

基于广义窗函数和最小二乘支持向量机的混沌背景下微弱信号检测*

行鸿彦^{1)2)†} 程艳燕¹⁾²⁾ 徐伟¹⁾²⁾

1) (南京信息工程大学, 江苏省气象探测与信息处理重点实验室, 南京 210044)

2) (南京信息工程大学电子与信息工程学院, 南京 210044)

(2011年7月6日收到; 2011年10月14日收到修改稿)

为了从混沌背景中检测微弱信号, 研究分析了复杂非线性系统的相空间重构理论, 提出了一种基于广义窗函数的最小二乘支持向量机的预测法. 该方法以广义嵌入窗为基础, 利用自关联函数法确定 Lorenz 系统的嵌入维数和时间延迟, 实现相空间重构, 结合最小二乘支持向量机建立 Lorenz 系统的误差预测模型, 检测微弱目标信号 (瞬态和周期信号). 仿真实验表明, 该方法的预测模型具有较小的误差, 能够有效地从混沌背景噪声中检测出微弱目标信号, 减小噪声对目标信号的影响. 与传统方法相比, 在降低检测门限的同时, 能够有效地提高预测的精度, 在混沌噪声下信噪比为 -87.41 dB 的情况下, 相对于传统支持向量机方法所得的均方根误差 0.049 (-54.60 dB 时) 降低近两个数量级至 0.000036123 (-87.41 dB 时).

关键词: 嵌入维, 广义时间窗, 相空间重构, 最小二乘支持向量机

PACS: 05.45.Pq

1 引言

混沌是指非线性确定性系统中由于对初值敏感而出现的貌似随机的运动^[1]. 混沌理论与其他学科的交叉性, 使混沌特性与微弱信号检测方面的结合得到了广泛应用, 如医学^[2]、水文^[3]、通信^[4]、海陆目标检测^[5]、工程检测^[6]等. 混沌背景下微弱信号检测是目前信号处理研究的热点之一.

混沌背景下微弱信号检测过程中, 混沌时间序列的建模和预测十分重要, 其基础是 Takens^[7] 提出的相空间重构理论, 即将低维混沌时间序列映射重建到高维空间, 在维持重要因子拓扑不变性的前提下, 进行相空间重构, 而相空间重构的质量对模型的建立和预测有着直接的影响, 重构参数是嵌入维 m 和时间延迟 τ . 其中, 嵌入维数指能够完全包容以状态转移构成的吸引子的最小相空间的维数, 吸引子在该相空间中不能有任何交叠之处^[8]. 重

构时间延迟则指重构时间序列的采样间隔. 现有的相空间重构方法主要有 Grassberger-Procaccia (G-P) 算法^[9]、C-C 法^[10] 和时间窗口法^[11] 等, G-P 算法虽然计算相对简单、收敛较快, 但算法本身所得关联维数会因吸引子的不均匀而产生误差, 而且在无标度区的确定和线性回归计算时易受主观因素影响. 2006 年 Harikrishnan 等^[12] 提出一种用最大范数来代替欧几里得范数的方法, 使得重构参数不受噪声和边界效应的影响. C-C 法计算重构参数具有较高的计算效率, 但在确定嵌入窗窗长时存在对全局极小点依赖性较强的不足, 只适用于处理较小数据点数的混沌时间序列. 2007 年陆振波等^[13] 针对混沌时间序列相空间重构 C-C 法的不足, 提出的改进型 C-C 法所确定的时延与嵌入维数更加准确可靠, 计算速度也有较大提升, 但估计精度存在一定程度的损失. 时间窗口法在给予足够数据的情况下能获取较好的嵌入维数和时间延迟, 但是确定窗

* 国家自然科学基金 (批准号: 61072133) 和江苏省“传感网与现代气象装备”优势学科平台资助的课题.

† E-mail: xinghy@nuist.edu.cn

长大多依靠经验来判断.

混沌背景下微弱信号检测的传统统计方法多采用基于随机理论的信号处理方法, 将背景信号看作随机噪声, 却忽略了混沌内在的物理特性, 使模型的使用受限. 从相空间重构的角度出发, 利用混沌内在特性更有利于在混沌背景下检测微弱目标信号.

国际上, Kenshi 等^[14]研究了利用极为有限的混沌时间序列数据重构其非线性动力系统模型, 为相空间重构在信号检测应用提供了理论基础. 2011年 Diogo 等^[15]采用重现量化分析从随机信号中盲提取混沌信号源, 对某些随机信号具有一定的适用性, 但对微弱信号的检测性能并未进行分析. 在未知动态特性的强混沌杂波背景下, 文献[16]采用重构动态特性和混沌同步方法对微弱目标信号进行估计和检测, 通过选择合适的耦合系数, 可明显地降低检测结果的均方误差.

