

基于独立分量分析的图象分离技术及应用

吴小培¹⁾³⁾ 冯焕清¹⁾ 周荷琴²⁾ 王涛¹⁾

¹⁾(中国科技大学电子科学与技术系, 合肥 230026) ²⁾(中国科学技术大学自动化系, 合肥 230026)

³⁾(安徽大学计算智能与信号处理教育部重点实验室, 合肥 230039)

摘要 简要介绍了有关独立分量分析的基本理论和算法,探讨了独立分量分析在序列图象处理方面的应用,提出了基于独立分量分析的运动目标检测新方法.同时用独立分量分析方法对含有运动目标的序列图象进行了独立分量分离的试验,试验中,首先获取序列图象的独立分量和模型混合矩阵,然后将含有背景干扰的独立分量置零,并用混合矩阵进行逆运算,从而获得了非常清晰的运动目标轨迹.试验结果表明,这种独立分量分析方法具有良好的盲源分离性能,而且在运动目标检测等方面,基于独立分量分析的检测方法较传统的检测方法更有效.

关键词 独立分量分析 图象分离 图象序列 盲源分离

中图法分类号: TP391 文献标识码: A 文章编号: 1006-8961(2001)02-0133-05

Image Separation Technique and Application Based on Independent Component Analysis

WU Xiao-pei¹⁾³⁾, FENG Huan-qing¹⁾, ZHOU He-qing²⁾, WANG Tao¹⁾

¹⁾ Department of Electronic Science and technology, USTC, Hefei 230026)

²⁾ Department of Automation, USTC, Hefei 230026)

³⁾ The Key Laboratory of Intelligent Computing and Signal Processing of Ministry of Education of China, Hefei 230039)

Abstract Independent Component Analysis(ICA) is a novel approach of blind source separation and has received attention because of its potential application in signal processing such as in speech recognition system, image processing, telecommunication and medical signal processing. In this paper, the fundamental theory and algorithm of ICA is introduced. The feasibility of ICA for sequential image processing is studied and a novel ICA based approach of moving target detection is proposed. One of the main tasks of moving target detection is how to remove the interference of background efficiently. In our research work, we find that ICA has the good performance for the background rejection. The steps of our method are that: firstly, we apply ICA to the sequential images of containing moving target to get the mixing matrix of ICA linear mixing model and the vector of the independent components. The result of ICA show that the background component is separated from other independent components. So, secondly we can set the independent components that contain obvious background image to be zero and then do the inverse computation of ICA using the mixing matrix. After the two processing steps above, we get the clear track of moving target. The experiment results illustrate that ICA has good performance for blind source separation, and the novel approach of moving target detection based on ICA is more effective than the traditional detection method.

Keywords Independent component analysis, Image separation, Sequential images, Blind source separation

0 引言

多源混合信号的盲源分离技术在通讯、语音信号处理、生物医学信号处理、阵列信号处理以及通用

信号分析等方面有着非常重要的应用价值,如独立分量分析(Independent Component Analysis,简称ICA)就是一种新的盲源分离技术,而且它在一定条件下能有效地从多通道观测信号中分离出源信号,这种ICA问题可简单描述为:假定从 N 个通道获得 N 个

观测信号 $x_i (i = 1, 2, \dots, N)$, 则每个观测信号即是由 M 个独立源信号 $s_i (i = 1, 2, \dots, M)$ 的线性混合, 即 $X = AS$, 其中, $X = [x_1, x_2, \dots, x_N]^T$ 和 $S = [s_1, s_2, \dots, s_M]^T$ 分别是观测信号矢量和源信号矢量; A 是尺寸为 $M \times N$ 的未知混合矩阵. 由于独立源 S 和混合矩阵 A 都是未知的, 因此显然用常规的信号处理手段无法解决盲源分离这一实际问题. 自 90 年代起, 国际上就对 ICA 问题进行了广泛的研究, 目前该项研究工作大致可分为两大类, 一是 ICA 的基本理论和算法的研究, 到目前为止, 已提出了多种 ICA 算法^[1,2], 其主要任务就是估计分离矩阵 W , 以实现从多通道观察信号中分离出相互独立的信源(独立分量), 即 $S = WX$; 另一类工作则集中在 ICA 的实际应用方面, 文献 [1]~[6] 中介绍了 ICA 在语音信号分离、生物医学信号处理、金融数据分析、图象消噪、人脸识别等方面的应用成果. 这些应用成果充分展示了 ICA 的特点和价值.

