

文章编号:1001-9081(2010)11-2956-03

基于稀疏表示的数据流异常数据预测方法

徐雪松¹, 李玲娟¹, 郭立玮²

(1. 南京中医药大学 信息技术学院, 南京 210046; 2. 南京中医药大学 中医药研究院, 南京 210046)

(xxs105@yahoo.cn)

摘要:为了提高数据流中异常数据的预测速度与精度,提出一种基于稀疏表示的数据流异常数据预测方法。结合了小波噪声检测方法,采用新近发展起来的稀疏表示工具,对含有异常数据的数据流进行小波变换,并得到一组小波系数,然后对这些系数建立稀疏表示模型。引入随机测量矩阵对小波系数进行变换,恢复小波系数的稀疏性达到预测异常数据的目的。仿真结果表明,在一定条件下该方法可获得相当好的预测效果。

关键词:数据流; 异常数据预测; 稀疏表示; 小波变换

中图分类号: TP311.13 文献标志码:A

Prediction method for outliers over data stream based on sparse representation

XU Xue-song¹, LI Ling-juan¹, GUO Li-wei²

(1. College of Information Technology, Nanjing University of Chinese Medicine, Nanjing Jiangsu 210046, China;

2. Research Institute of Chinese Medicine, Nanjing University of Chinese Medicine, Nanjing Jiangsu 210046, China)

Abstract: This paper proposed a new prediction method for outliers over data stream based on sparse representation to improve the optimum prediction speed and performance of outliers over data stream. Combining the wavelet noise detection method, using newly developed tools for sparse representation, a transformation method for outliers over data stream was proposed. In order to identify outliers, the introduction of random measurement matrix of wavelet transform coefficients was applied with sparse representation to forecast data value in the future timestamp. The simulation results on actual data source show that this method can provide precise instantaneous detection under certain conditions.

Key words: data stream; outliers prediction; sparse representation; wavelet transform

0 引言

近年来,几乎所有应用中的数据流都不可避免地包含有异常源,由于数据流的无限性,无法物化整个数据流,需要一遍扫描算法^[1],而且越来越多的数据流应用都需要及时地对任务进行处理,以获得尽可能短的响应时间,因此数据流上异常数据的预测需要简单高效的在线处理方法。文献[2]提出的特征选择方法和文献[3]提出的数据挖掘方法不适合实时监测和识别数据流中的异常数据的变化;文献[4]提出的小波奇异性预测方法和文献[5]提出的神经网络方法需要训练的数据量太大,运算代价高,并且对实时预测有较大影响;文献[6]将数据流值过大变化率作为奇异数据的判定依据,此法仅能判断一步数据流的变化,未包括最近数据流变化的状态,虽然计算复杂度低,但不适合大量或超大量数据流的应用,且检测精度有限。

为此,本文提出一种基于稀疏表示的数据流异常数据预测的方法,引入稀疏表示技术,旨在真实估计重要小波系数但不丢失重要信息,将异常数据预测归结为如下求解极值问题,该方法在计算效率和还原精度上可获得相当好的预测效果。

1 问题定义

1.1 数据流类型

本文主要研究时间序列类型数据流,在这种数据流中,数

据点是按照下标*i*的排序出现;以升序为例,每一个新到数据点的*i*值都比以前的数据点的*i*值大。典型时间序列类型数据流中的数据点是形如(时间戳,值)的二元组。网络流量监测数据是每隔一定时间进行采样获得的当前流量统计值,所以网络流量数据就是这种类型的数据流。

1.2 窗口模型

异常检测算法能够处理的数据流模型根据不同的时序范围可以划分成多种子模型,包括界标模型(Landmark Model)、滑动窗口模型(Sliding Window Model)和快照模型(Snapshot Model)^[7]。

