

基于贝叶斯网络的跳频序列多步预测^{*}

张恒伟, 杨有龙, 朱原媛

(西安电子科技大学 理学院, 西安 710071)

摘 要: 根据跳频频率序列具有混沌特性,在相空间重构理论基础上提出一种用于跳频频率序列预测的贝叶斯网络模型。该模型将重构后的整个相空间作为先验数据信息,进而通过学习贝叶斯网络并利用贝叶斯网络推理算法达到对跳频频率多步预测的目的。仿真结果表明该方法具有良好的多步预测能力,并能有效地克服过拟合现象。

关键词: 跳频序列; 贝叶斯网络; 相空间重构; 多步预测

中图分类号: TN975 **文献标志码:** A **文章编号:** 1001-3695(2012)01-0237-04

doi:10.3969/j.issn.1001-3695.2012.01.066

Multi-step prediction of frequency-hopping sequences based on Bayesian networks

ZHANG Heng-wei, YANG You-long, ZHU Yuan-yuan

(School of Science, Xidian University, Xi'an 710071, China)

Abstract: According to the chaotic characteristics of frequency hopping (FH) sequences and based on the phase-space reconstruction, This paper proposed a Bayesian network model applied to FH sequences prediction. The model regarded entire phase-space as a priori data information to learn Bayesian networks. Then it achieved the multi-step prediction of frequency hopping using the Bayesian network inference algorithm. Experiment results show that the proposed method can provide high accurate precision with steady multi-step prediction ability and avoid the over-fitting effectively.

Key words: FH sequences; Bayesian networks; phase-space reconstruction; multi-step prediction

0 引言

跳频通信作为扩频通信技术的一个重要分支,其突出特点是抗干扰能力强、抗多径衰落、低截获率和易于组网等,在军事通信领域具有广泛的应用。随着跳频技术的发展,跳频信号的调制样式呈现出多样化和复杂化,因此根据截获的跳频频率序列,合理预测未来频率的跳变范围,对取得现代战争的胜利具有至关重要的意义。已有的研究表明,跳频通信的频率序列具有混沌特性^[1,2]。基于跳频频率序列具有的混沌特性以及混沌的短期可预测性,利用混沌理论对跳频频率序列进行预测成为各个领域研究的热点^[3]。

Packard 及 Takens 等人先后提出的相空间重构理论为混沌时间序列预测奠定了理论基础。在此基础上,人们提出了多种预测方法^[4]。全局预测法是将轨迹中的全部相点作为拟合对象,找出时间序列演变规律,实现预测。这种方法概念清晰,预测精度较高,但是当系统关系复杂时,模型难以建立,并且计算量较大,复杂度高。局部预测法是在相空间中寻找与预测点最邻近的相点,利用邻近点的变化规律逼近预测点的序列值。这种方法模型简便,在局部邻域中预测较精确,但是一旦超出相应的区域范围,局部模型的精度便会下降,而且该方法对先验信息利用不完整,模型也不稳定。自适应预测法在预测的过程中,根据当前的预测误差来调整模型中的参数,使得下次预测值的误差达到最小,这种方法预测精度高,模型适应性强,但

是对算法的跟踪识别和实时递推性要求较高。

本文借鉴神经网络预测方法^[5,6],在相空间重构理论框架下,提出基于贝叶斯网络的跳频频率预测方法,它将重构后的整个相空间作为先验数据信息,以此进行贝叶斯网络结构学习和参数学习,进而利用贝叶斯网络推理算法对跳频频率未来时刻频率值进行预测。由 Logistic 映射和 Lorenz 系统仿真实验表明,该方法具有较高的预测精度,在进行多步预测时,一定步数范围内,模型同样可以有效地对跳频序列进行预测,并且可以避免过拟合现象。

