

基于 Wigner 分布时频遮隔的信号分解算法

田光明^{1,2}, 陈光¹

(1. 电子科技大学自动化工程学院, 四川成都 610054; 2. 中国工程物理研究院总体工程研究所, 四川绵阳 621900)

摘 要: 综合特征值分解及 Wigner 分布时频遮隔提出了一种信号分解算法, 并推广应用于其他交叉项抑制时频表示. 对于由时频面上互不重叠分量合成的多分量信号, 证明了信号分量可与各分量 Wigner 分布之和的逆 Fourier 变换的特征值分解相对应; 通过阈值法可从抑制交叉项时频表示获得信号时频支撑区域, 以此为模板遮隔 Wigner 分布可减少交叉项并保持自项聚集性, 其逆 Fourier 变换的特征值分解就可实现多分量信号分解. 仿真实例分析结果表明了该理论与算法的正确性和实用性. 最后分析了算法性能并拓展了其应用范围.

关键词: Wigner 分布; 时频遮隔; 特征值分解; 信号分解

中图分类号: TN957.52 **文献标识码:** A **文章编号:** 0372-2112 (2008) 01-0095-05

Algorithm for Signal Decomposition Using Time-Frequency Masking of Wigner Distribution

TIAN Guang-ming^{1,2}, CHEN Guang-ju¹

(1. College of Automation, University of Electronic Science and Technology of China, Chengdu, Sichuan 610054, China;

2. Institute of Systems Engineering, China Academy of Engineering Physics, Mianyang, Sichuan 621900, China)

Abstract: Integrating the eigenvalue decomposition (ED) with time frequency masking (TFM) of Wigner distribution (WD), an algorithm of signal decomposition was presented, and generalized to other type of TFRs with cross-terms reduction. For multi-component signals, whose components respectively exist in the time frequency (TF) regions which does not overlapped with each other, it was testified that, signal components may be corresponded to the ED of the inverse Fourier transform (IFT) of the summation of the components' WDs. By thresholding, the TF support regions of the WD's auto terms maybe obtained from the TF representations (TFRs) with cross-terms reduction; and from WD by TFM, one TFR which reduces the cross terms and keeps the auto terms' concentration may be obtained. Then the ED of IFT of this TFR can achieve multi component signal decomposition. The results of simulations and instance illustrated the validity and practicability of the theory and algorithm. Finally, the performance of the algorithm was analyzed and its application was popularized.

Key words: Wigner distribution; time frequency masking; eigenvalue decomposition; signal decomposition

1 引言

奇异值分解在原理上需要无穷多项来精确表示一个时频分布^[1,2], 但在许多情况下几项就足够达到很高的精确性, 从而实现降噪或分类. Marinovich 和 Eichmann 研究了 Wigner 分布 (WD) 的奇异值分解, 其结果可应用于信号探测、分类形状描述及生物医学超声波组织分析等^[3]. 作为双线性信号综合的特例, Hlawatsch 和 Krattenthaler 将离散逆 WD 特征值分解用于信号综合, 避免了混淆和相位模糊^[4]. Stankovic 和 Thayaparan 等使用 S-方法进行多分量信号分解, 并用于高频雷达信号分析^[5].

WD 时频分辨率、能量聚集性均很高, 但分析多分

量信号时不可避免地出现交叉项. 对 WD 进行平滑而构造新时频分布 (如 Cohen 类双线性时频分布)、时频重排、自适应核函数设计等方法^[6]可抑制交叉项, 且都是在自项保持与交叉项抑制之间折衷. 一般地, 通过简单阈值法由各种交叉项抑制时频表示均可获得信号 WD 自项时频支撑区域, 从而以此为模板遮隔 WD 可得到保持 WD 自项聚集性而减少交叉项的时频表示, 即遮隔 WD (MWD). 如果一个二维函数是多个时频不重叠信号 WD 之和, 那么其逆 Fourier 变换的非零特征值及特征向量可对应于这些信号^[5]. 本文首先推导了基于 WD 逆 Fourier 变换特征值分解的信号分解; 然后以自适应核函数设计时频表示 (AOKTFR)^[9,10]为例构造了 WD 时频遮

隔算法,并综合前述事实和 MWD 实现了多分量信号分解;最后通过仿真实例分析说明了算法正确性与实用性,并讨论了算法性能及其应用拓展.