在国内, 崔万照等^[17]根据混沌动力系统的相空间延迟坐标重构理论, 基于支持向量机强大的非线性映射能力, 建立了混沌时间序列的支持向量机预测模型, 取得了较好的预测结果. 2008年李月等^[18]利用系统对随机噪声信号的免疫性和对微弱周期信号的敏感性, 建立微弱周期信号的定量检测方法, 取得了很好的效果, 但没有研究在混沌背景干扰下的微弱信号检测问题.

2007年我们利用神经网络有效地从混沌背景噪声中检测出微弱瞬态信号和周期信号^[19], 且检测门限较低. 2010年我们针对神经网络存在“过拟合”等限制模型泛化能力的问题, 提出基于小波分解的最小二乘支持向量机预测模型^[20], 通过增加对偶约束项巧妙地改进核函数的参数, 其精度、检测效果比传统径向基函数(RBF)神经网络等有了显著提高. 如何通过有效地重构相空间来提高微弱目标信号检测的效果, 如何利用支持向量机等方法预测混沌时间序列误差, 提高预测的精度和检验效果, 是我们目前的研究重点.

本文将研究基于广义窗函数和最小二乘支持向量机的混沌背景下微弱信号检测, 通过基于广义时间窗的自关联函数法确定 Lorenz 系统的相空间嵌入维 m 和时间延迟 τ 之间的关系, 实现相空间重构, 研究其混沌特征, 利用最小二乘支持向量机建立 Lorenz 系统的误差模型并对时间序列中的目标信号进行预测, 通过设置不同的目标信号进行仿

真验证, 同现有的其他检测方法进行比较, 研究其检测能力.

2 混沌时间序列相空间重构的理论基础

混沌系统由多个自由度来决定, 而实测信息多是一个系统的少数方面而非全部, 往往得到等间隔的单变量时间序列 $\{x_1, x_2, x_3, \dots, x_n\}$, 其中 $t_j = t_0 + j\Delta t, j = 1, 2, \dots, N, x_j = x(t_j)$ 利用单变量时间序列重构相空间, 有利于研究混沌系统. 对于实测时间序列 $\{x_j\}$, 假设原动力系统吸引子维数为 d , 其嵌入维为 m , 重构时间延迟为 τ , 则重构的 N_m 个 d 维向量为 $Y = \{x_j, x_{j+\tau}, x_{j+2\tau}, \dots, x_{j+(d-1)\tau}\}$, 其中 $j = 1, 2, \dots, N_m, N_m = N - (d-1)\tau$. 这 N_m 个 m 维向量在 m 维相空间描述的轨迹可以将混沌吸引子完全展开, 在拓扑等价的情况下恢复出原动力系统.

Takens 定理指出, 相空间轨迹中的每一点存在映射关系

$$Y_{j+\tau} = \Psi(Y_j), \quad (1)$$

相对于 $Y_j, Y_{j+\tau}$ 中只有 $x_{j+d\tau}$ 是新信息, 所以 (1) 式可以改写成

$$x_{j+d\tau} = F([x_j, x_{j+\tau}, x_{j+2\tau}, \dots, x_{j+(d-1)\tau}]). \quad (2)$$

Takens 已证明, 在数据无穷多且无噪声污染时, 若 $m \geq 2d + 1$, 重构的相空间可将原动力系统的拓扑性质保留下来, 但 Takens 定理对于时间延迟的选择未做出说明. 实验研究表明^[21], 时间延迟 τ 过大或过小都会对相空间重构的质量产生影响: 当 τ 过小, 相空间相邻两元素 $x(t_j)$ 与 $x(t_{j+\tau})$ 差异过小时, 重构相空间的吸引子沿相空间主对角线压缩, 即冗余; 当 τ 过大时, 吸引子的动态特性会变得不相关.

3 基于广义窗函数和最小二乘支持向量机的微弱信号检测方法

对于时间序列 $\{x_j\}$, 存在一个合适的延迟 τ , 使得在重构相空间中的系统轨迹既无压缩也不折叠. 重构相空间中任意两个坐标的延迟时间与广义

嵌入窗长 Γ 的差值之和 [22] 为

$$J = \sum_{k=1}^{m-1} C_{m-k}^1(k\tau - \Gamma), \quad (3)$$

鉴于系统稳定性, 从方差角度考虑, 在 $J = 0$ 的基础上, 方差越小, 所得重构系统也就越稳定, 即

$$\sigma^2 = \sum_{k=1}^{m-1} \left\{ \left[\sum_{k=1}^{m-1} C_{m-k}^1(k\tau - \Gamma) - \frac{1}{C_{m-1}^2} \sum_{k=1}^{m-1} C_{m-k}^1(k\tau - \Gamma) \right]^2 \right\}. \quad (4)$$