1 相空间重构

对于混沌系统,由于传统的低维坐标无法揭示混沌系统的复杂动力学特征。Takens 等人^[7]提出将时间序列在某些固定时间的延迟点上的观测量看成新的坐标,由它们共同确定多维状态空间的一点。这个多维空间即为重构的相空间,并证明了当相空间的嵌入维数 $m \geq 2D + 1$ 时, D 为系统的奇异吸引子维数,在相空间中可以完全展开混沌吸引子。此时重构后的相空间与原始状态空间是微分同胚的,在高维相空间中进行跳频频率预测等价于在原始空间的预测,所以相空间重构是进行跳频频率预测的第一步。

设观测到的跳频频率序列为

$$\{x_i\}, i = 1, 2, \dots, N \tag{1}$$

其中: $x_i \in \{f_1, f_2, \dots, f_M\}$, f_i 为跳频通信时的频率值。相空间重

构就是选择嵌入维数 m 和时间延迟 τ , 由 $\{x_i\}$ 延拓成一个 m 维相空间, 设得到重构后的相空间为

$$X = [X(1), X(2), \dots, X(n)] = \begin{bmatrix} x_1 & x_2 & \cdots & x_n \\ x_{1+\tau} & x_{2+\tau} & \cdots & x_{n+\tau} \\ \cdots & \cdots & \cdots & \cdots \\ x_{1+(m-2)\tau} & x_{2+(m-2)\tau} & \cdots & x_{n+(m-2)\tau} \\ x_{1+(m-1)\tau} & x_{2+(m-1)\tau} & \cdots & x_N \end{bmatrix} \quad (2)$$

其中: $n = N - (m - 1)\tau$, 每一列表示相空间中的一个相点。嵌入维数 m 和时间延迟 τ 是相空间重构中两个重要参数。选取延迟时间 τ 的方法有自相关法、去偏自相关法、时间窗法、互信息法等, 选取 m 的方法有伪邻点法、奇异值分解法、Cao 法、饱和关联维数法等。已有理论证明, 混沌时间序列的嵌入维数和时间延迟密切相关, 因此可以采取改进的 C-C 方法^[8] 来确定延迟时间 τ 和嵌入维数 m 。

2 贝叶斯网络

贝叶斯网络^[9,10] 表示为一个有向无环图 $B = (G, \theta)$ 。图 $G = (V, E)$ 中节点代表随机变量, 节点间的边代表变量间的直接依赖关系。每个节点 $X_i \in V, i = 1, 2, \dots, m$ 都附有一个条件概率分布 $P(X_i | pa(X_i))$, 其中 $pa(X_i)$ 表示变量 X_i 的父节点集合。设节点 X_i 共有 r_i 个取值 $1, 2, \dots, r_i$, 其父节点 $pa(X_i)$ 的取值共有 q_i 个组合 $1, 2, \dots, q_i$, 则网络参数

$$\theta_{ijk} = P(X_i = k | pa(X_i) = j) \quad (3)$$

基于节点间的独立性和概率的链规则, 联合概率分布可以分解为几个局部分布的乘积, 如式(4)所示。

$$P(X_1, X_2, \dots, X_m) = \prod_{i=1}^m P(X_i | pa(X_i)) \quad (4)$$

贝叶斯网络的基础是贝叶斯网络的学习, 包括结构学习和参数学习两部分, 当前比较流行的方法是从数据中学习贝叶斯网络。构造贝叶斯网络的主要目的是进行贝叶斯概率推理。

2.1 贝叶斯网络结构学习

贝叶斯网络的结构学习就是在给定数据 D 的条件下, 尽可能结合先验知识, 确定一个与 D 最匹配的有向无环图 G 。结构学习分为模型选择和模型优化两步。模型选择就是选择后验概率 $P(G|D)$ 最大的那个模型, 即

$$G^* = \arg \max_G P(G|D) \quad (5)$$

如果参数先验分布是如下的乘积狄利克雷分布:

$$P(\theta | G) \propto \prod_{i=1}^n \prod_{l=1}^{q_i} \prod_{k=1}^{r_i} \theta_{ijk}^{a_{ijk}-1} \quad (6)$$

