

基于压缩感知的图像处理算法研究

陆 钊 朱晓姝

(玉林师范学院计算机科学与工程学院 玉林 537000)

(广西高校复杂系统优化与大数据处理重点实验室 玉林 537000)

摘 要 在对图像数据进行识别和恢复的过程中,由于图像的相似性,存在数据的稀疏性。在压缩感知恢复图像的过程中,由于缺乏对统计数据先验信息的利用,导致计算复杂度低,并且恢复精度低。针对此问题,采用压缩感知的改进算法对图像进行恢复,对矩阵的相似性和相似距离进行定义,根据定义应用主成分分析映射以及贝叶斯先验信息对图像的迭代恢复算法进行改进。实验结果显示,所提方法的准确性明显高于其他恢复算法,并且恢复的图像清晰度高。根据计算复杂度的对比,所提算法的计算复杂度低,计算时间少。

关键词 压缩感知,主成分映射,图像恢复,计算复杂度

中图法分类号 TP393 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2017.06.055

Research on Image Processing Algorithm Based on Compressed Sensing

LU Zhao ZHU Xiao-shu

(School of Computer Science and Engineering, Yulin Normal University, Yulin 537000, China)

(Guangxi Universities Key Lab of Complex System Optimization and Big Data Processing, Yulin 537000, China)

Abstract In the process of recognizing and restoring image data, data's sparsity usually occurs due to the similarity of images. In the process of compressed sensing image restoration, the lack of prior information on statistical data generally brings about higher computational complexity and lower restoring accuracy. This paper introduced a refined algorithm of compressed sensing to restore the images, and it defined similarity distances of the matrix as well. The similarity distances and similarity of the matrix are defined by the similarity of the image. Based on the present definition, the application of principal component analysis mapping and Bayesian prior information will enhance images' iterative recovery algorithm. Experimental results show that the proposed method is more accurate than other restoration algorithms and the images restored are of better definition. Comparatively speaking, the proposed algorithm has a lower computational complexity and consumes a shorter period of computational time.

Keywords Compressed sensing, Principal component mapping, Image restoration, Computational complexity

1 引言

在基于局部图像的压缩感知技术中,传统的局部图像由于缺乏大量图像数据支持,很难找到最优的重建图像或者感知图像。然而,根据局部样本的图像重建能够节省大量的内存和计算资源,所以具有很强的实用性。信号处理的理论知识显示,采样频率高于奈奎斯特速率,该信号保证没有混叠恢复。但是在实际的操作中,保证高于奈奎斯特采样速率会占用过多的资源,对大量的图像进行重建是不现实的。而压缩感知技术能够按照低于奈奎斯特速率的方式进行信号采样(由于图像中存在大量的不变元素,可以进行压缩)。压缩感知的原理是可以用于已知图像的信号压缩(即具有许多零或者趋近于零的变换系数,如离散余弦变换或者小波基),然而,图像信号通常含有非常大的数据量,特别是超分辨率图

像^[1-3]。因此,基于帧的感测和恢复可能需要大量的内存来存储,并且虽然具有 Hadamard 内核可以降低计算复杂度,但是仍然需要执行巨大的计算线性矩阵操作。另一种方法是基于块压缩感知,其信号处理单元具有小尺寸块,因为它需要小尺寸的测量矩阵,并且也鼓励独立的低成本小尺寸块恢复。此外,低子速率压缩感知允许更高效的感知传感器、模数转换器或感测时间。本文主要研究的对象为小块的图像恢复和低子速率的压缩感知方法。

传统的一般恢复方法(如基于凸优化方法^[4]、贪婪算法^[5]和贝叶斯压缩感知算法^[5])尽管具有高计算成本但不能确保恢复的图像质量。因此,一个可能的解决方案是补充测量具有一些先验的信号信息来恢复图像。文献[6]首次在压缩感知中采用了先验信息,使用了信号系数的大小。文献[7]进一步讨论了最小化中的重新加权过程。文献[8]采用概率先验

到稿日期:2016-12-31 返修日期:2017-02-16 本文受广西高校科学技术研究项目(KY2015LX300, KY2015YB241, 2013LX112),玉林市科技创业成果转化专项经费项目(16022009)资助。