2 基于 WD 与特征值分解的信号分解

2.1 信号 WD 与特征值分解

设 $x(n)$ 是 $|n| \leq N/2$ 内时限离散信号,其离散 WD 定义为:^[2,7]

$$W_x(n, k) = 2 \sum_{m=-N/2}^{N/2} x(n+m)x^*(n-m) e^{-j\frac{2\pi}{N+1}m(2k)} \quad (1)$$

其逆 Fourier 变换为:

$$x(n+m)x^*(n-m) = \frac{1}{2(N+1)} \sum_{k=-N/2}^{N/2} W_x(n, k) e^{j\frac{2\pi}{N+1}m(2k)} \quad (2)$$

令 $n_1 = n+m, n_2 = n-m$, 则有

$$x(n_1)x^*(n_2) = \frac{1}{2(N+1)} \sum_{k=-N/2}^{N/2} W_x\left(\frac{n_1+n_2}{2}, k\right) e^{j\frac{2\pi}{N+1}k(n_1-n_2)} \quad (3)$$

当 $(n_1+n_2)/2$ 非整数时,可用曲面拟合等方法插值计算 $W_x((n_1+n_2)/2, k)$. 记上式右侧为 $R_W(n_1, n_2)$, 则

$$R_W(n_1, n_2) = x(n_1)x^*(n_2) \quad (4)$$

表示为矩阵形式:

$$R_W = \mathbf{x}\mathbf{x}^* \quad (5)$$

其中, \mathbf{x} 是元素为 $x(n)$ 的列向量, \mathbf{x}^* 是 \mathbf{x} 的复数共轭转置, R_W 是元素为 $R_W(n_1, n_2)$ 的矩阵.

矩阵 R_W 的特征值分解为:

$$R_W = \mathbf{Q}\mathbf{\Lambda}\mathbf{Q}^T = \sum_{i=1}^{N+1} \lambda_i \mathbf{u}_i(n) \mathbf{u}_i^*(n) \quad (6)$$

其中, λ_i 和 $\mathbf{u}_i(n)$ ($i=1, 2, \dots, N+1$) 分别是矩阵 R_W 的特征值和特征向量.

比较式(5)和式(6), 矩阵 R 可用唯一正特征值分解, 即 $\lambda_2 = \lambda_3 = \dots = \lambda_{N+1} = 0$. 那么有

$$\mathbf{x}(n)\mathbf{x}^*(n) = \lambda_1 \mathbf{u}_1(n) \mathbf{u}_1^*(n) \quad (7)$$

$$\lambda_1 = E_x \quad (8)$$

其中, E_x 为信号 $x(n)$ 的能量

$$\mathbf{x}(n) = \sqrt{\lambda_1} \mathbf{u}_1(n) \quad (9)$$




图1 基于 WD 的信号分解:(a) 原信号 WD;(b) 复合信号 WD;(c) 原信号(实线)与复合信号(虚线);(d) (c) 的误差

即特征向量 $\mathbf{u}_i(n)$ 与信号向量 $\mathbf{x}(n)$ 分别在幅值和相位方面相差常数.

图1给出了四个时频不重叠高斯 chirp 分量(图2(b~e))合成信号(图1(c))WD(图1(a))的分解结果,图1(c,d)表明通过分解所得最大特征值及其特征向量重构信号基本上恢复了原始信号,WD(图1(b))与原信号WD是一致的.这说明前述理论分析是正确的.

2.2 分量 WD 之和与特征值分解

设信号 $x(n)$ 是由在时频面上互不重叠分量 $x_i(n)$ ($i=1, 2, \dots, M$) 合成的, 即

$$x(n) = \sum_{i=1}^M x_i(n) \quad (10)$$

其中, 每个分量 $x_i(n)$ 的 WD $W_{x_i}(n, k)$ 分别位于互不重叠时频区域 $D_i, i=1, 2, \dots, M$, 即对于 $i \neq j, D_i \cap D_j = \emptyset$.