当 $\sigma^2 = 0$ 时, m, τ 与 Γ 之间的关系更为合理.

$$\sum_{k=1}^{m-1} \left(\frac{m^2(m-3)[(m+1)\tau - 3\Gamma]^2}{6(m-2)} \right) = 0, \quad (5)$$

进而推得

$$\frac{m^4(m-3)^2[(m+1)\tau - 3\Gamma]^2}{36(m-2)^2}(m-1) = 0, \quad (6)$$

化简知 $m = 0, 1, 3$ 或 $J = 0$ 时, 最为合理. 在一般情况下, $m > 3$, 故 $J = 0$ 为最优, 可得

$$\Gamma = \frac{m+1}{3}\tau. \quad (7)$$

自关联函数 [22]

$$c(\Gamma) = \frac{\sum_{k=0}^N [x(t_0 + (k+1)\Gamma) - x_a][x(t_0 + k\Gamma) - x_a]}{\sum_{k=0}^N [x(t_0 + k\Gamma) - x_a]^2} \quad (8)$$

其中 $x_a = \frac{1}{N} \sum_{k=1}^N x(t_0 + k\Gamma)$. 当 $c(\Gamma) = 0.707$ 时, Γ 为最佳窗长, 此时, m 和 τ 的最佳关系得以确定.

支持向量机 (support vector machines, 简记为 SVM) 具有最小化模型的结构风险, 从而提高模型泛化能力的优点, 其扩展最小二乘支持向量机 (least square support vector machine, 简记为 LS-SVM) 逐步应用在混沌时间序列预测方面, 本文在其改进重构模型的基础上进行信号检测. 模型的复杂程度取决于支持向量的数目, 而非样本空间的维数, 但维数与一些周期的消失和分叉有关 [23].

有训练集 $S = \{(x_i, y_i) | i = 1, 2, \dots, N\}$, 其中 $x_i \in R_n, y_i \in R$, 训练样本数为 N , 根据结构风险化最小原理将回归问题归结为一个约束优化问题.

$$\min_{w, b, \xi} J(w, \xi) = \frac{1}{2}w^T w + \frac{\gamma}{2} \sum_{i=1}^l \xi_i^2,$$

约束条件

$$y_i = w^T \varphi(x_i) + b + \xi_i, i = 1, 2, \dots, l, \quad (9)$$

其中, $\varphi(\bullet)$ 为核空间的映射函数; 偏差量 $b \in R$; 可调参数 $\gamma \in R$; 权向量 $w \in R_n$; 误差变量 $\xi_i \in R$.

建立 Lagrange 函数

$$L(w, b, \xi_i, \alpha) = J(w, \xi) - \sum_{i=1}^l \alpha_i (w^T \varphi(x_i) + b + \xi_i - y_i), \quad (10)$$

其中, $\alpha_i \in R$ 为 Lagrange 乘子. 根据 KKT (Karush-Kuhn-Tucker) 条件知

$$\frac{\partial L}{\partial w} = 0; \frac{\partial L}{\partial \xi_i} = 0; \frac{\partial L}{\partial b} = 0; \frac{\partial L}{\partial \alpha_i} = 0, \quad (11)$$

消去变量 ξ_i 和 w , 得到线性方程组

$$\begin{bmatrix} 0 & I^T \\ I & \Omega + \frac{1}{\gamma} I \end{bmatrix} \begin{bmatrix} b \\ a \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix}. \quad (12)$$

符合 Mercer 条件的对称函数可作为核函数, 本文选择 RBF 作为核函数来建立 SVM 回归模型, 使用的 RBF 和回归函数分别如下:

$$K(x_i, x_j) = \exp \left(-\frac{\|x_i - x_j\|^2}{\sigma^2} \right), \quad (13)$$

$$y_i = \sum_{i=1}^l \alpha_i K(x_i, x_j) + b. \quad (14)$$

调节可调参数 γ 和径向基核函数中的 σ 来确定 LS-SVM 模型. 将实际得到的时间序列与模型预测出的理想时间序列进行对比求差, 用频谱分析法等分析预测误差, 进行门限比较来确定是否存在目标信号.

4 仿真实验

合适的广义嵌入窗长 Γ 对应的相轨迹既不折叠也不压缩, 根据 m, τ 与 Γ 之间的关系式 (7) 可以重构出质量较好的相空间, 基于 LS-SVM 的微弱信号检测模型的基本实验步骤如下:

1) 利用广义时间窗法确定广义嵌入窗长 Γ , 根据 m, τ 与 Γ 之间的关系式 (7), 确定合适的嵌入维 m 和时间延迟 τ , 利用 (2) 式重构相空间, 并验证空间的合理性;

2) 建立目标信号与混沌背景信号, 选取合适的实验数据, 分为训练数据和测试数据来训练模型;

3) 通过模型仿真得到理想数据与实际数据的拟合图, 进一步得到误差的幅值图形;

4) 对误差幅值进行分析, 明显异于其他误差处则会存在目标信号, 从而达到检测的目的.