陆 钊(1978—),男,硕士,讲师,主要研究方向为图像处理、数据挖掘;朱晓姝(1973—),女,教授,硕士生导师,主要研究方向为数据挖掘、分布式处理, E-mail: xszhu@csu.edu.cn(通信作者)。

的重构条件的稀疏性的方法,实现在一个贝叶斯框架中显示改进稀疏信号。在压缩感知的图像中,先验信息指的是关于图像的一些知识信号,例如空间平滑度或空间相关性,在像素之间有助于提高恢复图像的质量。文献[1-2]利用图像的空间相关性信号来提高信号的质量,用恢复时先前解码的块的稀疏性相关的空间预测当前块。但是,每个块的空间预测都是一个耗时的任务。在具有不同子速率的小波域中感应和恢复小波子带图像信号,取决于它们各自的稀疏水平。另外,文献[1-2]还修改了压缩采样匹配恢复方法,完成了加权过程,遵循视觉熵的概念得到了基于帧的小波系数。尽管存在某些局限性,如基于帧的性质和高计算需求,但至少能够清楚地表明图像信号的先验知识对于提高图像信号的压缩恢复性能非常重要。众所周知,图像的统计数据或视频信号随频率变化,其能量更多地集中在低频分量,所以在统计学上,低频分量相对于高频分量,更有可能具有较大幅度的变化。从中可以得到,在图像恢复中,低频分量的先验信息十分重要。在利用压缩感知恢复图像的算法中,本文提高压缩感知图像的回收性能,使用先验信息,采用加权处理,得到较好效果的恢复图像。不同于以往工作,本文采用不同的方式来避免算法的复杂度过高,给予低频信号较高的权重,根据不同频率信号的加权进行迭代算法的设计,形成一种迭代算法的投影图像恢复算法。

在许多应用中通常采用主成分分析通常来降低维数和进行压缩,而它根据数据相关性性质,通过复杂度较高的计算变换即特征分解经常阻碍其在资源严重受限的环境中使用。在未知信号系数和模型参数的图像中使用贝叶斯框架。算法使用分层形式的拉普拉斯模型,具有稀疏性的未知信号。基于稀疏先验信息提出的模型包括其高度稀疏性,并且基于此模型给出了一种迭代算法,能够快速重建图像信号,从而解决了图像重建和恢复中计算复杂度的问题。

2 系统模型

对于一个向量 f 代表一个 $N \times 1$ 维的未知信号,其为一个可以基于一组线性基进行压缩的信号,可以表示为 $f = \varphi w$ 。其中 w 是一个 $N \times 1$ 维的松弛信号,其中大部分的参数为 0。考虑到获取系统,可得到获取信号为:

$$y = \Phi' f + n \quad (1)$$

其中, $M \times 1$ 线性测量值为 y , 原始信号 f 由 $M \times N$ 的矩阵 $\Phi' = [\Phi_1', \Phi_2', \dots, \Phi_N']$ 和噪声向量 n 表示。可以重新写式(1)为:

$$y = \Phi w + n \quad (2)$$

其中, $\Phi = \Phi' \varphi$, 根据压缩感知理论,当测量次数比较小时,即 $M \ll N$, 在一定条件下,原始信号 f 可以通过利用适当的重建算法来非常精确地重建。压缩感知可以看作是传统的组合采集和压缩过程:传统方法中,信号以无损方式压缩,随后获得保留最重要特征的信号,例如最大小波系数。因为测量的数量 M 远小于未知系数 w 的数量,所以应采用重建机制来获得原始信号。利用 w 的稀疏特性,逆问题是 w 正则化约束的 l_0 范数,其等于 w 的非零项的个数。

对原始信号的近似通过求解以下优化问题获得:

$$\hat{w} = \arg \min_w \{ \|y - \varphi w\|_2^2 + \tau \|w\|_0 \} \quad (3)$$

一般来说,一个真正的稀疏信号的幅度降序或可压缩信号 x 在恢复时是未知的。其在视频图像或信号处理方面的实际意义是:可以合理地假设恢复图像缩放顺序和估计准确程

度,并可作为先验信息(称为估计幅度降序)。可以使用 DCT 系数的锯齿形扫描顺序,此方法已经广泛应用于图像和视频压缩等标准中,如 JPEG, H. 264 / AVC 和 H. 265 / HEVC。因此,本文所提的方案采用的先验信息为压缩感知恢复出来的幅度降序信息。