那么, 记

$$CH(\langle X_i, pa(X_i) \rangle | D) = \sum_{j=1}^{q_i} \left[\log \frac{\Gamma(a_{ij})}{\Gamma(a_{ij} + m_{ij})} + \sum_{k=1}^{r_i} \log \frac{\Gamma(a_{ijk} + m_{ijk})}{\Gamma(a_{ijk})} \right] \quad (7)$$

为 X_i 的家族 CH 评分。其中, m_{ijk} 是 D 中满足 $X_i = k, Pa(X_i) = j$ 的样本个数, a_{ijk} 表示参数先验分布, $m_{ij} = \sum_{k=1}^{r_i} m_{ijk}, a_{ij} = \sum_{k=1}^{r_i} a_{ijk}$ 。

模型优化即在选定模型评分函数后, 搜索出评分最高的网络结构, 常采用 K2 算法^[11]。K2 算法用一个变量顺序 ρ 和一个正整数 u 来限制搜索空间, 它要寻求的是满足如下两个条件的最优模型 G :

a) G 中任一变量的父节点个数不超过 u ;

b) ρ 是 G 的一个拓扑序。

并且 K2 算法假设所有参数先验分布都是均匀分布, 即参数 a_{ijk} 都是 1。

2.2 贝叶斯网络参数学习

参数学习在统计学中称为参数估计。贝叶斯网络的参数学习就是在已知网络结构的条件下, 通过数据 D 来确定每个节点的条件概率表。

设 $D = \{D_1, D_2, \dots, D_n\}$ 为一组完整数据, 则参数 θ 的对数似然函数为

$$l(\theta | D) = \sum_{i=1}^n \log p(D_i | \theta) = \sum_{i=1}^n \sum_{l=1}^{q_i} \sum_{k=1}^{r_i} m_{ijk} \log \theta_{ijk} \quad (8)$$

其中: m_{ijk} 是数据中满足 $X_i = k, Pa(X_i) = j$ 的样本数量。对于任意固定的 i 和 j , 由于 $\sum_{k=1}^{r_i} \theta_{ijk} = 1$, 故当 θ_{ijk} 取如下的值时,

$$\theta_{ijk}^* = \frac{m_{ijk}}{\sum_{k=1}^{r_i} m_{ijk}} \quad (9)$$

表达式 $\sum_{k=1}^{r_i} m_{ijk} \log \theta_{ijk}$ 的值达到最大, 从而 $l(\theta | D)$ 达到最大。所以式(9)所给出的 θ_{ijk}^* 是 θ_{ijk} 的最大似然估计。

2.3 贝叶斯网络推理

贝叶斯网络推理是指利用贝叶斯网络结构和节点的条件概率分布表, 在给定证据下, 计算查询变量取值的概率。因为贝叶斯网络是对随机变量集合的联合概率分布的图形表示, 所以利用条件概率表可以计算出联合概率分布, 进而就能计算出任意的条件概率。后验概率问题是指已知贝叶斯网络中一些证据变量 E 的取值 e , 计算查询变量 Q 的条件概率取值, 即计算 $p(Q|E=e)$ 。本文利用后验概率问题预测未来跳频频率值。

3 预测原理与步骤

因为相空间重构后过程保持重构相空间与原系统是微分同胚的, 故可以在相空间中研究跳频频率序列的性质及其吸引子。设原始跳频序列为 $\{x_i\}, i = 1, 2, \dots, N, n = N - (M - 1)\tau$, 对未来时刻 $x_{N+1}, x_{N+2}, \dots, x_{N+\eta}$ 的频点值进行预测时, 已有方法主要是利用相空间中当前相点 $X(n) = [x_n, x_{n+\tau}, \dots, x_N]^T$ 通过构造一个映射 $F(\cdot)$ 来预测未来相点 $X(n+l) = [x_{n+l}, x_{n+l+\tau}, \dots, x_{N+l}]^T$ 的值, 使得