4.1 广义嵌入窗长的确定

首先采用典型的 Lorenz 混沌模型进行仿真研究. Lorenz 方程为

$$\begin{aligned} \dot{x} &= \sigma(y - x), \\ \dot{y} &= -xz + cx - y, \\ \dot{z} &= xy - bz, \end{aligned} \quad (15)$$

其中, $\sigma = 16, b = 4.0, c = 45.92$. 初始值取 $x = 10, y = 1, z = 0$.

通过 FractalFox2.0 软件对原始动力系统进行维数计算得到 $d = 2.03$, 故 $m \geq 5$. 取 $m = 5$, 计算广义嵌入窗长 Γ , 仿真结果如图 1.

从对自关联函数的做图过程中, 可知步长越小, 曲线越平滑; 步长越大, 曲线波动越大. 但为了使 $c(\Gamma)$ 最大限度地接近零, 只能选择较为平衡的值, 如图 1 中标记处, 当取 $\Gamma = 115$ 时, $c(\Gamma) = 0.0030$. 此时, $c(\Gamma)$ 是使 $x(t)$ 与 $x(t + \Gamma)$ 为线性无关的最小值.




图 1 自关联函数图

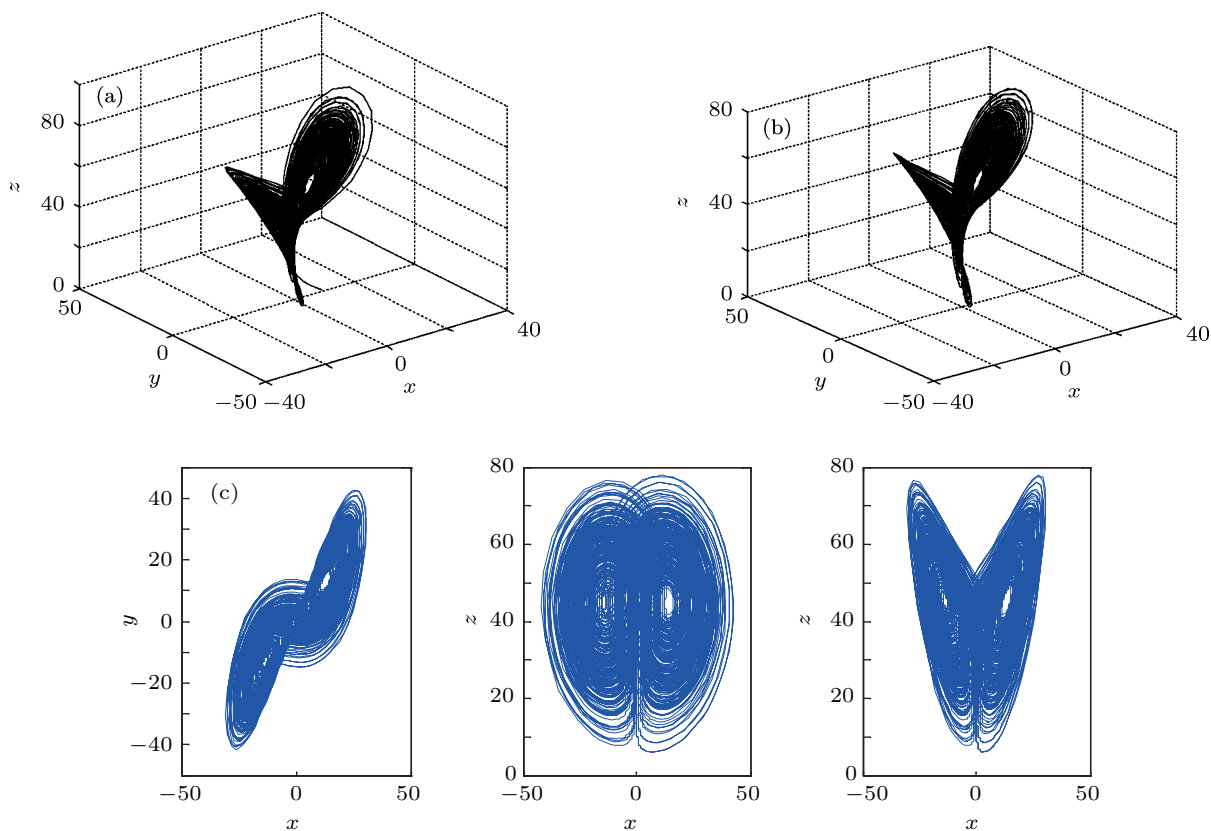


图 2 重构图形 (a) 原始的吸引子图形; (b) 重构的吸引子图形; (c) 重构的 Lorenz 吸引子在各个方向上的投影

4.2 混沌信号的获取

根据 (7) 式确定 $m = 5, \tau = 57$. 在此条件下, 进行相空间重构, 重构结果如图 2(b) 所示, 各个平面上的投影如图 2(c).