在贝叶斯建模中,所有未知数被视为随机的数量与指定的概率分布。未知信号 w 的先验信息分布为 $p(w|\gamma)$, 其中已知 w 的本质属性。所观察的信号 y 也是一个随机变量,其分布为 $p(y|w, \beta)$, 其中, $\beta = \frac{1}{\sigma^2}$ 是噪声方差的倒数。这些分布由参数 γ 和 β 的分布决定,被称为超参数,其分布为超先验信息。贝叶斯建模的压缩感知重建问题需要定义 $p(w, \gamma, \beta, y)$ 的联合分布,由贝叶斯定理可以得到:

$$p(w, \gamma, \beta, y) = p(y|w, \beta) p(w|\gamma) p(\gamma) p(\beta) \quad (4)$$

观测噪声是独立的,高斯为零,均值和方差等于 β^{-1} , 可以表示为:

$$p(y|w, \beta) = N(y|\varphi w, \beta^{-1}) \quad (5)$$

β 的先验信息可以表示为一个 Gamma 分布:

$$p(\beta|a^\beta, b^\beta) = \Gamma(\beta|a^\beta, b^\beta) \quad (6)$$

其中, Gamma 分布定义为:

$$\Gamma(\beta|a^\beta, b^\beta) = \frac{(b^\beta)^{a^\beta}}{\Gamma(a^\beta)} \beta^{a^\beta-1} \exp[-b^\beta \beta] \quad (7)$$

在定义中, $\beta > 0$ 代表超参数, $b^\beta > 0$ 表示一个度量参数, 并且 $a^\beta > 0$ 表示一个形状参数。 β 的均值和方差可以分别表示为:

$$E(\beta) = \langle \beta \rangle = \frac{a^\beta}{b^\beta} \quad (8)$$

$$\text{Var}(\beta) = \frac{a^\beta}{(b^\beta)^2} \quad (9)$$

Gamma 分布一般选择高斯分布的逆方差(精度)作为先验分布,因为其是 Gamma 分布的共轭值。这极大地简化了分析,并且包括均匀分布作为极限的情况。

在式(3)中改进的正则化公式等价于使用一个先验的拉普拉斯系数,即

$$p(w|\lambda) = \frac{\lambda}{2} \exp(-\frac{\lambda}{2} \|w\|_1) \quad (10)$$

应用式(5)和式(10)最大后验概率公式, $\tau = \frac{\lambda}{\beta}$ 。然而,拉普拉斯先验概率的公式不能处理贝叶斯分析,因为它不与式(5)中的条件分布共轭。为了解决此问题,使用分级先验概率方法。对于分级模型, w 的先验分布为:

$$p(w|\gamma) = \prod_{i=1}^N N(w_i|0, \gamma_i) \quad (11)$$

其中 $\gamma = (\gamma_1, \gamma_2, \dots, \gamma_N)$, 在层次结构的第二阶段中, Jeffrey's 的超先验概率独立应用在 γ_i 为:

$$p(\gamma_i) \propto \frac{1}{\gamma_i} \quad (12)$$

因为

$$p(\gamma_i) = \lim_{\varsigma \rightarrow 0} \Gamma(\gamma_i|\varsigma, 0) \quad (13)$$

可以从每个 w_i 的先验分布中获得一个样本,此样本独立于首先得到的样本 γ_i , 当 $\varsigma \rightarrow 0$, 采样服从正态分布 $N(0, \gamma_i)$ 。

先验模型条件是精度变量 $\alpha_i = \gamma_i^{-1}$ 。Gamma 超先验概率用于精度变量,即

$$p(\alpha_i|a_i^\alpha, b_i^\alpha) = \Gamma(\alpha_i|a_i^\alpha, b_i^\alpha) \quad (14)$$

在式(11)和式(14)中具有分层先验的公式通常称为相关向量机或稀疏贝叶斯学习。形状和比例参数分别为 $\alpha_i^s = 1$, $b_i^s = 0$, 从而获得这些参数的非均匀信息分布。