$$X(n+l) = F(X(n)) \quad (10)$$

其中: η 为最大预测步长; $l = 1, 2, \dots, \eta$ 。一般将 $F(\cdot)$ 作为多项式函数或者网络拓扑模型。

本文方法认为在将原始跳频序列嵌入到 m 维相空间时, 实质是利用原始序列中的某个跳频点和它在延迟时间 τ 下生成的多个不同延迟点, 共同重构成 m 维相空间中的一个相点。因为时间延迟 τ 的选取要确保这些时延点间相互关联, 故可以利用贝叶斯网络来刻画这种关联性。贝叶斯网络通过构造含有 m 个节点的有向无环图, 把 m 维相空间中各分维之间的相互依赖关系直观地用图形表示, 而且每个节点都具有定量的条件概率分布, 进而利用某些已知频率值的分量通过概率推理求出其余分量的频率值。

对 m 维相空间未来相点 $X(n+l)$ 的预测, 目的是预测该相点的第 m 个分量, 即 x_{N+l} 的值。本文在相空间重构基础上, 提出基于贝叶斯网络的跳频频率预测方法。将相空间全部相点 $X(t) = [x_t, x_{t+\tau}, \dots, n, \dots, x_{t+(m-2)\tau}, x_{t+(m-1)\tau}]^T, t = 1, 2, \dots, n$ 作为

先验数据信息进行贝叶斯网络学习,即将相空间每个相点作为贝叶斯网络的一条完整数据,每个相点的第 i 个分量作为贝叶斯网络的第 i 个节点的一个历史观测值,利用 K2 算法和最大似然估计可以学习得到贝叶斯网络的结构和参数;对于未来相点 $X(n+l)=[x_{n+l},x_{n+l+\tau},\cdots,x_{n+l+(m-1)\tau}]^T,l\leq\eta$,预测目标是第 m 个分量 $x_{n+l+(m-1)\tau}$,故将贝叶斯网络的第 m 个节点 X_m 作为查询变量,前 $m-1$ 个节点作为证据变量 $E(n+l)$,且证据取值为

$$E(n+l)=\{X_1=x_{n+l},X_2=x_{n+l+\tau},\cdots,X_{m-1}=x_{n+l+(m-2)\tau}\}$$

(11)

根据贝叶斯网络后验推理算法,即寻求

$$x_{n+l+(m-1)\tau}=\max_{f_i}p(X_m=f_i|E(n+l))$$

(12)

概率取值最大的 f_i 即为 $x_{n+l+(m-1)\tau}$ 的预测值。将预测出的新相点加入相空间,对贝叶斯网络的参数进行更新学习,以此进行下一个 η 步预测。基于贝叶斯网络的跳频频率预测模型同样具有较高的预测精度。

当 $l=1$ 时,该预测模型为单步预测,当 $l\geq 2$ 时为多步预测。由混沌系统所固有的确定性表明跳频频率是可以预测的,但混沌对初值的敏感性又决定了它的长期不可预测性,所以下面讨论最大预测步数。基于本文上面的分析,若当前相点为 $X(n)=[x_n,x_{n+\tau},\cdots,x_{n+(m-1)\tau}]^T$,则与它相邻的未来相点为

$$\begin{aligned} X(n+1) &= [x_{n+1},x_{n+1+\tau},\cdots,x_{n+1+(m-1)\tau}]^T \\ X(n+2) &= [x_{n+2},x_{n+2+\tau},\cdots,x_{n+2+(m-1)\tau}]^T \\ &\vdots \\ X(n+\tau) &= [x_{n+\tau},x_{n+\tau+\tau},\cdots,x_{n+\tau+(m-1)\tau}]^T \end{aligned}$$

(13)