大家知道, 序列图象的分析与处理是图象处理领域的一个重要课题, 其应用领域也非常广泛, 例如, 电视图象的处理与传输、军事运动目标的跟踪与识别、交通运输中的自动导航和交通监测、机器人视觉等. 由于序列图象的相邻图象间具有较大相似性这样一个重要特征, 例如用高速摄影机拍摄的子弹飞行过程的运动序列图象, 其背景几乎是没有任何变化的, 还有, 在其他一些类似的情况下所获得的序列图片中, 除运动目标的相对位移外, 其背景图象变化均不大, 因而序列图象的这一特征为运动目标的检测与跟踪、特征增强以及图象压缩与传输等实际问题的解决提供了一个具有导向性的思路, 并产生了一系列用于序列图象分析和处理的基本方法^[7]. 这里, 值得一提的是基于特征分析(eigenanalysis)的线性变换技术, 如主分量分析(PCA)、奇异值分解(SVD)以及近期发展起来的 ICA 技术, 在序列图象处理中均起着越来越重要的作用, 但由于 PCA 和 SVD 是基于信号二阶统计特性的分析方法, 其目的只是用于去除图象各分量之间的相关性, 因而它们主要用于图象数据的压缩, 可是, ICA 则是基于信号高阶统计特性的分析方法, 而且经 ICA 分解出的各信号分量之间是相互独立的, 正是因为这一特点, 使 ICA 在信号处理领域受到了广泛的关注. 本文则将 ICA 方法应用于运动图象序列分析与处理, 并取得了一些非常有参考价值的实验结果.

1 图象序列的独立分量分析

图 1 是一个基于 ICA 的图象序列生成与分解模型. 根据 ICA 理论, 序列图象或多通道观测图象 X 可看成是由相互独立的源图象 S 线性混合而成. 另外, 根据输出信号的独立性原则, 即使在独立源图象 S 和混合矩阵 A 都是未知的情况下, ICA 也能有效地估计分离矩阵 W , 以便将源图象从观测图象中分离出来, 且使分离结果 $\hat{S}$ 中的各图象彼此相互独立.




图 1 图象生成与分解模型

ICA 理论及分离算法的关键在于如何度量分离结果的独立性. 文献 [1] 中介绍了多种独立性度量准则, 而本文则介绍了一种基于负熵的独立性判决准则和分离算法——FastICA 算法. 笔者曾用该算法对混入脑电信号中的心电干扰成分进行了成功的分离^[8], 另外还用该算法实现了混合语音信号的分离. 实验表明, FastICA 算法具有优良的盲源分离性能. 图 2 是一模拟的 4 通道观测图象, 其是由 4 幅 128×128 pixel 大小的真实源图象随机混合而成, 下面即以这一混合图象的 ICA 分解为例, 来阐明 ICA 基本理论和分离算法.




图 2 混合图象

1.1 负熵判据

由中心极限定理可知,如一随机量 X 由许多相互独立的随机量之和组成,只要各独立的随机量具有有限的均值和方差,且不论各独立随机量为何种分布,则 X 必接近高斯分布.由于图象信号一般为亚高斯信号,但根据中心极限定理可以推断,观测图象信号 x_i 较之源图象信号 s_i 更接近于高斯分布,或者说, s_i 比 x_i 的非高斯性更强,因此在分离过程中,可通过 $\hat{s}_i$ 的非高斯性度量来监测分离结果间的相互独立性,即当非高斯性度量达到最大时,即表明已完成对各独立分量的分离.对于一概率密度函数为 $p(y)$ 的随机量 y ,其负熵定义为

$$Ng(y) = H(y_{\text{gauss}}) - H(y) \quad (1)$$

式中, y_{gauss} 是一与 y 具有相同方差的高斯分布的随机量, $H(\cdot)$ 为随机变量的信息熵

$$H(y) = - \int p(y) \lg p(y) dy \quad (2)$$

根据信息理论,在具有相同方差的随机变量中,高斯分布的随机变量具有最大的信息熵,但非高斯性越强,信息熵越小.由式(2)可得,当 y 具有高斯分布时, $Ng(y) = 0$,且 y 的非高斯性越强, $Ng(y)$ 值越大.但实际应用中,由于式(1)的计算,需要知道概率密度分布函数,这显然是不切实际的,因而文献[1]中给出一种进行非高斯性度量^[1]的近似公式为

$$Ng(y) \propto [E\{G(y)\} - E\{G(y_{\text{gauss}})\}]^2 \quad (3)$$

其中, $E(\cdot)$ 为均值运算; $G(\cdot)$ 可取

$$G_1(u) = \frac{1}{a_1} \lg \cos(a_1 u), G_2(u) = -\exp(-u^2/2)$$

等非线性函数.不难理解,式(3)同样可以用于对分离结果的的非高斯性(即独立性)进行度量,且可用于实际计算.