当使用非先验信息 α_i 时, $p(\alpha_i | \alpha_i^s, b_i^s)$ 变为:

$$p(\alpha_i | 1, 0) = \lim_{\xi \rightarrow 1} \Gamma(\alpha_i | \xi, 0) \quad (15)$$

重要的是, 当 γ_i 变为 α_i 时, 它们相应的最大后验估计不相关。基于以上模型, 在本文中使用拉普拉斯先验信号系数。为了克服拉普拉斯分布与观测不共轭的缺点, 采用分层方法, 用以下的超先验值 γ_i 。

$$p(\gamma_i | \lambda) = \Gamma(\gamma_i | 1, \lambda/2) = \frac{\lambda}{2} \exp(-\frac{\lambda \gamma_i}{2}) \quad (16)$$

应用式(11)的高斯模型 $p(w | \gamma)$ 可以得到:

$$p(w | \lambda) = \frac{\lambda^{\frac{N}{2}}}{2^N} \exp(\sqrt{\lambda} \sum_i |w_i|) \quad (17)$$

最后, 可以得到超先验信息为:

$$p(\lambda | v) = \Gamma(\lambda | \frac{v}{2}, \frac{v}{2}) \quad (18)$$

3 迭代加权先验信息算法

迭代算法可以解决线性求逆过程中的病态矩阵问题, 对于最原始的问题 $y = \Phi x$, 可以利用下式解决。

$$x^{(n+1)} = x^{(n)} + \Phi^T (y - \Phi x^{(n)}) \quad (19)$$

这种迭代就是将限制条件进行映射, 映射到第 n 个状态, 当然投影应用于逆问题的压缩感知有一个约束下的一般概念子空间的联合, 约束有助于缩小空间。在这个意义上, 它的解决方案更容易、更快找到。但是, 由于不同程度的解空间减少, 压缩感知恢复图像的投射性能与约束的定义及其关联映射有关。本文采用主成分分析的映射方式, 主成分分析为: 考虑 M 个向量组成的矩阵, 记为 $X = [x_1, \dots, x_M]$, 其中 $x_m \in R^N$, 假设向量的均值为 0, 而 X 的协方差矩阵 $\Sigma = XX^T/M$, 对于一个给定向量 x_m , 其主成分分析应用线性转化为 $\tilde{x}_m = W^T x_m$, 其中转换矩阵 W 是矩阵 Σ 的特征值分解。

$$\Sigma = W \Lambda W^T \quad (20)$$

其中, W 包含 N 个单位特征值列向量。

接下来, 将转换矩阵投影到一个子空间, 以方便后续压缩。具体来说, 假设有 K 个正交向量 p_k , 这形成了 K 维子空间 P , 此空间提供了正交基 $P = [p_1 \dots p_K]$ 。定义 P 为正交矩阵, 其维度为 $N \times K$ 。接着 x_m 映射到空间 P , $y_m = PP^T x_m$, 所以映射向量 $\tilde{Y} = [\tilde{y}_1 \dots \tilde{y}_M]$, 则协方差矩阵为:

$$\tilde{\Sigma} = \frac{\tilde{Y} \tilde{Y}^T}{M} = P^T \Sigma P \quad (21)$$

在经典的特征值计算问题和矩阵的特征向量中, 多个解决方案找到包含近似的子空间序列, 构成精度增加的特征向量子空间。因此, 解决关键问题的方法是生成近似给定子空间内的特征向量。用于这种子空间近似的最著名的方法是 Rayleigh-Ritz 理论, 因此所讨论的矩阵是实的、对称协方差矩阵 Σ 。Rayleigh-Ritz 理论描述了 Σ 和 $\tilde{\Sigma}$ 特征向量。 K 个特征值 $\lambda_k(\Sigma)$ 可以定义为:

$$u_k = P \tilde{u}_k, 1 \leq k \leq K \quad (22)$$

其中, $\tilde{u}_k$ 是 $\tilde{\Sigma}$ 的特征向量, 注意 $\|u_k\|_2 = 1$, 最后定义归一化映射 v_n 为:

