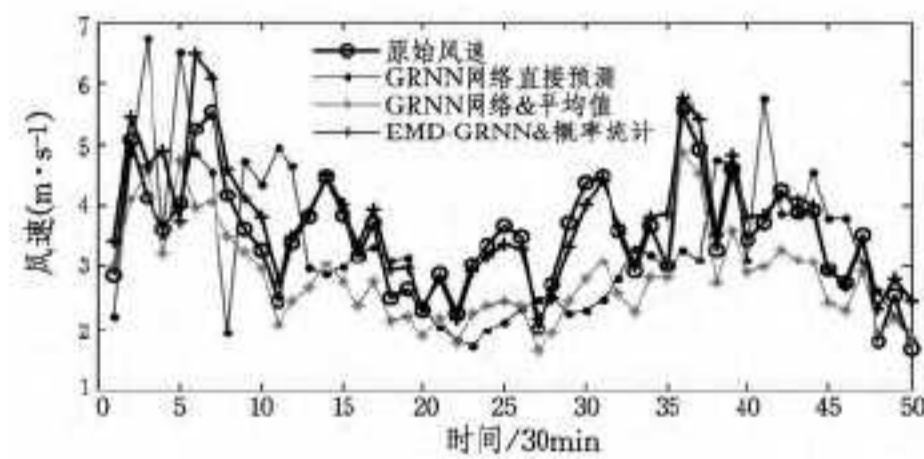


图 8 冬季各预测曲线

从图 7 和图 8 可以看出,基于 EMD-GRNN 预测模型结合概率统计的算法,预测的精度和稳定性非常好。表 1 中的数据表明,运用 EMD 分解进行预测,要比用原风速信号直接 GRNN 网络预测值精确许多。主要原因在于,风速带有一定的突变,具有典型的非平稳性和非线性。EMD 分解能有效地将非平稳信号转化为平稳信号。

表 1 预测误差对比

季节	误差指标	GRNN 网络 直接预测	GRNN 网络 & 平均值	EMD-GRNN & 概率统计
夏季	MAPE(%)	39.76	19.81	9.87
	RMSE( $(m/s)^2$ )	3.0343	1.0007	0.1744
冬季	MAPE(%)	27.26	20.40	8.32
	RMSE( $(m/s)^2$ )	1.4758	0.6903	0.1696

同时,从表 1 中能看出,采用本文 EMD-GRNN& 概率统计方法要比 GRNN 网络 & 平均值方法预测的风速值更精确。主要在于,求平均值的做法相当于每一次的预测值是独立的,跟前  $k$  次预测结果是无关系的,而运用概率统计的做法,则充分注重前后预测值之间的联系,能够把握住风速变化的规律。实际实验中经过多次预测,MAPE 值稳定在 8%~13%;RMSE 值稳定在 0.16~0.20,预测效果非常稳定。另外,通过实验仿真对比,与运用 BP 网络<sup>[10]</sup>、最小二乘法<sup>[11]</sup>、ARMA<sup>[12]</sup>、SVM<sup>[13]</sup>搭建的预测模型在预测精度和预测稳定性上相比,本文提出的短期风速预测算法有很大的改善。

结束语 本文叙述的 EMD-GRNN 结合概率统计的短期风速预测算法能够有效地处理非线性、非平稳的时间序列。这种算法速度快,精度高,预测结果稳定。实验过程中对原风速直接采用 GRNN 网络训练并预测,并且取各分量的预测值及预测值的平均值,另外所有预测样本均实验多次以上,通过对比验证了本文提出的预测算法的准确度和稳定性。

在实验中同时也发现了一些不知之处,比如第一次预测值的概率计算没有参照物,故实验中采用各分量概率相等,但结果显示这一做法对精度有较大影响,于是第一个时间点数据采用已知数据来代替,从长远的角度来看,这种处理方法是可行的。