1.2 FastICA 算法

FastICA 算法分如下两步实现:(1)对观测信号进行白化处理;(2)独立分量提取.其中,步骤(1)可看成是对观测信号的预处理,由于白化处理可去除各观测信号间的相关性,因而简化了后续独立分量的提取过程.这种信号的白化处理比较简单,用类似主分量分析的方法即可实现^[9].设白化后的信号为 $\bar{X}$,则 $\bar{X}$ 满足

$$E\{\bar{X}\bar{X}^T\} = E\{B\bar{X}\bar{X}^TB\} = I \quad (4)$$

式中, B 称为白化矩阵, I 为单位矩阵,符号“ T ”为矩阵(向量)的转置.经白化处理后,观测信号 X 即变为具有单位方差的信号向量 $\bar{X}$,且 $\bar{X}$ 中各信号分

量相互正交.具体计算时,是将图2中的4幅观察图象按行扫描成为4个长度为16384的一维信号进行处理,如果要观察处理结果,按相反的过程还原成2维图象即可.图3为观测图象经白化处理后的结果.




图3 白化处理后的图象

由此可见,白化处理还不能实现源图象的分离,而只是去除了观测图象信号间的相关性.接下来的工作是对白化信号 $\bar{X}$ 的进一步处理,即寻找分离矩阵 $\bar{W}$,以实现独立分量的提取(注:此处的 $\bar{W}$ 是针对白化以后的信号 $\bar{X}$ 而言的),而且这种分离过程是一迭代逼近过程,变量 n 表示迭代步数,令 $\hat{s}_i^{(n)}$ 是 $\hat{s}^{(n)}$ 中的某一分量, $\bar{w}_i(n)$ 为分离矩阵 $\bar{W}(n)$ 中,与 $\hat{s}_i^{(n)}$ 对应的某一行向量,即

$$\hat{s}_i^{(n)} = \bar{w}_i^T(n) \cdot \bar{X}; \quad n = 1, 2, 3, \dots \quad (5)$$

然后在分离过程中,用式(3)所定义的目标函数对分离结果 $\hat{s}_i^{(n)}$ 的非高斯性进行度量,并对 $\bar{w}_i(n)$ 进行调整. FastICA 算法的调整公式为^[12]

$$\bar{w}_i(n+1) = E\{\bar{X}G'(\bar{w}_i^T(n)\bar{X})\bar{X}\} - E\{G'(\bar{w}_i^T(n)\bar{X})\bar{X}\}\bar{w}_i(n) \quad (6)$$

若当相邻两次的 $\bar{w}_i(n)$ 无变化或变化很小时,即可认为 $\hat{s}_i^{(n)} \approx s_i$,则迭代过程结束.式(6)中的均值计算可通过时间平均获得.这里要注意的是:每次迭代后,都要对 $\bar{w}_i(n)$ 进行如下归一化处理: $\bar{w}_i(n) = \bar{w}_i(n) / \|\bar{w}_i(n)\|$,以确保式(5)的分离结果具有单位能量,由此可见,这是 ICA 问题的一个基本限制.对于多个独立分量,虽可重复使用上述过程进行分离,但每提取出一个独立分量后,则要从观测信号中减去这一独立分量,如此重复,直至所有独立分量完全分离,并可得到混合矩阵 A 和分离矩阵 W :

$$W = \bar{W}B \quad (7)$$

对图3的进一步处理结果如图4所示,从图4可以看到,ICA 的分离结果非常理想.




图4 ICA分离图象

上述理论分析和实验结果虽已从原理上展示了ICA的盲源分离能力,但在实际应用中,由于多通道观测图象的构成往往比较复杂,虽然一般情况下ICA的分离结果不是明确的物理图象,但分离结果中往往包含着一些非常重要的图象信息,且这些信息对于图象的特征提取、目标增强以及图象数据压缩都非常有用,例如由于运动图象的序列图象间存在一定的相似性,且这些相似的部分可认为来源于同一个独立源,因此ICA方法将能有效地分离出序列图象中的相似和差异成分。




图5 运动图象序列

分量依次为 $s_1, s_2, \dots, s_8$ (图7), 其中前7个独立分量中,基本不包含背景干扰成分,这是因为ICA将序列图象中不变的背景成分归结为一个独立分量(图7中的最后一幅图象 s_8)。为了更好地观测运动物体轨迹,将图7中含有背景成分的独立分量 s_8 置零,然后利用所得的混合矩阵 A 对图7进行逆向运算,即得到一组新的观测图象 $\hat{X}$ (如图8所示),即

$$\hat{X} = AS^{-1} = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{18} \\ a_{21} & a_{22} & \cdots & a_{28} \\ \cdots & \cdots & \cdots & \cdots \\ a_{81} & a_{82} & \cdots & a_{88} \end{bmatrix} \begin{bmatrix} s_1 \\ \cdots \\ s_7 \\ 0 \end{bmatrix}$$