在多数数据流预测应用中,预测步长一般远大于数据流中相邻两个数据项之间的采样间隔,预测步长越短(极端情况为预测下一个采样时刻的流值),总体的预测信息越丰富,但其计算代价也就越大。因此,为了降低计算代价,本文引入滑动窗口结构。这种窗口模式为:两个滑动端点(当新项目到达时,或者向前或者向后替换掉旧的项目)定义一个滑动窗口,即滑动窗口模型仅关心数据流中最新的W(W也称为滑动窗口大小)个数据,其查询范围是($I_{\max}(n-W+1, 0), \dots, I_n$),随着数据不断到达,窗口中的数据也不断平移。这样可以满足实时数据流一次扫描且猝发式到达的特点。在实际应用中,不可能预先限制要检测的最大的滑动窗口数目,以及被检测的最大滑动窗口的长度,具体数据要根据选用的数据集计算得出。

收稿日期:2010-05-19;修回日期:2010-07-21。 基金项目:国家自然科学基金资助项目(30873449)。

作者简介:徐雪松(1975-),男,江苏南京人,讲师,博士,主要研究方向:离群数据挖掘、信息安全;李玲娟(1967-),女,陕西宝鸡人,副教授,主要研究方向:数据挖掘、机器学习;郭立玮(1948-),男,福建闽清人,教授,博士生导师,主要研究方向:中药制剂、生物药剂学、制药工程。

1.3 概要数据结构

数据流上的异常数据预测常用的概要数据结构为小波。在小波分析方法中, 少数几个小波参数就拥有大部分能量^[8], 根据这个特性, 可以选择少数小波参数, 近似还原原始信号。小波分析方法也被应用于数据库领域。

2 基于稀疏表示的数据流异常数据预测模型

针对时间序列类型数据流, 在实际应用中, 设含有异常数据的数据流观测数据表示如下:

$$f(k) = s(k) + n(k) \quad (1)$$

其中: $f(k)$ 为数据流观测数据, $s(k)$ 为无异常数据的数据流数据, $n(k)$ 含有异常数据且服从正态分布 $N(0, \sigma^2)$ 。设 $\omega_{j,k}$ 为观测数据流对应的小波系数, $j(j=1, \dots, J)$ 为尺度因子, $k=1, \dots, U$ 为时间。

对于正常的数据流观测值, 选择适当小波基, 其小波变换后能够得到稀疏的小波系数。若数据流观测值中含有异常数据, 其小波系数的稀疏性会大大降低, 由此引入随机测量矩阵对小波系数进行变换, 恢复小波系数的稀疏性达到预测异常数据的目的, 在变换过程中小波分解尺度需限制在一定范围内, 因为小波系数沿着小波分解尺度具有很强的相关性, 小波分解的尺度越大, 信号的分辨率越高; 但在用小波变换求解异常数据小波系数时, 如果小波分解的尺度选择过大, 并不能明显的提高预测效果, 反而会增大计算量, 而小波分解尺度如果选择过小, 就不能有效地还原数据, 在算法中为异常数据量设置上限阈值 ε 。

首先给出稀疏表示中的随机测量矩阵 $\Phi_{M,N} (M < N)$, 作为一个基本要求, 略去 $\omega_{j,k}$ 的下标 j 和 k , 这样可以从小波系数的整体结构特性去处理异常数据。令 ω 表示给定尺度上 N 小为 $N \times 1$ 的列向量, Φ 满足一致不确定原理 (Uniform Uncertainty Principle, UUP)^[9], 即对于任意 $S (S \leq M \lg N)$ 和稀疏向量 z :

$$0.8 \frac{M}{N} \| z \|_2^2 \leq \| \Phi z \|_2^2 \leq 1.2 \frac{M}{N} \| z \|_2^2 \quad (2)$$

设 $y = \Phi\omega$, 这样可以通过式(3) 得到稀疏表示的最大系数向量 $\bar{\omega}$:

$$\bar{\omega} = \arg \max(\| y - \Phi z \|_2^2 + \gamma \| z \|_0) \quad (3)$$

其中: $\| \cdot \|_0$ 为零范数, 表示非零元素的个数。对于式(3), 本文将验证在某种条件下能够得到唯一解, 且是无偏的, 该无偏估计值为预测的数据流中对应的异常向量。