设跳频频率序列的长度为 N ,最大预测步长为 η ,因为所建模型的证据变量含有 $m-1$ 个节点,故可预测的未来相点 $X(n+l)$ 的第 $m-1$ 个分量下标应小于等于 N ,即

$$N+l-\tau\leq N$$

(14)

故 $\eta=\tau$,所以最大可预测步长为 τ 。

预测模型如图 1 所示。




图1 预测模型

预测模型的具体步骤如下：

a) 利用跳频序列 $\{x_1,x_2,\cdots,x_N\}$ 进行相空间重构。首先按 C-C 方法求出嵌入维数 m 和时间延迟 τ , 以此进行相空间重构, 设重构后的相空间为 X 。

b) 将 X 作为数据集 D , 利用 K2 算法进行贝叶斯网络结构学习。设 $\rho=[X_1,X_2,\cdots,X_m],u=3$, 出发点是一个含有 m 个节点的无边图, 按顺序逐个考察 ρ 中的变量, 确定父节点, 然后添加相应的边。对某一个变量 X_j , 假设已经找到一些父节点 $pa(X_j)$, 如果 $|pa(X_j)|<u$, 则继续为它寻找父节点。具体方法是: (a) 考虑那些在 ρ 中排在 X_j 之前, 但却还不是 X_j 的父节点的变量, 从这些变量中选出 X_i , 使得新家族 CH 评分 $V_{\text{new}}=\text{CH}(\langle X_i,pa(X_j)\cup\{X_i\}\rangle|D)$ 达到最大; (b) 将 V_{new} 与旧家族 CH 评分 $V_{\text{old}}=\text{CH}(\langle X_i,pa(X_j)\rangle|D)$ 比较, 如果 $V_{\text{new}}>V_{\text{old}}$, 则把 X_i

添加为 X_j 的父节点, 否则停止为 X_j 寻找父节点。

c) 令 $l=N,\eta=\tau$, 将 X 作为数据集 D , 利用式 (9) 分别求出每个节点处的条件概率分布表。

d) 令 $k=1$, 输入证据 $E(n+k)=\{X_1=x_{n+k},X_2=x_{n+k+\tau},\cdots,X_{m-1}=x_{n+k+(m-2)\tau}\},n=N-(m-1)\tau,k\leq\eta$, 可以求出最大后验概率 $P(X_m|E(n+k))$ 对应的频点值, 该频点值即为预测的 x_{n+k} 值。 $k=k+1$, 循环步骤 d), 直到 $k=\eta+1$ 。

e) 令 $l=l+\eta$, 若 l 小于 $N+L,X=X\cup X(l+1)\cup X(l+2)\cup\cdots\cup X(l+\eta)$, 返回步骤 c); 否则结束。

4 仿真实验

为了衡量不同模型的预测效果, 将数据归一化处理, 归一化方法为

$$x'_n=[x_n-\min_n(x_n)]/[\max_n(x_n)-\min_n(x_n)]$$

(15)

本文采用均方根误差 (RMSE) 和绝对误差 $e(n)$ 作为模型评价标准。

$$\text{RMSE}=\sqrt{\frac{1}{L}\sum_{i=1}^L(x_n-\hat{x}_n)^2}$$

(16)

$$e(n)=\hat{x}_n-x_n$$

(17)

其中: $x_n,\hat{x}_n$ 和 L 分别表示真实值、预测值和预测的序列长度。

对于 Logistic 映射,

$$x(k+1)=\mu x(k)[1-x(k)]$$

(18)

当参数 $3.57<\mu<4$ 时, 该系统具有混沌特性。取 $\mu=3.7,x(0)=0.1$ 进行迭代, 生成长度为 6 000 的时间序列, 跳过前 1 000 个过渡点, 利用余下 5 000 个数据进行仿真实验。由 C-C 方法可求得延迟时间 $\tau=3$, 嵌入维数 $m=2$, 故可预测的最大步长 $\eta=3$ 。