$$\text{令 } \tilde{W}(n, k) = \sum_{i=1}^M W_{x_i}(n, k) \quad (11)$$

则如同式(2)、式(3), 上式的逆 Fourier 变换为:

$$\begin{aligned} R_{\tilde{W}}(n_1, n_2) &= \frac{1}{2(N+1)} \sum_{k=-N/2}^{N/2} \tilde{W}\left(\frac{n_1+n_2}{2}, k\right) e^{j\frac{2\pi}{N+1}k(n_1-n_2)} \\ &= \frac{1}{2(N+1)} \sum_{k=-N/2}^{N/2} \sum_{i=1}^M W_{x_i}\left(\frac{n_1+n_2}{2}, k\right) e^{j\frac{2\pi}{N+1}k(n_1-n_2)} \\ &= \sum_{i=1}^M \left[\frac{1}{2(N+1)} \sum_{k=-N/2}^{N/2} W_{x_i}\left(\frac{n_1+n_2}{2}, k\right) e^{j\frac{2\pi}{N+1}k(n_1-n_2)} \right] \end{aligned} \quad (12)$$

将每个分量 $x_i(n)$ 的 WD $W_{x_i}(n, k)$ 的逆 Fourier 变换(如式(3))代入式(12)并表示为矩阵形式, 可得

$$R_{\tilde{W}} = \sum_{i=1}^M \mathbf{x}_i \mathbf{x}_i^* \quad (13)$$

其中, \mathbf{x}_i 是元素为 $x_i(n)$ 的列向量. 矩阵 $R_{\tilde{W}}$ 的特征值分解为:

$$R_{\tilde{W}} = \sum_{i=1}^{N+1} \lambda_i \mathbf{u}_i \mathbf{u}_i^* \quad (14)$$

将特征值由大到小排序, 不妨设 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_{N+1}$.

各信号分量在时频面上互不重叠意味着它们是正交的. 如果所有非零特征值互不相同, 那么特征值分解(14)是唯一的, 且非零特征值项与式(13)一一对应. 如同2.1, $x_i(n)$ 对应于唯一正特征值 λ_k 及其特征向量 \mathbf{u}_k , 即对于 $x_i(n)$ ($i=1, 2, \dots, M$), 存在唯一 k ($1 \leq k \leq M$), 使得

$$\lambda_k = E_{x_i} \quad (15)$$

$$x_i(n) = \sqrt{\lambda_k} \mathbf{u}_k(n) \quad (16)$$

且当 $k = M+1, \dots, N+1$ 时, $\lambda_k = 0$.

图2给出了四个时频不重叠高斯 chirp 信号分量(图2(b~e))WD之和(图2(a))逆 Fourier 变换的特征值分解结果, 图2(f~i)显示了分解分量与原始分量(见图2(b~e))的误差. 显然, 分解所得非零特征值及其特征向量准确地恢复了原始信号分量. 事实上, 分解所得信号分量 WD 之和与图2(a)所示原始信号分量

WD 之和也是一致的. 因此, 若消除 WD 交叉项并保持自项聚集性, 那么通过逆 Fourier 变换的特征值分解就可以识别多分量信号分量.

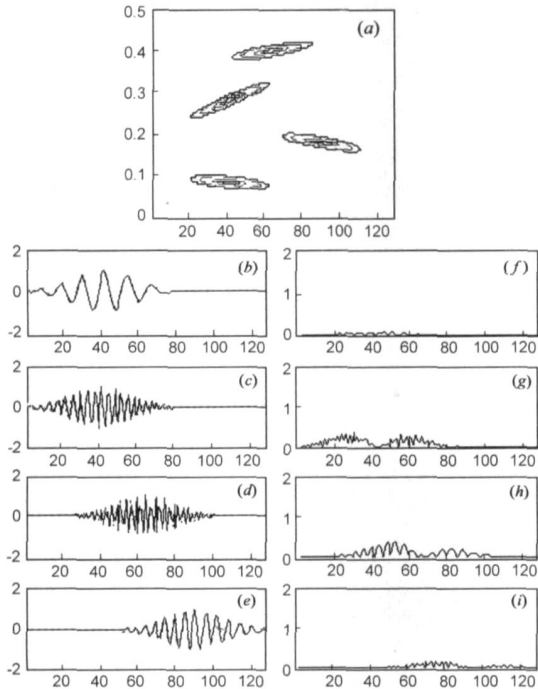


图 2 基于分量 WD 之和 (a) 的信号分解: (b~e) 分解分量 (虚线) 与原分量 (实线) 及其误差 (f~i)