对比图 2(a), (b) 可知, 重构效果较好, 图 2(c) 则从各个方向上的投影进一步直观显示出重构效果. 图 2 说明重构吸引子能够有效地反映出原吸引子的特性.

用步长为 0.01 的四阶 Runge-Kutta 法求解方程 (15), 取其 x 分量作为时延混沌信号, 观测 17000 个观测点, 记为 $\{x(n)|n = 1, 2, \dots, 17000\}$, 为确保系统完全进入混沌, 取 3000 点以后的点, 将序列长度为 2000 的实验数据用于训练混沌预测模型.




图 3 获取数据 (a) X 方向上的幅值; (b) 归一化的 X 方向上的幅值

图 3 中截取了混沌信号的有效实验数据, 如图 3(a), 为了方便使用 LS-SVM 对数据进行处理, 预先将数据进行归一化处理, 如图 3(b).

4.3 LS-SVM 模型的训练及预测的误差

将原始混沌信号输入 LS-SVM 训练的模型, 得

到相应的训练结果.

图 4 中是没有目标信号时通过 LS-SVM 对输入数据进行训练, 输出的预测数据与理想数据的拟合较为理想.




图 4 理想数据与实际数据图 其中 Xt 代表不含目标信号的混沌时间序列 (以下简称为理想数据), Yt 代表包含目标信号的混合信号时间序列 (以下简称实际数据) 以下图中均同




图 5 理论理想实验结果 (a) 误差幅值图; (b) 理想数据与实际数据图

在调整参数过程中可以发现, LS-SVM 是通过支持向量机构造推理模型, 因此对因子数量没有

明显限制^[1]. 由于所受影响因素较少, 主要参数为 LS-SVM 的正则参数 γ 和内核参数的平方带宽 σ^2 , 采用单纯性搜索方法和迭代重加权方法结合起来对参数进行调整, 初步判断预测的最理想参数为 $\gamma = 14351509143.8339$, $\sigma^2 = 749.90673979757$.

在图 5(a) 中, 可以较为清晰地判断目标信号的存在, 但是图 5(b) 中实际数据与理想数据的拟合在整体上出现了明显偏差, 约在 50 点处开始出现偏差且影响逐渐增大. 已知目标信号为微弱信号, 且混沌系统具有一定抗噪性能, 不应在整体上对系统产生过大影响, 故继续调节 γ 和 σ^2 以达到合理状态.




图 6 $\gamma = 10^8, \sigma^2 = 100$ 时的测试结果 (a) 误差幅值图; (b) 理想数据与实际数据图

在理想数据的前提下, 图 6 将参数调节为 $\gamma = 10^8, \sigma^2 = 100$, 在维持误差确定的同时, 理想数据与

实际数据差异有所改善, 进一步降低正则参数和内核参数的平方带宽至 $\gamma = 10^7, \sigma^2 = 10$, 除了能维持误差位置的判断, 还能较好地拟合理想数据与实际数据. 图 7 和图 8 对比发现, 降低内核参数的平方带宽后, 图 8 虽然能够很好地拟合理想数据与实际数据, 但是误差具体位置的确定, 尤其是前端位置较为模糊. 图 7 和图 9 对比发现, 降低正则参数后, 图 9 虽然能够进一步提高理想数据与实际数据的拟合程度, 但是无法确定误差的具体位置且对误差存在性的判定也受到了阻碍.




图 7 $\gamma = 10^7, \sigma^2 = 10$ 时的测试结果 (a) 误差幅值图; (b) 理想数据与实际数据图

经过参数调节和对比分析, 可确定 $\gamma = 10^7, \sigma^2 = 10$ 为较理想的参数. 根据误差幅值, 可以观察到在 200 点到 250 点之间误差幅值特别大, 由此判断确实存在目标信号.