对于 Lorenz 系统,

$$\begin{cases} dx/dt=\sigma(y-x) \\ dy/dt=(r-z)x-y \\ dz/dt=xy-bz \end{cases}$$

(19)

当参数 $\sigma=10,b=8/3,r=28$, 初始值向量为 $(-1,0,1)$, 系统呈现混沌状态。利用 Euler 法进行迭代求值, 设定步长 $h=0.01$, 产生 7 000 个数据点, 跳过前 1 000 个数据的过渡阶段, 取后面 6 000 个序列样本点进行仿真实验。采用 C-C 方法求得延迟时间 $\tau=12$ 和嵌入维数 $m=3$, 故可预测的最大步长 $\eta=12$ 。

4.1 单步预测仿真

对 Logistic 映射产生的跳频频率序列, 取前 2 500 个数据点作为训练样本集 $D1$, 将其后 100 个频点值作为预测集 $D2$ 进行单步预测。利用重构后的相空间数据进行贝叶斯网络结构学习和参数学习, 并根据贝叶斯网络推理算法对跳频序列进行单步预测。图 2 为单步预测仿真结果, 其中, “o” 表示实际频点值, “*” 表示预测频点值。图 3 为预测结果的绝对误差图。

从图 2 可以看出, 本文所建立的贝叶斯网络预测模型, 在对跳频序列未来时刻频点值进行预测时, 预测结果与真实值吻合率较高, 预测结果的 RMSE 为 0.011 6。由图 3 可知, 模型预测结果的绝对误差数量级为 -2 , 与文献 [12] 是同一个数量级。因此, 该模型可以对跳频频率序列进行有效的单步预测。

4.2 多步预测仿真

以 Lorenz 系统和 Logistic 映射生成的时间序列为例, 取训

练样本集 $D1$ 的数据量大小都为 1 500 条进行多步预测,预测集 $D2$ 为 $D1$ 后面相邻的 100 条数据集。仿真结果如表 1 所示。




图2 单步预测仿真图

图3 单步预测误差图

表 1 多步预测效果统计表

Lorenz 系统		Logistic 映射	
预测步长/步	RMSE	预测步长/步	RMSE
2	0.045 6	1	0.014 1
4	0.059 5		
6	0.060 0		
8	0.166 0		
10	0.302 1	2	0.014 1
12	0.367 5		
		3	0.014 1

根据表 1 数据可知,在一定的预测步长内,模型的预测精度较高。随着预测步长的增大,模型预测能力变差,因为混沌时间序列具有正的最大 Lyapunov 指数,故预测误差会随着预测步长的增大而增大,这也正说明了混沌的长期不可预测性。由表 1 数据可知,当预测步长变化很小时,模型预测精度几乎不变,这是因为应用贝叶斯网络模型进行跳频频率预测时,后验概率推理的基础是从数据中学习到的结构和参数,其中参数学习是基于统计的方法进行的。如果训练样本集 $D1$ 相对于预测步长 l 较大,利用训练样本集 $D1$ 进行参数学习后,再将预测出的新相点 $X(n+1),X(n+2),\cdots,X(n+l)$ 加入 $D1$ 进行参数更新,每个节点处的参数变化是很微小的,所以此时预测步长 l 的微小变化对模型预测精度影响不大。

为了检验该模型对不同数据的稳定程度,对于 Logistic 映射,取训练样本集 $D1$ 的数据量大小固定为 1 500,分别从不同区间段获取三组数据。对训练样本集后面相邻的 100 个频点值进行 2 步预测,预测效果如表 2 所示。

表 2 不同区间段 2 步预测效果统计表

数据区间	1 ~ 1500	2001 ~ 3500	4001 ~ 5500
RMSE	0.0141	0.0132	0.0160

根据表 2 数据可以看出,对于确定的混沌系统,当训练样本集 $D1$ 的数据量大小一定时,对于不同区间段的训练样本集,其预测结果的均方根误差差别非常微小,故基于贝叶斯网络的预测方法可以有效地避免过拟合现象。