3 基于 WD 时频遮隔的信号分解

3.1 WD 的时频遮隔

无交叉项干扰且尽可能等于各分量 WD 之和的时频表示对于 2.2 节信号分解非常重要. 然而, 不含交叉项且具有 WD 聚集性或充分接近 WD 聚集性的时频分布并不存在^[8], 所以获得接近 WD 聚集性并尽量减少交叉项的时频表示具有重要意义. 一种较为简单的方法是通过时频遮隔保持 WD 自项并尽可能消除 WD 交叉项, 但需要获得信号各分量时频支撑区域. 存在许多可有效抑制交叉项并保持一些时频分布期望性质的时频表示, 如 Cohen 类双线性时频分布、时频重排、自适应核函数设计等^[1~3]. 其中, AOKTFR 采用径向高斯核函数, 根据不同类型信号自动确定核函数在模糊平面的形状; 信号自项成份集中在模糊平面原点附近, 而交叉项远离原点; 作为一个低通滤波器, 最优核函数允许模糊平面上自项成份通过, 而将交叉项成份抑制. 因此, 用阈值法从 AOKTFR 就得到 WD 自项时频支撑区域, 以此区域为模板对 WD 进行时频遮隔可获得期望的时频表示. 算法如下:

步骤 1 由文献[10]中的算法计算信号 $x(n)$ 的 AOKTFR $A_x(n, k)$;

步骤 2 用硬门阈滤波器对 $A_x(n, k)$ 滤波得到信

号 $x(n)$ 的时频支撑区域, 即时频遮隔模板:

$$z(n, k) = \begin{cases} 1, & \text{if } |A_x(n, k)| \geq tr \\ 0, & \text{if } |A_x(n, k)| < tr \end{cases} \quad (17)$$

其中, tr 为预设阈值;

步骤 3 由式(1)计算信号 $x(n)$ 的 WD $W_x(n, k)$, 并通过阈值为零的硬门阈滤波去除交叉项负值:

$$\hat{W}(n, k) = \begin{cases} W(n, k), & \text{if } W(n, k) \geq 0 \\ 0, & \text{if } W(n, k) < 0 \end{cases} \quad (18)$$

步骤 4 将模板 $z(n, k)$ 与 $W_x(n, k)$ 相乘得到新的时频表示 $\hat{W}_x(n, k)$, 即 MWD:

$$\hat{W}_x(n, k) = z(n, k) W_x(n, k) \quad (19)$$

显然, 所得 MWD $\hat{W}_x(n, k)$ 具有与 WD 相同自项聚集性, 但消除了自项外交叉项和交叉项负值. 图 3 给出了图 1(c) 所示信号 AOKTFR、遮隔模板和 MWD, 其中阈值为 AOKTFR 最大值 15%. 比较图 3(c) 和图 1(a)、图 2(a) 可以看出, MWD 消除了交叉项干扰, 其分量聚集性与 WD 相同、近似于各分量 WD 之和.




图 3 (a) 信号 AOKTFR; (b) 遮隔模板; (c) MWD

3.2 信号分解算法

MWD 消除了交叉项干扰, 由 2.2 节可知, 对其逆 Fourier 变换进行特征值分解就可以识别信号分量, 并重构信号. 算法如下:

步骤 1 对信号 $x(n)$ 的 MWD $\hat{W}_x(n, k)$ 进行逆 Fourier 变换, 并计算矩阵 $R_{\hat{W}}$ (式(12)):

$$R_{\hat{W}} = \frac{1}{2(N+1)} \sum_{k=-N/2}^{N/2} \hat{W} \left[\frac{n_1 + n_2}{2}, k \right] e^{j \frac{2\pi}{N+1} k (n_1 - n_2)} \quad (20)$$

其中, 当 $(n_1 + n_2)/2$ 非整数时, 如同 2.1 节通过插值计算 $\hat{W}((n_1 + n_2)/2, k)$.

步骤 2 分解矩阵 $R_{\hat{W}}$ 为特征值 λ_i 和特征向量 u_i , 并将特征值从大到小排序, 且 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_{N+1}$;

步骤 3 选择前 M 个正特征值及其特征向量重构

$$\text{原信号 } x(n): \quad \tilde{x}(n) = \sum_{i=1}^M \sqrt{\lambda_i} u_i(n) \quad (21)$$

在实际应用中, 可取特征值累积率:

$$\sum_{k=1}^r \lambda_k / \sum_{k=1}^N \lambda_k \geq \alpha \quad (22)$$

其中, r 为大于零的特征值数目. 一般地, $\alpha = 95\%$.