令 ω' 表示无异常小波系数, ω_n 是含有异常数据的数据流 $n(k)$ 对应的小波系数, 两者相加得数据流观测值的小波系数, 表示为 $\omega = \omega' + \omega_n$ 。由于 $n(k)$ 服从正态分布, ω_n 也服从零均值 Gauss 分布, 因此得:

$$y = \Phi\omega = \Phi(\omega' + \omega_n) = \Phi\omega' + \Phi\omega_n \quad (4)$$

记:

$$g(z) = \| y - \Phi z \|_2^2 + \gamma \| z \|_0 \quad (5)$$

对于任意的 $u \neq \omega_n$, 可以验证 $E(g(u)) < E(g(\omega_n))$, 即 $E(g(\bar{\omega})) = \omega_n$ 。

引入随机矩阵 Φ , 其元素服从高斯分布, 联立式(4) ~ (5) 可得:

$$\begin{aligned} g(u) - g(\omega_n) &= (\| y - \Phi u \|_2^2 - \| y - \Phi \omega_n \|_2^2 + \\ &\quad \gamma (\| u \|_0 - \| \omega_n \|_0) = \\ &= (\| \Phi(\omega_n - u) \|_2^2 + 2[\Phi(\omega_n - u)]^\top \Phi \omega_n) + \\ &\quad \gamma (\| u \|_0 - \| \omega_n \|_0) \end{aligned} \quad (6)$$

令 $\Phi(\omega_n - u)$ 和 $\Phi\omega_n$ 独立, 则式(7) 成立:

$$\begin{aligned} E(g(u) - g(\omega_n)) &= E(\| \Phi(\omega_n - u) \|_2^2 + \\ &\quad \gamma E(\| u \|_0 - \| \omega_n \|_0)) \end{aligned} \quad (7)$$

对任意 $\omega_n \neq u$, 可得 $E(g(\omega_n) - g(u)) > 0$, 且由式(3) 可知 $\bar{\omega} = \text{argmax}_z g(z)$, 所以 $E(g(\bar{\omega})) = \omega_n$ 。

3 预测模型的局部最大解

将式(5) 等式右侧第一项记为 $g_1(z)$, 则 $g_1(z)$ 的最大值可由下式求偏导数得:

$$\frac{\partial g_1(z)}{\partial z} = -2 \Phi^T(y - \Phi z) = 0 \quad (8)$$

用系数向量代替 z 得:

$$\omega^{(t+1)} = \omega^{(t)} + \mu \Phi^T(y - \Phi \omega^{(t)}) \quad (9)$$

其中 $\mu > 0$ 是一个待定常数。由于迭代公式(9) 并未考虑 $\gamma \| \omega \|_0$ 这一项, 该式不一定能够收敛到式(3) 的最大, 为了求解最大值 $\gamma \| \omega \|_0$, 在式(9) 中增加如下阈值步骤, 可以保证最大值 $\gamma \| \omega \|_0$ 中的非零系数个数得以实现:

$$\omega^{(t+1)} = H_\delta(\omega^{(t)} + \mu \Phi^T(y - \Phi \omega^{(t)})) \quad (10)$$

$$H_\delta(\omega_i) = \begin{cases} \omega_i, & |\omega_i| \geq \delta \\ 0, & \text{其他} \end{cases} \quad (11)$$

其中: δ 为可选阈值, H_δ 为硬阈值算子 ($i = 1, \dots, W$)。

以下证明迭代式(10) 的不动点 ω 为式(3) 的最大值, 即 $\gamma > 0$, 若任意 $\Delta \omega$ 满足 $|\Delta \omega_i| < \xi$, 则式 $g(\bar{\omega} + \Delta \omega) < g(\bar{\omega})$ 成立。为此引入辅助目标函数如下:

$$\begin{aligned} G(\omega, u) &= \sum_i [\omega_i^2 - 2 \omega_i(u_i + \Phi_i^T y - \mu \Phi_i^T \Phi u) + \\ &\quad \gamma |\omega_i|^0] + (1 - \mu) \| \Phi \omega \|_2^2 + \| y \|_2^2 + \\ &\quad \| u \|_2^2 - \mu \| \Phi u \|_2^2 \end{aligned} \quad (12)$$