表 1 混沌序列预测模型性能对比

	本文	对偶约束 LS-SVM ^[20]	LS-SVM ^[20]	SVM ^[20]	RBF 神经网络 ^[20]
SNR/dB	-87.41	-71.33	-62.82	-54.60	-30.20
RMSE	0.000036123	0.0080	0.022	0.049	0.058




图8 $\gamma = 10^7, \sigma^2 = 1$ 时的测试结果 (a) 误差幅值图; (b) 理想数据与实际数据图




图9 $\gamma = 10^6, \sigma^2 = 10$ 时的测试结果 (a) 误差幅值图; (b) 理想数据与实际数据图

同理可用于微弱正弦信号的检测. 设微弱正弦信号 $s(n) = 0.005 \sin(2\pi fn)$, 归一化频率为 0.3, 微弱正弦信号对混沌背景混合信号的信噪比 (SNR) 为 -79.8418 dB, 经过相空间重构后, 用 LS-SVM 进行预测, 设置正则参数 $\gamma = 100000$, 内核参数的平方带宽 $\sigma^2 = 1$, 得到预测结果的均方根误差 (RMSE) 为 7.3240×10^{-5} (见表 1). 根据误差幅值, 可以观察到相较于瞬态信号, 正弦信号的误差比较大, 大致可以观察到约在 100 点到 2300 点之间误差幅值特别大 (如图 10), 由此判断目标信号确实存在, 但具体位置无法确定.

对于 LS-SVM 的参数设置, 虽然仿真所得的理想参数对于误差幅值的确定比较准确, 但是对模型的理想数据与预测数据的拟合而言, 正则参数 $\gamma = 100000$, 内核参数的平方带宽 $\sigma^2 = 1$ 已经比较准确 (如图 11(a)), 而此时误差幅度在目标信号处不明显 (如图 11(b)), 对误差 $err(n)$ 进行快速 Fourier 变换 [24], 利用文献 [19] 中的方法计算误差幅值频谱图, 可在幅频图横轴 0.3 处出现最高峰值, 由此判定误差, 如图 11(c), 进而检测出目




图10 $\gamma = 100000, \sigma^2 = 1$ 时的误差幅值图

标信号.

图 11 中 $\gamma = 100000, \sigma^2 = 1$ 时, 通过 LS-SVM 预测得出的数据与实际数据拟合较好 (如图 11(a)), 但是在 0 至 1300 点之间误差起始的具体位置却难以界定 (如图 11(b)), 通过幅频变换可确定归一化频率的具体位置 (如图 11(c)).

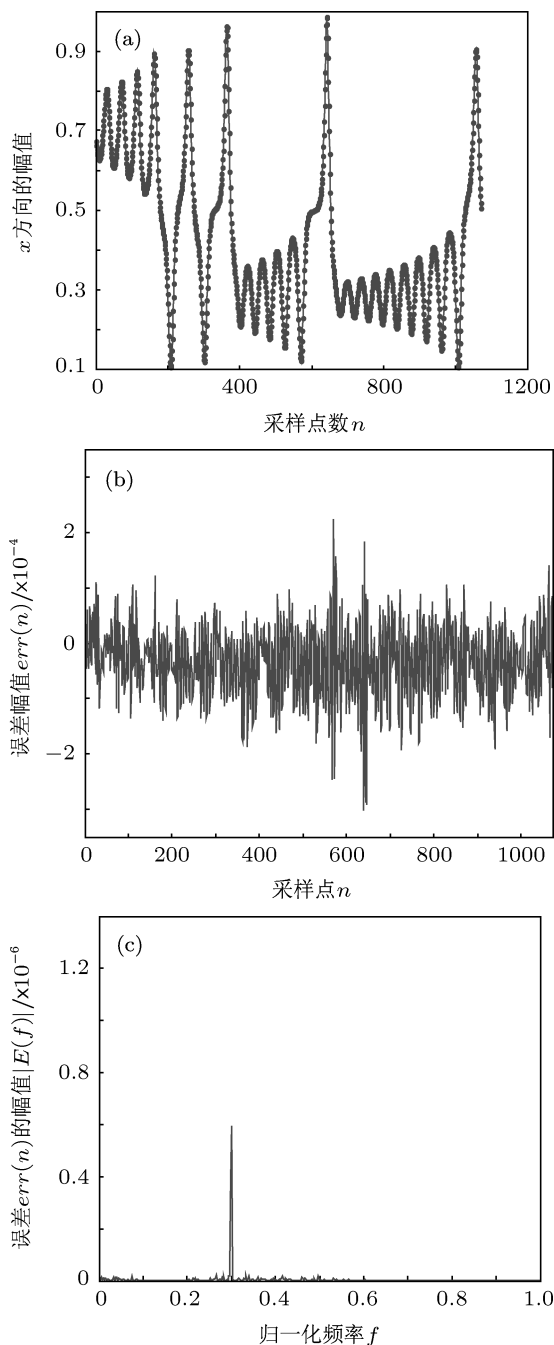


图 11 Lorenz 系统测试结果 (a) LS-SVM 系统拟合图; (b) 误差幅值图; (c) 误差幅值频谱图

为进一步验证模型的有效性, 采用 Chen's 系统作为验证模型. 虽然 Chen's 系统和 Lorenz 系统在形式上相似, 但两者有本质区别, 且前者在工程应用上具有更广泛的前景 [25].