$$v_n = \frac{PP^T w_n}{\|PP^T w_n\|_2} \quad (23)$$

在迭代方法中, 应用此映射方法可以解决收敛速度慢、计算复杂度高的问题, 得到的算法如下所示。

1. 输入: 初始化 $x^{(0)}$, 收集向量 y , 测量 Φ , 和加权矩阵 w , 并且令 $n=0$
2. 对 y 的数据进行 PCA 投影, 如式(23)所示
3. 当投影矩阵达到预定值 η , 则
 - 3.1 更新过程为 $x_u^{(n+1)} = x^{(n)} + \Phi^T (y - \Phi x^{(n)})$
 - 3.2 根据加权矩阵, 得到加权恢复值 $x^{(n+1)} = w x_u^{(n)}$
 - 3.3 $n = n + 1$
4. 结束
5. 输出恢复的数据 $\hat{x} = x^{(n)}$

4 算法性能分析

对于压缩感知算法来说, 其算法性能主要有两部分: 1) 压缩感知恢复的图像的误差; 2) 压缩感知算法的收敛性。首先考虑误差。给定噪声测量向量, $y = \Phi x + n$, 其中 n 是一个噪声向量。在迭代到第 $n+1$ 步时, 可以提供一种近似 $x^{(n+1)}$, 则恢复的误差为 $r^{(n+1)} = x - x^{(n+1)}$, 满足

$$r^{(n+1)} = Q r^{(n)} + (I - W) x - W \Phi^T n \quad (24)$$

其中, I 为单位矩阵, 并且 $Q = W(I - \Phi^T \Phi)$, 因为 $\|Q\|_2 \leq$

$\max_{0 \leq i \leq N-1} w_i$, 若 $\|\Phi\|_2 \leq 1$, 则可以得到以下结论:

$$\begin{aligned} \|\Phi\|_2 &= \|W(I - \Phi^T \Phi)\|_2 \\ &\leq \|W\|_2 \|I - \Phi^T \Phi\|_2 \\ &\leq w_{\max} \|I - \Phi^T \Phi\|_2 \end{aligned} \quad (25)$$

由于 $y = \Phi x$, 根据矩阵的变换, 可以得到:

$$\|I - \Phi^T \Phi\|_2 = \max_{\|x\|=1} |x^T (I - \Phi^T \Phi)^T (I - \Phi^T \Phi) x| \quad (26)$$

式(26)可以变为:

$$\|I - \Phi^T \Phi\|_2 = \max_{\|x\|=1} |x^T x - 2y^T y + y^T \Phi^T \Phi y| \quad (27)$$

由于 $0 \leq y^T \Phi^T \Phi y \leq \|\Phi^T\|_2 \|y\|_2$, 因此可以得到:

$$-2x^T x \leq -2y^T y \leq -2y^T y + y^T \Phi^T \Phi y \leq 0 \quad (28)$$

从而可以得到条件参数 $c = \|\Phi^T\|_2 < 1$ 。所以当条件参数小于 1 时, 其恢复误差的边界:

$$\|r^{(n+1)}\|_2 \leq c^{n+1} \|r^{(0)}\|_2 + (1 + c^{n+1}) e_b \quad (29)$$

其中, $e_b = \|(I - Q)^{-1} (I - W) x\|_2 + \|(I - Q)^{-1} W \Phi^T e\|_2$ 。

对式(25)和式(29)进行求导, 可以得到以下结论: e_b 与 $T = (I - Q)^{-1} (I - W)$ 和 $T_e = (I - Q)^{-1} W \Phi^T$ 两个参数有关, 其二阶矩越小, 其恢复误差也就越小。

然后对收敛的性质进行分析。根据第一个误差性质的分析, 得到条件参数 $c = \|\Phi^T\|_2 < 1$, 所提算法的收敛速率为 η 。其中 η 的上界为:

$$\eta \leq \|(I - \Phi^T \Phi) W\|_F / N \quad (30)$$

其中, $\|\cdot\|_F$ 代表弗罗贝尼乌斯范数, 并且

$$\eta = \lim_{n \rightarrow \infty} \{ \|x^{(n+1)} - \hat{x}\|_2 / \|x^{(n)} - \hat{x}\|_2 \} \quad (31)$$