从图8中的任何一幅图象都可清晰地观测到运

2 基于ICA的运动目标检测

在一固定的观察点连续拍摄一运动物体时,即可得到包含运动物体和背景的序列图象,该图象中的背景可近似认为不变,只是背景的平均灰度因光照的变化可能会有所改变,但对运动目标而言,由于移动过程会改变目标与观测点的视角,因而会造成目标图象在图象序列中的变化。图5是一模拟连续拍摄的运动图象序列,它是用一随机运动的小方块来模拟运动物体,并设计了背景图象的灰度变化。由于运动目标的灰度与背景图象灰度存在混叠,因而几乎难以辨别运动目标在每一幅序列图象中的位置。显然,要想检测出运动物体的运行轨迹,则消除背景干扰是其最基本的任务。传统的检测方法是图象的相减运算,图6即是图象减运算的结果。从图5可以看到,由于图象序列中各图象的平均灰度并不完全相同,所以相减运算并不能有效地消除背景,且运动目标的增强效果也不佳。

用ICA方法对图5进行处理,所得的8个独立




图6 物体运动轨迹检测结果(传统方法)

动物体的运动轨迹,由此可见,ICA的检测结果要明显优于传统方法。从上述实验结果来看,ICA非常适合于SCMO(静止的摄像机和运动的目标)情况下的序列图象处理,且图象序列间的灰度变化对ICA的处理效果几乎没有什么影响;但对于一些用于运动目标检测的传统方法而言,灰度的变化可能会在很大程度上影响图象的处理效果,例如会出现虚假的目标或边缘等。另外,我们还对ICA在MCMO情况下的序列图象处理问题也进行了研究,在特征增强和数据压缩等方面,ICA也表现出了较好的性能,但效果没有在SCMO情况下那么明显,而有关的研究工作还在进行中。




图 7 ICA 分解结果

左列自上至下分别为 s_1 s_2 s_3 s_4
右列自上至下分别为 s_5 s_6 s_7 s_8

图 8 物体运动轨迹
检测结果(ICA 方法)

3 结束语

本文将 ICA 理论应用于运动目标检测.从实验结果看,ICA 在图象分离方面具有较强的能力;从滤波角度来看,由于 ICA 是针对多观察图象的空域滤波技术,因此特别适合于序列图象处理和特征增强.目前 ICA 理论和算法还不很成熟,其中的很多内容还需要进一步完善,因此希望本文所讨论的内容能引起读者对 ICA 理论及应用研究的兴趣.

参 考 文 献

1 Hyvarinen A. Independent component analysis: A tutorial. http://www.cis.hut.fi/projects/ica/IJCNN99_tutorial2.html
2 Hyvarinen A. Survery on independent component analysis. <http://www.cis.hut.fi/appo/NCS99web.html>
3 Comon *et al.* Independent component analysis: A new concept? Signal Processing. 1994 36(3) 287314.

4 Delfosse N, Loubaton P. Adaptive blind separation of independent source: A deflation approach. Signal Processing, 1995 45 (1) 5983.
5 Stewart M, Bartlett, Sejnowski T. Viewpoint invariant face recognition using independent component analysis and attractor networks. In: Neural Information Processing Systems-Natural and Synthetic, Mozer M, Jordan M, Petsche T eds. Cambridge, MA: MIT Press, 1997, 9: 817823.
6 杨福生等. 独立分量分析及其在生物医学工程中的应用. 见 '99 中国生物医学电子学学术年会论文集(南京). 1999 3437.
7 余松煜,周源华,吴时光. 数字图象处理. 北京:电子工业出版社, 1987.
8 吴小培,冯焕清,周荷琴等. 独立分量分析在脑电信号预处理中的应用. 北京生物医学工程, 2000 20(4) 201205.
9 Castleman K R. Digital image processing. 北京:清华大学出版社, 1998.

吴小培 1966 年生,1988 年 6 月获电子科技大学硕士学位,现为中国科学技术大学博士生(在职),安徽大学副教授,硕士生导师.主要研究方向为信号处理理论及应用.

冯焕清 中国科学技术大学电子科学与技术系教授、博导.主要研究方向为生物医学信息处理、医学影像图象处理、生物系统建模与仿真、智能医疗仪器等.

周荷琴 中国科学技术大学自动化系教授、博导.主要研究方向为生物医学信息处理、医学影像图象处理、智能医疗仪器、计算机辅助教育等.

王 涛 中国科学技术大学电子科学与技术系讲师,博士.研究方向为生物医学信息处理、智能医疗仪器等.