$$\begin{aligned} \dot{x} &= a(y - x), \\ \dot{y} &= (c - a)x - xz + cy, \\ \dot{z} &= xy - bz, \end{aligned} \quad (16)$$

其中, $a = 35, b = 3, c = 28$. 采用广义窗函数法确定嵌入维和时间延迟 $m = 6, \tau = 51$. 在 100 点到 150

点之间于混沌信号 $x(n)$ 上叠加一个幅值为 0.005 的微弱瞬态信号 $s(n)$, 此时瞬态信号对混沌背景混合信号 SNR 为 -90.5270 dB, 得到预测结果 RMSE 为 2.22388×10^{-5} , 说明检测性能较高, 更有利于检测出目标信号.




图 12 Chen's 系统验证结果 (a) LS-SVM 系统拟合图; (b) $\gamma = 100000, \sigma^2 = 1$ 时误差幅值频谱图; (c) $\gamma = 1.5049 \times 10^7, \sigma^2 = 3.6953 \times 10^6$ 时误差幅值频谱图

图 12(a) 可知广义窗函数和 LS-SVM 相结合的方法仍然可以使得预测数据与理想数据较好地拟合, 从图 12(b) 中可以看到, 在目标信号存在部分

的误差幅值明显高于其他位置, 经过模型参数调节, 当 $\gamma = 1.5049 \times 10^7$, $\sigma^2 = 3.6953 \times 10^6$ 时, 可以确定在 100 到 150 点之间存在目标信号. 通过对 Chen's 混沌系统的仿真, 进一步验证了基于广义窗函数和 LS-SVM 的微弱信号检测方法的有效性, 说明模型具有一定的普适性, 对于处理实际问题将更加灵活.

5 结论

根据混沌时间序列相空间重构及其局部可预测的特性, 本文利用基于广义嵌入窗的自关联函数确定最优嵌入维数和时间延迟来重构混沌系统的相空间, 进一步利用混沌系统可短期预测的特点, 采用 LS-SVM 法预测混沌序列, 从而实现微弱目标信号的检测.

在相空间中, 将参数聚焦于正则化参数和核函数的平方带宽, 采用通过核函数将样本空间映射

到高维特征空间的非线性分析方法——最小二乘支持向量机建立单步预测模型, 并且将在混沌背景中的微弱目标信号检测转换成从误差幅值中分析并确定目标信号的存在. 以 Lorenz 混沌系统作为背景, 分别以瞬态和周期信号作为目标信号进行仿真实验, 经过分析表明该方法能够很好地检测出目标信号、检测门限较低, 而且模型的 RMSE 比传统 RBF 神经网络和 LS-SVM 方法提高了近 2 个量级, 还可以根据不同目标信号灵活地调整正则参数和内核参数的平方带宽, 并结合实际信号情况的反馈调整至适合模型. 使用 Chen's 混沌系统进行验证和分析, 在一定程度上提高了预测模型的普适性, 更好地逼近混沌系统的实际物理过程, 提高预测精度和微弱信号检测效果.

在实际混合信号中除较强的混沌背景信号、微弱目标信号外, 还常含有白噪声, 因此下一步工作将重点研究白噪声等对系统的影响, 提高系统的抗干扰能力, 便于实际应用.