图 4 给出了图 3(c) 所示 MWD 的分解结果, 所得分量与原分量的误差分别见图 4(a~d). 显然, 四个分量均被准确识别, 可很好地重构原始信号, 其 WD 之和 (图

4(e))与原始分量WD之和(图2(a))、综合信号WD(图4(f))与原始信号WD(图1(a))基本一致。




图4 基于MWD的信号分解:信号分量与分解分量之误差(a~d)、分解分量WD之和(e)与综合信号WD(f)

4 仿真与实例

4.1 有噪合成信号

在前两节中,通过无噪合成信号分析验证了理论和算法的正确性。对原始信号(图1(c))加入高斯白噪声得到信噪比为3dB的有噪信号,并利用上节算法进行了分析(其中阈值为AOKTFR最大值的20%),所得分量与原分量的误差分别见图5(e~h)。由于噪声与交叉项干扰,WD(图5(a))自项被淹没,AOKTFR(图5(b))自项有所扭曲且干扰较为严重,但MWD(图5(c))聚集

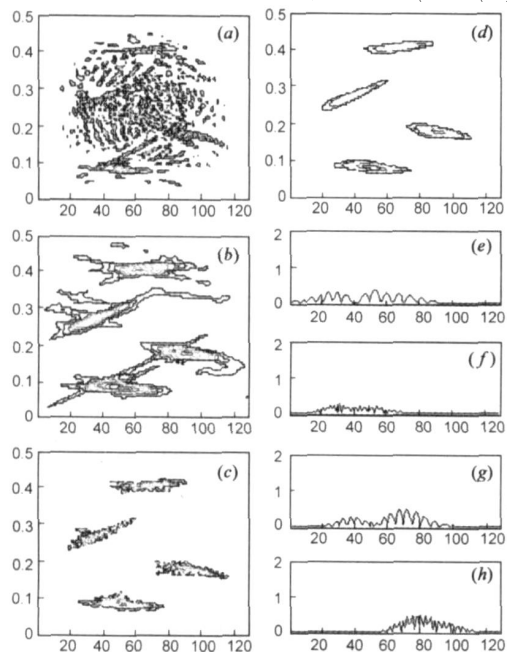


图5 (a)有噪信号的WD;(b)AOKTFR;(c)MWD;(d)四个分解分量WD之和及其与原始分量的误差(e~h)

性与WD相同而干扰被减少。分解分量误差有所增大,但四个信号分量仍然被识别,其和可重构原始信号,而分量WD之和(图5(d))中清晰可见自项因扭曲而有所畸变。这说明本文算法具有一定的抗干扰能力,可以识别有噪信号的分量并重构信号以降低噪声。

4.2 回声定位信号

大棕色蝙蝠发出回声定位脉冲探测飞行路径上的障碍物。这种脉冲由瞬时频率(IF)为抛物线性调频脉冲组成。其解析信号由Hilbert变换生成(见图6(a,b))。AOKTFR、WD及MWD分别见图6(c~e),显然后者抑制了WD交叉项。时频遮隔算法阈值为AOKTFR最大值的20%。由MWD逆Fourier变换特征值分解结果见图6(f,g),定位信号中两个主要分量被识别出来了;由峰值探测法^[1]所得IF分别见图6(h,i);综合信号的实部和虚部见图6(a,b)。




图6 回声定位信号分析:原始信号(虚线)与综合信号(实线)的实部(a)和虚部(b),原始信号的AOKTFR(c)、WD(d)及MWD(e)、分解分量实部(f、g)及IF(h、i)

5 算法性能分析与推广

5.1 算法性能分析

从前述算例,特别是分量误差可以看出,本文算法可较为准确地识别出各信号分量,且具有一定的噪声免疫力。一般地,这些分量基本上是单分量的,从而易于计算IF。由于特征值分解通常较为费时,该方法计算复杂度较高。

将图4(e)中分解分量WD之和分别与图3(c)中MWD比较可知,二者基本上是一致的。事实上,对通过MWD $\hat{W}_x(n, k)$ 计算的矩阵 R_W (式(20))进行特征值分解,由正特征值及对应特征向量所得信号分量WD之和

在最小均方意义下等于函数 $\hat{W}_x(n, k)$. 遮隔 WD 可以抑制自项外的交叉项, 但仍保留了自项内的交叉项正值, 从而分解所得分量产生畸变(见图 5(d)). 因此, 尽量抑制交叉项并保持与 WD 相同自项聚集性更为有利, 如 S-方法^[5]. 显然, 分解所得分量 WD 之和是一种交叉项抑制并具有与 WD 相同自项聚集性的时频表示.