如果其收敛速度值较小, 则所提算法收敛速度较快。

5 实验结果

实验采用了 4 个标准的 512×512 灰度图像, 其包括各种不同的特性, 以显示所提恢复方法的有效性。所有测试图像被分割为 8×8 , 16×16 或 32×32 的块, 其中没有太小或对于独立的感知和恢复来说太大的图像块, 如图 1 所示。



图1 实验图像

实验使用独立和相同分布高斯随机矩阵作为恢复模型,因为图像数据具有统计先验性,并满足 RIP 条件压倒性概率作为先验信息。每个测试模拟 5 次以中和在创建恢复模型中的随机性。注意所提算法不仅仅限于基于块或高斯随机矩阵,同时也适用于任何其他压缩感知恢复矩阵(因为所提算法的重点是如何在压缩感知恢复算法中应用先验信息知识)。

根据低子速率应用的预期目标的压缩感知,采用采样子图像 0.1、0.2 和 0.3,其中测量次数的减少显著(相当于 10 倍、5 倍或 3.3 倍的减少采样率)。为了对比所提方法在图像恢复和重建上的质量,将本文与具有代表性的方法进行对比,对比方法为 l_1 重建^[9]、TWIST^[10] 和 TVAL3^[11]。其恢复误差和复杂度对比如表 1 和表 2 所列,其恢复图像对比如图 2 所示。

表1 恢复误差对比/dB

块尺寸	恢复误差			
	8×8	16×16	32×32	平均值
l_1 重建	3.98	2.97	2.75	3.97
TWIST	7.44	5.03	3.92	5.95
TVAL3	1.73	1.73	0.20	0.91
所提算法	-0.17	-4.73	-4.78	-3.58

表2 时间消耗对比/s

块尺寸	恢复误差			
	8×8	16×16	32×32	平均值
l_1 重建	20.34	31.97	119.96	43.09
TWIST	103.30	41.99	16.59	63.52
TVAL3	136.58	58.81	19.28	0.91
所提算法	13.22	6.63	4.80	9.24



图2 算法恢复图像对比

加权参数 w_i 会决定错误边界 e_b 的增加和减少,如果是锯齿形(作为先验信息给出)与实际幅度降序,误差项 e_b 将会产生很小的误差,恢复出高质量的图像。根据分析,可以给出相关的锯齿形的参数,此参数的幅度值的降序可以由式(32)表示:

$$FZ = \frac{1}{L} \frac{1}{N} \sum_{i=0}^{L-1} \sum_{j=0}^{N-1} |X_d^i(j) - X_{zg}^i(j)| \quad (32)$$

结束语 本文根据压缩感知的原理,针对恢复迭代算法计算复杂度高、收敛速度慢的缺点,应用了先验信息和主成分分析映射,在保证恢复精度的条件下,提高了收敛速度,实验从效果和数据方面印证了所提算法的优越性。