### 参考文献

- [1] 王晓兰,李辉.基于EMD与LS-SVM的风电场短期风速预测[J].计算机工程与设计,2010,31(10):2303-2307
- [2] 刘兴杰,米增强,杨奇逊,等.一种基于EMD的短期风速多步预测方法[J].电工技术学报,2010,25(4):165-170
- [3] 戴浪,黄守道,黄科元,等.风电场风速的神经网络组合预测模型[J].电力系统及其自动化学报,2011,23(4):27-31
- [4] 张娅莉,喇果彦.GRNN神经网络在信息分析预测中的应用[J].数据采集与处理,2009,24(S):100-103
- [5] Huang N E, Shen Z, Long S R. The empirical mode decomposition and the hilbert spectrum for nonlinear and non-stationary time series analysis [J]. Proceedings of the Royal Society London, 1998, 454 (1): 903-905
- [6] 储茂得,周松林.基于小波分析与神经网络的风电场短期风速预测[J].安徽科技学院学报,2011,25(1):35-38
- [7] 闻新,周露,李翔,等. MATLAB神经网络仿真与应用[M].北京:科学出版社,2003
- [8] 赵新泽,蒋光震,何灿芝,等.概率论与数理统计教程[M].成都:西南交通大学出版社,1991
- [9] 陈欣,宋丽莉,黄浩辉,等.中国典型地区风能资源特性研究[J].太阳能学报,2011,32(3):331-336
- [10] 储茂得,周松林.基于小波分析与神经网络的风电场短期风速预测[J].安徽科技学院学报,2011,25(1):35-38
- [11] 王晓兰,李辉.风电场输出功率年度预测中有效风速预测研究[J].中国电机工程学报,2010,30(8):117-122
- [12] 杨锡运,孙翰墨.基于时间序列模型的风电场风速预测研究[J].动力工程学报,2011,3(21):203-208
- [13] 曾杰,张华.基于蚁群优化的最小二乘支持向量机风速预测模型研究[J].太阳能学报,2011,32(3):296-300
- [47] Mahdavi M, Chehreghani M H, Abolhassani H, et al. Novel meta-heuristic algorithms for clustering web documents [J]. Applied Mathematics and Computation, 2008, 201: 441-451
- [48] Ren D, Qiang S. Feature selection with harmony search [J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics, 2012, 42(6): 1509-1523
- [49] Ali K, Rosni A, Abdul S R. Harmony search based supervised training of artificial neural networks [C] // Proc of the 1st International Conference on Intelligent Systems, Modeling and Simulation. Liverpool, United Kingdom, Piscataway, NJ: IEEE Press, 2010: 105-110
- [50] Verma A, Panigrahi B K, Bijwe P R. Harmony search algorithm for transmission network expansion planning [J]. IET Generation, Transmission & Distribution, 2010, 4(6): 663-673
- [51] 李亮,王玉杰,王秋生,等.土坡稳定分析中模拟任意滑动面的新策略及其效率分析[J].水利学报,2008,39(5):535-541
- [52] Cheng Y M, Li L, Lansivaara T, Chi S C, et al. An improved harmony search minimization algorithm using different slip surface generation methods for slope stability analysis [J]. Engineering Optimization, 2008, 40(2): 95-115
- [53] Xu H, Gao X Z, Wang T, et al. Harmony search optimization algorithm; application to a reconfigurable mobile robot prototype [J]. Stud. Comput. Intell, 2011, 270: 11-22
- [54] Tangpattanakul P, Meesomboon A, Artrit P. Optimal trajectory of robot manipulator using harmony search algorithms [J]. Stud. Comput. Intell, 2010, 270: 23-36
- [55] Yazdi E, Azizi V, Haghghat A T. A new biped locomotion involving arms swing based on neural network with harmony search optimizer [C] // Proc of the IEEE International Conference on Automation and Logistics. Chongqing, China: IEEE Press, 2011: 18-23
- [56] Coelho L S, Diego L, Bernert A. A harmony search approach using exponential probability distribution applied to fuzzy logic control optimization [J]. Stud. Comput. Intell, 2010, 270: 77-88
- [57] Das S K, Chatterjee A, Rakshit A. Design of a hybrid stable adaptive fuzzy controller employing lyapunov theory and harmony search algorithm [J]. IEEE Trans. Contr. Syst. Tech, 2010, 18: 1440-1447
- [58] Panehal A. Harmony search optimization for HDR prostate brachytherapy [D]. American Association of Physicists in Medicine, 2009: 720-721
- [59] Amor J, Alexandre E, Gilpita R. Music-inspired harmony-search algorithm applied to feature selection for sound classification in hearings aids [C] // Proc of Audio Engineering Society the 124th Convention. Netherlands, UK, Piscataway, NJ: IEEE Press, 2008: 17-20
- [60] Dong H, Bo Y, Gao M. Improved harmony search for detection with Photon density wave [C] // Proceedings of SPIE. Washington: SPIE Press, 2008: 1-9
- [61] Gandhi T K, Chakraborty P, Roy G G, et al. Discrete harmony search based expert model for epileptic seizure detection in electroencephalography [J]. Expert Systems with Applications, 2012, 39(4): 4055-4063
- [62] Alia O M, Mandava R, Aziz M E. A hybrid harmony search algorithm to mri brain segmentation [C] // Proc of the 9th IEEE international conference on cognitive informatics. Beijing, China: IEEE Press, 2010: 712-719
- [63] Landa T I, Gil-Lopez S, Del S J, et al. Efficient citywide planning of open WiFi access networks using novel grouping harmony search heuristics [J]. Engineering Applications of Artificial Intelligence, 2013, 26(3): 1124-1130
- [64] Forsati R, Haghghat A T, Mahdavi M. Harmony search based algorithms for bandwidth-delay-constrained least-cost multicast routing [J]. Computer Communications, 2008, 31(10): 2505-2519
- [65] Zhang R, Hanzo L. Iterative multiuser detection and channel decoding for DS-CDMA using harmony search [J]. IEEE Signal Processing Letters, 2009, 16(10): 917-920
- [66] Jaco F, Steven M, Richard G. Harmony filter: A robust visual tracking system using the improved harmony search algorithm [J]. Image and Vision Computing, 2010, 28(12): 1702-1716
- [67] Gao M L, He X H, Luo D S, et al. Object tracking based on harmony search comparative study [J]. Journal of Electronic Imaging, 2012, 21(4)
- [68] Sörensen K. Metaheuristics-the metaphor exposed [J]. International Transactions in Operational Research, 2013: 1-16