若 $\omega_i \neq 0$, 则 $|\omega_i|^0 = 1$; 否则 $|\omega_i|^0 = 0$ 。若 $\| \sqrt{\mu} \Phi \|_2^2 < 1$, 则有 $G(\omega, u) \geq G(\omega, \omega) = g(\omega)$, 由此得:

$$g(\bar{\omega} + \Delta \omega) = G(\bar{\omega} + \Delta \omega, \bar{\omega}) - \| \Delta \omega \|_2^2 + \mu \| \Phi \Delta \omega \|_2^2 \quad (13)$$

由式(13) 可得:

$$\begin{aligned} G(\bar{\omega} + \Delta \omega, \bar{\omega}) - G(\bar{\omega}, \bar{\omega}) &= \sum_i [(\bar{\omega}_i + \Delta \omega_i)^2 - \\ &\quad 2(\bar{\omega}_i + \Delta \omega_i)(\bar{\omega}_i + \Phi_i^T y - \mu \Phi_i^T \Phi \bar{\omega}) + \gamma |\bar{\omega}_i| + \\ &\quad \Delta \omega_i|^0] - \sum_i [\bar{\omega}_i^2 - 2 \bar{\omega}_i(\bar{\omega}_i + \Phi_i^T y - \mu \Phi_i^T \Phi \bar{\omega}) + \gamma |\bar{\omega}_i|^0] + \\ &\quad (1 - \mu)(\| \Phi(\bar{\omega} + \Delta \omega) \|_2^2 - \| \Phi \bar{\omega} \|_2^2) = \\ &\quad \| \Delta \omega \|_2^2 + (1 - \mu) \| \Phi \Delta \omega \|_2^2 + \\ &\quad \sum_i [-2 \Delta \omega_i \Phi_i^T (y - \Phi \bar{\omega}) + \\ &\quad \gamma(|\bar{\omega}_i + \Delta \omega_i|^0 - |\bar{\omega}_i|^0)] \end{aligned}$$

进一步化简得:

$$G(\bar{\omega} + \Delta \omega, \bar{\omega}) - G(\bar{\omega}, \bar{\omega}) \leq \| \Delta \omega \|_2^2 + (1 - \mu) \| \Phi \Delta \omega \|_2^2 \quad (14)$$

将式(14) 代入式(13) 可得:

$$\begin{aligned} g(\bar{\omega} + \Delta \omega) &= G(\bar{\omega} + \Delta \omega, \bar{\omega}) - \| \Delta \omega \|_2^2 + \mu \| \Phi \Delta \omega \|_2^2 \leq \\ &\quad G(\bar{\omega}, \bar{\omega}) + \| \Phi \Delta \omega \|_2^2 \leq g(\bar{\omega}) \end{aligned} \quad (15)$$

由此得证 $g(\bar{\omega})$ 是一个局部最大值。

4 基于稀疏表示的数据流异常数据预测算法

本文运用现代随机测量矩阵实现异常数据的识别,采用新近发展的稀疏表示工具,根据包含异常数据的数据流系统模型及观测值,能够给出系统状态的无偏估计值,对动态数据具有较好的预测性能。

基于稀疏表示的数据流异常数据预测算法简述如下。

1) 在测试数据集上计算不同长度滑动窗口 B_i 的聚集值,这样对应每一个长度为 B_i 的滑动窗口将生成一个新的时间序列 f ,突变阈值的设置方式如下:

$$T(B_i) = \mu_f + \lambda\sigma_f$$

其中: μ_f 和 σ_f 分别是 f 的均值和方差,还可用 λ 调节随机变化检测的阈值。

2) 对含有异常数据的数据流 $f(k)$ 进行非下采样小波变换,并得到小波系数 $\omega_j (j = 1, \dots, J)$ 。

3) 选择合适的随机矩阵 $\Phi_{M \times N}$,计算 $y_j = \Phi\omega_j (j = 1, \dots, J)$,设 $j = J$ 。