参考文献

- [1] CHEN G, ZHANG J, LI D. Fractional-order total variation combined with sparsifying transforms for compressive sensing sparse image reconstruction[J]. Journal of Visual Communication and Image Representation, 2016, 38(c): 407-422.
- [2] MUSIC J, MARASOVIC T, PAPIC V, et al. Performance of compressive sensing image reconstruction for search and rescue[J]. IEEE Geoscience and Remote Sensing Letters, 2016, 13(11): 1739-1743.
- [3] LIAN Q S, HAN M, SHI B S, et al. Compressed sensing algorithm fused the cospase analysis model and the synthesis sparse model[J]. Acta Electronica Sinica, 2016, 44(3): 613-619. (in Chinese)
- 练秋生, 韩敏, 石保顺, 等. 融合解析模型和综合模型的压缩感知算法[J]. 电子学报, 2016, 44(3): 613-619.
- [4] BACCI A, GIUSTI E, TOMEI S, et al. Time-slotted FMCW MIMO ISAR with compressive sensing image reconstruction[C]// 2015 3rd International Workshop on Compressed Sensing Theory and its Applications to Radar, Sonar and Remote Sensing (CoSeRa). IEEE, 2015: 229-233.
- [5] WANG Y, QIAO Q Q, YANG X Y, et al. Sparse Bayesian reconstruction combined with self-adaptive dictionary learning [J]. Journal of Xidian University (Natural Science Edition), 2016, 43(4): 1-4. (in Chinese)
- 王勇, 乔倩倩, 杨笑宇, 等. 结合自适应字典学习的稀疏贝叶斯重构[J]. 西安电子科技大学学报(自然科学版), 2016, 43(4): 1-4.
- [6] CAO Y Q, BAI S, CAO M W. Image compression sampling based on adaptive block compressed sensing[J]. Journal of Image and Graphics, 2016, 21(4): 416-424. (in Chinese)
- 曹玉强, 柏森, 曹明武. 图像自适应分块的压缩感知采样算法[J]. 中国图象图形学报, 2016, 21(4): 416-424.
- [7] CHEN J, GAO Y, MA C, et al. Compressive Sensing Image Reconstruction Based on Multiple Regulation Constraints[J]. Circuits, Systems, and Signal Processing, 2017, 36(4): 1621-1638.
- [8] ZHOU Y, ZENG F Z. An Image Retrieval Algorithm Based on Two-Dimensional Compressive Sensing and Hierarchical Feature [J]. Acta Electronica Sinica, 2016, 44(2): 453-460. (in Chinese)
- 周燕, 曾凡智. 基于二维压缩感知和分层特征的图像检索算法[J]. 电子学报, 2016, 44(2): 453-460.
- [9] HORNING M, LIN M, SRINIVASAN S, et al. Compressed Sen-

sing Environmental Mapping by an Autonomous Robot[C]//Proc. Second Int'l. Workshop on Robotic Sensor Networks, Seattle, WA, 2015.

- [10] WEIZMAN L, ELDAR Y C, BASHAT D B. Compressed sensing for longitudinal MRI: An adaptive-weighted approach[J]. Medical physics, 2015, 42(9): 5195-5208.
- [11] NIARAKI A S, KIM K. Ontology based personalized route planning system using a multi-criteria decision making approach[J].

Expert Systems with Applications, 2009, 36(2): 2250-2259.

- [12] WANG W W, WANG H Q, LU H L, et al. PET/CT Medical Image Fusion Algorithm Based on Compressive Sensing and NSCT-PCNN[J]. Journal of Chongqing University of Technology (Natural Science), 2016, 30(2): 101-108. (in Chinese)
- 王文文, 王惠群, 陆惠玲, 等. 基于压缩感知和 NSCT-PCNN 的 PET/CT 医学图像融合算法[J]. 重庆理工大学学报(自然科学), 2016, 30(2): 101-108.

(上接第 311 页)

致, 后方运动快的会赶上前面运动慢的个体, 从而造成扎堆现象。白色个体没有情绪, 运动最慢, 在图 8(3)(c)中, 当白色个体运动到第一个门口时, 其他个体大都疏散完成。而图 8(2)中个体不具有情绪, 所有个体都以相近速度行走, 人员在运动过程中的分布比较均匀, 既不能体现个体恐慌时的状态, 又不能体现个体的差异性, 与真实运动差别较大。

结束语 本文提出了一种个性化情绪感染的人群动画生成方法。该方法将基于个性的 P-Durupinar 情绪感染模型与人群运动耦合。为了实现该方法, 本文构建了基于个性化情绪感染的人群运动框架: 建立个性化 P-Durupinar 情绪感染模型并将其与人群运动耦合, 通过真实感渲染得到预期人群动画效果。实验结果充分验证了个性对情绪的影响, 并且本文方法能够更加真实地模拟情绪感染下的人群运动。下一步工作是进一步完善情绪感染模型, 充分考虑分组等对情绪感染的影响, 增强人群运动行为的真实性。