基于信号 WD 逆傅立叶变换与特征值分解构造出依赖于信号的正交分解, 自适应构造信号分量而不需选定正交基; 且当分量能量互不相同(即特征值互不相等)时这种分解是唯一的. 这与一些常用的信号分解方法有所差别, 如: 线性变换信号分解^[2]是通过良好构造且便于应用的正交基来重构信号, 如傅立叶变换和小波变换等; 字典信号表示^[12]则严重地依赖于字典元素选择及元素排序策略, 需根据应用确定字典元素冗余度; 经验模式分解^[13]是将信号分解为所谓基本模式函数之和.

5.2 基于信号交叉项抑制时频表示的分解

由 1.1 节可知, 矩阵 R_w 的特征值分解(式(6))可检查任意二维函数 $W(n, k)$ 是否为有效 WD, 但在理论上任意二维函数 $P(n, k)$ 都可应用 3.2 节的信号分解算法, 而且由正特征值及对应特征向量所得分量 WD 之和在最小均方意义下等于函数 $P(n, k)$. 因此, 任何交叉项抑制时频表示均可进行类似信号分解, 如 AOKTFR、伪 WD、短时谱、Gabor 谱等, 但所得分量与原信号分量可能存在幅值和相位差异, 这种差异依赖于所用时频表示的性质. 图 7 给出了基于图 5(b) 所示有噪声合成信号 AOKTFR 特征值分解结果. 从图 7(b~e) 可知, 所得分量分别与原信号分量仅仅相差常数. 虽然所得分量存在一定程度的畸变, 但其 WD 之和(图 7(a))识别出 AOKTFR(图 5(b)) 显著部分, 减少了干扰, 而 AOKTFR 存在明显噪声.




图 7 基于有噪信号 AOKTFR 的分解: 分量 WD 之和 (a), 分解分量 (实线) 与比例原始分量 (虚线) 实部 (b~e)

6 结束语

本文采用基于 WD 时频遮隔逆 Fourier 变换特征值

分解实现了由时频面不重叠分量合成的多分量信号的分解, 仿真与实例分析验证了理论和算法的正确性与实用性. 时频遮隔仅减少了 WD 自项外交叉项, 虽然分解结果受到存在于自项内交叉项和噪声的影响而发生畸变, 但该算法仍然能够识别信号分量而应用于信号探测或分类等领域. 这种信号分解算法可以推广应用于其他任何交叉项抑制时频表示, 所得结果可识别信号分量, 但与真实信号分量可能存在依赖于时频表示自项性质的幅值和相位差异. 因此, 研究抑制交叉项并且尽量保持与 WD 相同自项聚集性的时频表示是非常必要的. 这恰恰是时频分析技术发展的动力^[6].

参考文献:

- [1] Cohen L. Time frequency Analysis: Theory and Applications [M]. Prentice Hall, 1995. 158- 162.
 - [2] 张贤达, 保铮. 非平稳信号分析与处理[M]. 北京: 国防工业出版社, 1998. 46- 52, 96- 104.
 - [3] Marinovich N M, Eichmann G. An expansion of the Wigner distribution and its applications[A]. In Proc. IEEE ICASSP 85 [C]. IEEE Press, 1985, 10: 1021- 1024.
 - [4] Hlawatsch F, Krattenthaler W. Bilinear signal synthesis [J]. IEEE Trans on Signal Processing, 1992, 40(2): 352- 363.
 - [5] Stankovic L J, Thayaparan T, Dakovic M. Signal decomposition by using the S method with application to the analysis of HF radar signals in sea clutter [J]. IEEE Trans on Signal Processing, 2006, 54(11): 4332- 4342.
 - [6] 邹红星, 周小波, 李衍达. 时频分析: 回溯与前瞻[J]. 电子学报, 2000, 28(9): 78- 84.
- ZOU Hong xing, ZHOU Xiao bo, LI Yar da. High time frequency analysis—a survey[J]. Acta Electronica Sinica, 2000, 28(9): 78- 84. (in Chinese) (下见本期第 85 页)

作者简介:



田光明 男, 1970 年 7 月出生于四川遂宁, 1992 年和 2001 年分别在大连理工大学、重庆大学获理学学士和工学硕士, 高级工程师, 现为电子科技大学自动化学院博士研究生. 主要从事非平稳信号处理及相关应用研究.