4) 如果 $\{ |y(t) - \Delta y(t)| > 0 \} \leq \bar{y}(t)$,那么执行下面几步:

① 利用式(10)计算 ω_j 。

② 输出 $g(\bar{\omega})$,进行小波反变换得异常数据。

③ 根据小波变换特性得异常数据预测值,用该预测值代替异常数据观测值。

5) 更新 $y(t)$,转 2)。

根据不同尺度上的非零小波系数具有相似位置分布特点,可以利用已经得到的某一尺度上的异常数据的小波系统位置信息去预测其他尺度上异常数据的小波系数的位置分布情况,该特征有助于选择优化过程中每一尺度上的迭代初值,从而能加速整个迭代算法的收敛性。

5 算法的实现及其实验结果的评估

本文实验中用到的所有代码均采用 VC++ 6.0 实现,运行实验计算机配置为 2.66 GHz CPU 的 Dell PC,内存 512 MB,Windows 2000 操作系统。

采用真实流量数据与模拟异常数据相结合方式来构造模拟流量数据,以 NLANR 测量的 Auckland 大学校园网出口 OC-3 线路 48 h 的 IP 分组流量数据为背景流量,统计时间间隔为 1 min。参照文献[10]对 DDoS 攻击的时间和流量分布进行统计分析,由此模拟构造数次网络攻击流量,包括恒定速率攻击以及渐进式攻击,再将其叠加到背景流量的不同时间段中。表 1 列出若干次模拟异常情况。

表 1 模拟流量异常列表

异常 ID	异常类型	间隔时间/s	最高速率/(packet/min)
T_1	SLA	10	+20 000
T_2	SLA	15	+30 000
T_3	AIA	10	+20 000
T_4	AIA	15	+30 000

算法性能可用检测概率 P_D 与误警概率 P_F 来验证:

$$P_D = \frac{\text{正确匹配的异常点个数}}{\text{已知的异常点个数}}$$

$$P_F = \frac{\text{误检的异常点个数}}{\text{总的数据点个数}}$$

将本文提出的算法与 GLR 算法进行比较,结果如表 2 所示。根据两种算法检测结果进行比较,本文算法在 SLA 类型中检测概率为 0.8,在 AIA 类型中检测概率为 0.6,要高于 GLR 算法;同样本文算法误警概率也低于 GLR 算法,说明本文提出的算法具有准确、及时、高可靠性的优点。

表 2 不同算法的性能比较

比较项	本文算法	GLR
已知的异常点个数	10	10
正确匹配的异常点个数(SLA)	8	4
正确匹配的异常点个数(AIA)	6	3
误检测的异常点个数(SLA)	4	12
误检测的异常点个数(AIA)	5	14
检测概率 P_D (SLA)	0.8	0.4
检测概率 P_D (AIA)	0.6	0.3
误警概率 P_F (SLA)/%	0.6	2.8
误警概率 P_F (AIA)/%	0.75	3.20

同样以该流量数据为背景,在固定预测步长的情况下,对比 GLR 算法与本文提出的算法在 5 min、10 min 等几个步长级别的预测精度。定义 i 预测点的相对预测误差:

$$\Delta p_i = \frac{v_i^f - v_i^a}{v_i^a} \times 100\%$$

其中: v_i^f 表示预测流值, v_i^a 表示实际测量流值。实验对不同的 20 次 DDoS 攻击进行测试,取每一级别的平均误差,实验结果如图 1 所示。本文提出的算法在 5,10,15 级别时误差较小,其平均预测精度明显高于 GLR 算法,而 GLR 算法的预测误差随着步长的加大而加大。总体上看出,本文提出的算法比 GLR 算法的相对误差平均低 3%,精度较高,算法运行稳定。