-
- [1] Dai S Q, Deng X J, Duan Z P 2001 *Advances in Mechanics* **31** 323 (in Chinese) [戴世强, 邓学姜, 段祝平 2001 力学进展 **31** 323324]
- [2] Li X Q, Deng Z D 2009 *ICBME 2008. Proceedings* **23** 390
- [3] Wang H P, Wang L M, Wan C L 2010 *Ship Electronic Engineering* **30** 167 (in Chinese) [王红萍, 王黎明, 万程亮 2010 舰船电子工程 **30** 167]
- [4] Kao J W, Berber S M, Kecman V 2010 *16th Asia-Pacific Conference on Communications* (APCC) 215
- [5] Lampropoulos G A, Leung H 2000 *IEEE International Radar Conference* 404
- [6] Wang Y N, Liu L J, Zhou B W, Zhang H 2010 *Chin. J. Sci. Instrum.* **31** 410 (in Chinese) [王耀南, 刘良江, 周博文, 张辉 2010 仪器仪表学报 **31** 410]
- [7] Takens F 1981 *Lecture Notes in Mathematics* **898** 366
- [8] Zhang S Q, Jia J, Gao M, Han S 2010 *Acta Phys. Sin.* **59** 1576 (in Chinese) [张淑清, 贾健, 高敏, 韩叙 2010 物理学报 **59** 1576]
- [9] Grassberger P, Procaccia I 1983 *Phys. Rev. Lett.* **50** 346
- [10] Kim H S, Eykholt R, Sales J D 1999 *Physica D* **127** 4850
- [11] Kugiumtzis D 1996 *Physica D* **95** 1328
- [12] Harikrishnan K P, Misra R, Ambika G, Kembhaviv A K 2006 *Physica D: Nonlinear Phenomena* **215** 137
- [13] Lu Z B, Cai Z M, Jiang K Y 2007 *J. Sys. Simul.* **19** 2528 (in Chinese) [陆振波, 蔡志明, 姜可宇 2007 系统仿真学报 **19** 2528]
- [14] Kenshi S, Yuko N, Shinichi A 2008 *Chaos, Solitons and Fractals* **38** 1274
- [15] Diogo C S, Ricardo S, Romis A 2011 *Digital Signal Processing* **21** 417
- [16] Kurian A P, Leung H 2009 *IEEE Trans. Cir. Sys.-I: Regular Papers* **56** 820
- [17] Cui W Z, Zhu C C, Bao W X, Liu J H 2004 *Acta Phys. Sin.* **53** 3303 (in Chinese) [崔万照, 朱长纯, 保文星, 刘君华 2004 物理学报 **53** 3303]
- [18] Li Y, Xu K, Yang B J, Yuan Y, Wu Y 2008 *Acta Phys. Sin.* **57** 3353 (in Chinese) [李月, 徐凯, 杨宝俊, 袁野, 吴宁 2008 物理学报 **57** 3353]
- [19] Xing H Y, Xu W 2007 *Acta Phys. Sin.* **56** 3773 (in Chinese) [行鸿彦, 徐伟 2007 物理学报 **56** 3773]
- [20] Xing H Y, Jin T L 2010 *Acta Phys. Sin.* **59** 143 (in Chinese) [行鸿彦, 金天力 2010 物理学报 **59** 143]
- [21] Xiao F H, Yan G R, Han Y H 2005 *Acta Phys. Sin.* **54** 550 (in Chinese) [肖方红, 阎桂荣, 韩宇航 2005 物理学报 **54** 550]
- [22] Xiu C B, Liu X D, Zhang Y H 2003 *Trans. Beijing Institute Technol.* **23** 219 (in Chinese) [修春波, 刘向东, 张宇河 2003 北京理工大学学报 **23** 219]
- [23] Xu J, Long K P, Rournier P D, Taha A K, Charge P 2010 *Chin. Phys. Lett.* **27** 080506
- [24] Yang S Q, Jia C Y 2002 *Acta Phys. Sin.* **51** 2454 (in Chinese) [杨绍清, 贾传炎 2002 物理学报 **51** 2454]
- [25] Wang M J, Zeng Y C, Chen G H, He J 2011 *Acta Phys. Sin.* **60** 010509 (in Chinese) [王梦蛟, 曾以成, 陈光辉, 贺娟 2011 物理学报 **60** 010509]

Detection of weak target signal with least-squares support vector machine and generalized embedding windows under chaotic background*

Xing Hong-Yan¹⁾²⁾ Cheng Yan-Yan^{1)2)†} Xu Wei¹⁾²⁾

1) (*Jiangsu Key Laboratory of Meteorological Observation and Information Processing,*

Nanjing University of Information Science and Technology, Nanjing 210044, China)

2) (*College of Electronic and Information Engineering, Nanjing University of Information Science and Technology, Nanjing 210044, China*)

(Received 6 July 2011; revised manuscript received 14 October 2011)

Abstract

To extract weak signal from the chaotic background, in this paper we analyze the theory of state space reconstruction of complicated nonlinear system, and put forward an estimation method utilizing the least-squares support vector machine (LS-SVM) based on a generalized window function. In the algorithm the generalized embedded window is taken as a foundation and the correlation function method is used to determine the embedded dimension and time delay of Lorenz system and so the state space reconstruction is realized and by combining the error forecasting model in which the LS-SVM is used to estimate the errors, the detection of the weak target signal, such as transient and periodic signal, is achieved. It is illustrated in the simulation experiments that the model proposed can detect the weak signals effectively from a chaotic background and reduce the influence of noise on the target signals, which possesses minor forecasting error. Compared with those conventional methods, this method has a remarkable advantage in reducing detection threshold and improving the accuracy of prediction. When the signal-to-noise ratio is -87.41 dB in the chaotic noise background, the new method can reduce the root mean square error nearly two orders of magnitude, reach 0.000036123, while the traditional SVM can only reach 0.049 under the condition of -54.60 dB.

Keywords: embedding dimension, generalized window, state space reconstruction, least-squares support vector machine

PACS: 05.45.Pq

* Project supported by the National Natural Science Foundation of China (Grant No. 61072133) and the Jiangsu Sensor Network and Modern Meteorological Equipment Preponderant Discipline Platform.

† E-mail: xinghy@nuist.edu.cn