E-mail: TianGuangming@hotmail.com



陈光 男, 电子科技大学自动化学院教授, 博士生导师, 中国电子学会会员, 英国 IEE 会员. 主研方向包括现代测试理论与技术、计算机辅助测试(CAT)、数据域测试、集成电路测试、可测性设计等.

- and Machine Intelligence, 2001, 23(2): 180–195.
- [6] Kinser J M, Lindblad T. Implementation of pulse coupled neural networks in a CNAPS environment[J]. IEEE Trans, Neural Networks, 1999, 10(3): 584–590.
- [7] 毕英伟, 邱天爽. 一种基于简化 PCNN 的自适应图像分割方法[J]. 电子学报, 2005, 33(4): 647–650.
BI Ying wei, QIU Tian shuang. An adaptive image segmentation method based on a simplified PCNN[J]. Acta Electronica Sinica, 2005, 33(4): 647–650. (in Chinese)
- [8] 张军英, 樊秀菊, 等. 一种改进型脉冲耦合神经网络及其图像分割[J]. 电子学报, 2004, 32(7): 1223–1227.
ZHANG Jun ying, et al. Image segmentation based on a modified pulse coupled neural network[J]. Acta Electronica Sinica, 2004, 32(7): 1223–1227. (in Chinese)
- [9] 马义德, 齐春亮, 等. 基于脉冲耦合神经网络和施密特正交基的一种新型图像压缩编码算法[J]. 电子学报, 2006, 34(7): 1255–1259.
MA Yi de, et al. A novel image compression coding algorithm based on pulse coupled neural network and gram schmidt orthogonal base[J]. Acta Electronica Sinica, 2006, 34(7): 1255–1259. (in Chinese)
- [10] 张军英, 卢志军, 等. 基于脉冲耦合神经网络的椒盐噪声图像滤波[J]. 中国科学 E 辑 信息科学, 2004, 34(8): 882–894.
- [11] 赵峙江, 张田文, 等. 一种新的基于 PCNN 的图像自动分割算法研究[J]. 电子学报, 2005, 33(7): 1342–1344.
ZHAO Shi jiang, et al. A study of a new image segmentation algorithm based on PCNN[J]. Acta Electronica Sinica, 2005, 33(7): 1342–1344. (in Chinese)
- [12] Pietro Perona, Jitendra Malik. Scale space and edge detection using anisotropic diffusion[J]. IEEE Trans, Pattern Analysis and Machine Intelligence, 1990, 12(7): 629–639.

作者简介:



于江波 男, 1979年3月出生于山东烟台, 北京交通大学电子信息工程学院博士研究生, 研究方向为图像处理、计算机视觉感知。

E-mail: yjbdin@sohu.com



陈后金 男, 1965年2月出生于安徽当涂, 北京交通大学电子信息工程学院教授, 博士生导师, 国家电工电子教学基地主任. 主要研究方向为信号和信息处理、生物神经网络、生物医学图像处理等。

(上接本期第 99 页)

- [7] Cunningham G S, Williams W J. Fast implementations of generalized discrete time frequency distributions[J]. IEEE Trans on Signal Processing, 1994, 42(6): 1496–1508.
- [8] 邹红星, 戴琼海, 李衍达, 等. 不含交叉项干扰且具有 WVD 聚集性的时频分布之不存在性[J]. 中国科学(E 辑), 2001, 31(4): 348–354.
- [9] Baraniuk R G, Jones D L. Signal dependent time frequency analysis using a radially Gaussian kernel[J]. Signal Processing, 1993, 32(3): 263–284.
- [10] Jones D L, Baraniuk R G. An adaptive optimal kernel time frequency representation[J]. IEEE Trans on Signal Processing, 1995, 43(11): 2361–2371.
- [11] Rao P, Taylor F J. Estimation of the instantaneous frequency using the discrete Wigner distribution[J]. Electron Letters, 1990, 26(9): 246–248.
- [12] Mallat S, Zhang Z F. Matching pursuit with time frequency dictionaries[J]. IEEE Trans on Signal Processing, 1993, 41(12): 3397–3415.
- [13] Huang N E, Shen Z, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non stationary time series analysis[A]. Proceedings of the Royal Society[C]. London: The Royal Society, 1998, 454: 903–955.