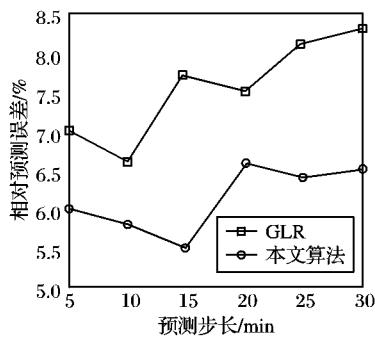


图 1 两种算法的 5 min 级别相对预测误差比较

基于实验可得出以下结论:

1) 本文算法适合实时性异常数据的判断,且结果较为准确,而 GLR 算法采用两个滑动窗口,有窗的延迟,因而有误差。

2) 采用稀疏表示和小波变换相结合的方法,利用小波变换以及随机变换矩阵的平移不变性,准确判断异常数据的位置,说明小波变换具有局部空间性,能够满足在某个瞬变时间附近抽取或定位信号的要求。

6 结语

高速网络数据流的大吞吐量和实时性的特征,对传统异常检测方法的计算效率提出了新的挑战,因此,本文通过引入新近发展起来的稀疏表示工具,提出一种基于稀疏表示的数据流异常数据预测方法。此方法与传统的异常数据识别方法

(下转第 3010 页)

中飞机的左右晃动和摄像机的随机抖动。图 5(b)为通过卡尔曼滤波去除高频噪声的图像序列,去除了摄像机的随机抖动量。然后对去除高频噪声的图像通过最小二乘法做曲线拟合去除低频噪声,即去除飞机的左右晃动量,最终得到稳定的图像序列如图 5(c)所示。

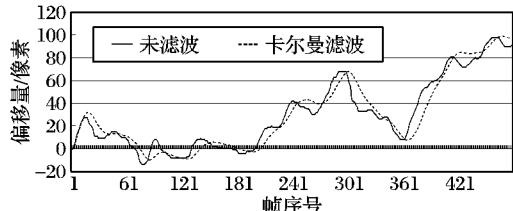


图 1 Y 方向运动曲线图

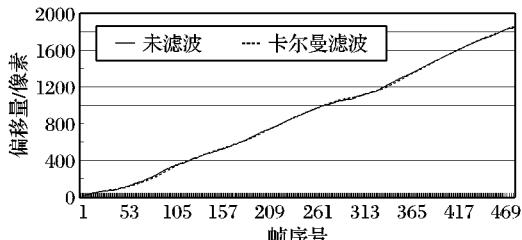


图 2 X 方向运动曲线图

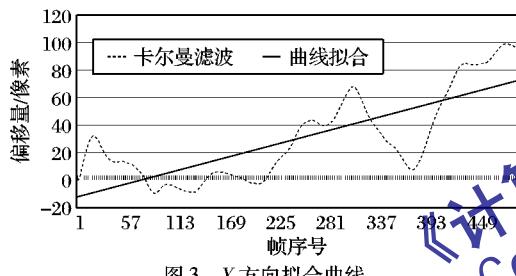


图 3 Y 方向拟合曲线

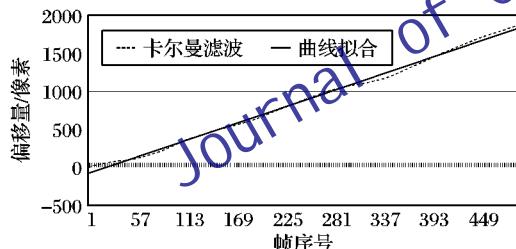


图 4 X 方向拟合曲线

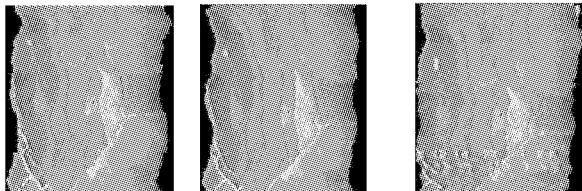
(上接第 2958 页)

相比,主要有两个改进之处:更少的计算时间和更高的还原精度,能够满足数据流的在线异常检测要求。实验表明无论从计算效率上还是从准确性上,本文提出的方法能够较好满足高速网络流量异常数据预测的需求。

参考文献:

- [1] BABCOCK B, BABU S, DATAR M, et al. Models and issues in data stream systems [C]// Proceedings of the Twenty-first ACM SIGMOD-SIGACT-SIGART Symposium on Principles of Database Systems. New York: ACM Press, 2002: 1–16.
- [2] 毛勇,周晓波,夏铮,等.特征选择算法研究综述[J].模式识别与人工智能,2007,20(2):211–218.
- [3] KNORR E M, NG R T. Algorithms for mining distance based outliers in large datasets [C]// Proceedings of the 24rd International Conference on Very Large Data Bases. San Francisco: Morgan Kaufmann, 1998: 392–403.