5 结束语

本文在相空间重构理论的基础上,通过构建贝叶斯网络模型达到对跳频频率序列预测的目的。该模型克服了局部预测法不能充分利用先验信息以及模型不稳定的缺点,又解决了全局预测法计算复杂度高的缺陷。实验表明该模型能够有效地对跳频频率进行多步预测,并且可以有效地防止过拟合现象。本文提出的方法开辟了跳频频率预测的新途径,在跳频通信领域具有广阔的应用前景。

参考文献:

[1] 郭双冰,肖先赐.几种跳频码混沌学特性及预测分析[J].系统工程与电子技术,2000,22(12):29-32.

[2] FARMER J D, SIDOROWICH J J. Predicting chaotic time series[J]. Physical Review Letters,1997,59(8):845-848.

[3] 李洪涛,郝士琦,王磊.基于混沌理论的跳频通信多步自适应预测[J]. 计算机应用研究,2007,24(3):260-262.

[4] 韩敏.混沌时间序列预测理论与方法[M]. 北京:中国水利水电出版社,2007:159.

[5] MUHAMMAD A F, SAEED Z. Chaotic time series prediction with residual analysis method using hybrid Elman-NARX neural networks[J]. Neurocomputing,2010,73(13-15):2540-2553.

[6] HAN M, WANG Y. Analysis and modeling of multivariate chaotic time series based on neural network[J]. Expert Systems with Applications,2009,36(2):1280-1290.

[7] TAKENS F. Detecting strange attractors in turbulence[C]//Lecture Notes in Mathematics, vol 898. Berlin:Springer,1981:366-381.

[8] 陆振波,蔡志明,姜可宇.基于改进的 C-C 方法的相空间重构参数选择[J]. 系统仿真学报,2007,19(11):2527-2530

[9] YANG You-long, WU Yan. VC dimension and inner product space induced by Bayesian networks[J]. International Journal of Approximate Reasoning,2009,50(7):1036-1045.

[10] 张连文,郭海鹏.贝叶斯网引论[M]. 北京:科学出版社,2006.

[11] COOPER G F, HERSKOVITS E. A bayesian method for the induction of probabilistic networks from data[J]. Machine Learning, 1992,9(4):309-347.

[12] 孟庆芳,张强,牟文英.混沌时间序列多步自适应预测方法[J]. 物理学报,2006,55(4):1666-1667.

下期要目

- ❖ 软件测试用例自动生成算法综述
- ❖ 基于稀疏性的图像去噪综述
- ❖ 移动系统可用性综合研究框架
- ❖ 面向软件可信性的可信指针分析技术综述
- ❖ 分数阶微积分在图像处理中的研究综述
- ❖ 基于网格的计算化学过程可视化
- ❖ 联网审计绩效评价影响因素的灰色关联分析
- ❖ 基于 DE 和 PSO 的混合智能算法及其在模糊 EOQ 模型中的应用
- ❖ 最优子种群遗传算法求解柔性流水车间调度问题
- ❖ 混合整数非线性规划问题的改进差分进化算法

- ❖ 一种改进的克隆函数优化算法
- ❖ 基于细菌觅食优化的盲信号提取算法
- ❖ 网格环境中一种改进的蚁群任务调度算法
- ❖ 粒子滤波算法改进策略研究
- ❖ 复形法粒子群优化算法研究
- ❖ 基于改进小生境粒子群算法的多模函数优化
- ❖ 基于聚类的数据敏感属性匿名保护算法
- ❖ 基于方形对称邻域的局部离群点检测方法
- ❖ 基于频繁项集挖掘算法的改进与研究
- ❖ 基于多核并行的海量数据序列模式挖掘
- ❖ 一种基于语义相似度的群智能文本聚类的新方法
- ❖ 基于混合克隆量子遗传策略的文本特征选择方法