参考文献

- [1] SHEN J J, WANG X J, CHAO Q W, et al. Fast and large-scale crowd authoring based on sample [J]. Chinese Journal of Computers, 2014, 37(3): 621-631. (in Chinese)
- 申晶晶, 王欣捷, 杪倩文, 等. 基于样本的大规模人群快速创作[J]. 计算机学报, 2014, 37(3): 621-631.
- [2] DURUPINAR F. From audiences to mobs: Crowd simulation with psychological factors [D]. Bilkent University, 2010.
- [3] PATIL S, VAN DEN BERG J, CURTIS S, et al. Directing crowd simulations using navigation fields[J]. IEEE Transactions on Visualization and Computer Graphics, 2011, 17(2): 244-254.
- [4] TSAI J, BOWRING E, MARSELLA S, et al. Empirical evaluation of computational fear contagion model crowd dispersions [J]. Autonomous Agents and Multi-Agent Systems, 2013, 27(2): 200-217.
- [5] DODDS P S, WATTS D J. A generalized model of social and biological contagion [J]. Journal of Theoretical Biology, 2005, 232(4): 587-604.
- [6] DURUPINAR F, PELECHANO N, ALLBECK J M, et al. How the ocean personality model affects the perception of crowds [J]. IEEE Computer Graphics and Applications, 2011(3): 22-31.
- [7] GUY S J, KIM S, LIN M C, et al. Simulating heterogeneous crowd behaviors using personality trait theory[C]//Proceedings of the ACM SIGGRAPH Eurographics Symposium on Computer Animation. ACM, 2011: 43-52.
- [8] KIM M, HYUN K, KIM J, et al. Synchronized multi-character motion editing [J]. ACM Transactions on Graphics (TOG),

2009, 28(3): 79.

- [9] LIU Z, JIN W, HUANG P, et al. An emotion contagion simulation model for crowd events [J]. Journal of Computer Research and Development, 2013, 50(12): 2578-2589. (in Chinese)
- 刘箴, 金炜, 黄鹏, 等. 人群拥挤事件中的一种情绪感染仿真模型研究[J]. 计算机研究与发展, 2013, 50(12): 2578-2589.
- [10] LIU Z. Personality Model of Virtual Character [J]. Computer Science, 2008, 35(12): 203-206. (in Chinese)
- 刘箴. 智能体的一种个性模型[J]. 计算机科学, 2008, 35(12): 203-206.
- [11] JIANG H, XU W, MAO T, et al. Continuum crowd simulation in complex environments[J]. Computers & Graphics, 2010, 34(5): 537-544.
- [12] WANG Z Q, MAO T L, JIANG H, et al. Guarder: virtual drilling system for crowd evacuation under emergency scheme [J]. Journal of Computer Research and Development, 2010, 47(6): 969-978. (in Chinese)
- 王兆其, 毛天露, 蒋浩, 等. 人群疏散虚拟现实模拟系统——Guarder[J]. 计算机研究与发展, 2010, 47(6): 969-978.
- [13] ZHOU M X, CHENG K, WANG Z X. Improved ant colony algorithm with planning of dynamic path [J]. Computer Science, 2013, 40(1): 314-316. (in Chinese)
- 周明秀, 程科, 汪正霞. 动态路径规划中的改进蚁群算法[J]. 计算机科学, 2013, 40(1): 314-316.
- [14] BAYAZIT O B, LIEN J M, AMATO N M. Better Group Behaviors in Complex Environments using Global[J]. Artificial Life, 2003, 8: 362.
- [15] VAN D B J, LIN M, MANOCHA D. Reciprocal Velocity Obstacles for real-time multi-agent navigation [C]//Proceedings of IEEE International Conference on Robotics & Automation. 2008: 1928-1935.
- [16] JUNG C G, et al. Psychology and Alchemy[M]. Princeton University Press, 1980.
- [17] YU L P, LIU Z, LIU T T, et al. Sampling speed based emotion contagion model for panic crowd [J]. Application Research of Computers, 2015, 32(10): 3172-3178. (in Chinese)
- 于力鹏, 刘箴, 刘婷婷, 等. 一种基于速度采样的恐慌人群情绪感染模型[J]. 计算机应用研究, 2015, 32(10): 3172-3178.
- [18] SUN Y C, LIU H, ZHANG G J. Cross platform system for real-time crowd simulation [J]. Journal of Chinese Computer Systems, 2015, 36(4): 863-867. (in Chinese)
- 孙云晨, 刘弘, 张桂娟. 支持跨平台的实时人群运动仿真系统[J]. 小型微型计算机系统, 2015, 36(4): 863-867.
- [19] Ember121. Students evacuate school during earthquake[OL]. <https://www.youtube.com/watch?v=4M45popnjs8>.