从图 5(c)可看出,用本文方法对无人机航空视频进行稳定,能够有效地去除高频和低频噪声。



(a) 原始图像序列 (b) 滤波后的图像序列 (c) 曲线拟合后的图像序列
图 5 图像实验

4 结语

无人机航空视频的全局运动不仅包含了飞机的剧烈抖动引起的高频噪声,还包含了飞机的慢速晃动引起的低频噪声。传统的电子稳像算法通常只关注高频抖动,无法有效地将低频晃动加以去除,本文提出了一种基于卡尔曼滤波与曲线拟合相结合的稳像算法,对实际拍摄的无人机航空视频处理结果表明,该方法能够有效去除干扰,取得很好的稳定效果。

参考文献:

- [1] 王彦锟,刘方.采用位平面和钻石搜索的全局运动估计[J].自动测量与控制,2007,26(11): 80–82.
- [2] 罗诗途,王艳玲,张纪,等.车载图像跟踪系统中电子稳像算法的研究[J].光学精密工程,2005,13(1): 95–103.
- [3] 邱平,于前洋,金光.基于特征点匹配技术的运动估计及补偿方法[J].光电工程,2005,32(2): 75–79.
- [4] 罗诗途,王艳玲,张纪,等.车载图像配准稳定算法中的关键技术[J].光电工程,2005,32(5): 16–20.
- [5] 邢慧,彦景龙,张树江.基于 Kalman 滤波的稳像技术研究[J].兵工学报,2007,28(2): 175–177.
- [6] 罗军,董鸿雁,沈振康.基于位平面匹配和卡尔曼滤波的视频稳定[J].红外与激光工程,2008,37(2): 304–307.
- [7] 沈晓晶,潘俊民.基于自适应 Kalman 预测器运动估计算法[J].计算机仿真,2004,21(10): 73–77.
- [8] 王楠,朱旭东,张华,等.基于位平面的运动矢量估计[J].指挥技术学院学报,2001,12(3): 29–32.
- [9] 郑伟,刘文耀,王涌天.一种结合遗传算法和钻石搜索的多模式快速运动估计方法[J].电子学报,2006,34(10): 1911–1916.
- [10] 钟平.机载电子稳像技术研究[D].长春:中国科学院长春光学精密机械与物理研究所,2003.
- [4] 张国江,邱家驹,李继红.基于人工神经网络的电力负荷坏数据辨识与调整[J].中国电机工程学报,2001,21(8): 105–108.
- [5] 高山,单渊达.小波奇异性检测在负荷数据纠错和平滑处理中的应用[J].中国电机工程学报,2001,21(11): 105–108.
- [6] 丁恰,卢建刚,钱玉妹,等.一种实用的超短期负荷预测曲线外推方法[J].电力系统自动化,2004,28(16): 83–85.
- [7] 金澈清,钱卫宁,周微英.流数据分析与管理综述[J].软件学报,2004,15(8): 1172–1181.
- [8] JAWERTH B, SWELDENS W. An overview of wavelet based multi-resolution analyses [J]. Review, 1994, 36(3): 377–412.
- [9] CANDES E J, TAO T. Near-optimal signal recovery from random projection: universal encoding strategies [J]. IEEE Transactions on Information Theory, 2006, 52(12): 5406–5426.
- [10] MOORE D, VOELKER G, SAVAGE S. Inferring Internet denial of service activity [C]// Proceedings of the 10th Usenix Security Symposium. Washington, DC: [s. n.], 2001: 9–22.