

# 基于回归函数结合局部自相似的单帧图像超分辨率算法

赵丽<sup>1,2</sup>, 齐兴斌<sup>1</sup>, 李雪梅<sup>1</sup>

(1. 山西大学 计算机工程系, 太原 030013; 2. 北京航空航天大学 计算机学院, 北京 100191)

**摘要:** 启发于过完备字典中稀疏线性组合的高分辨率图像的块与其对应的低分辨率局部块能很好地匹配, 提出一种回归函数结合局部自相似的单帧图像超分辨率算法; 该算法结合了实例图像块的学习和局部自相似图像块的学习, 实例图像块的局部回归避免了从低分辨率到高分辨率图像块映射的病态性问题; 通过局部自相似实例图像块学习获得非线性映射函数的一阶近似, 从而获得低分辨率图像块相对应的高分辨率图像块, 克服了实例图像块算法不足的问题; 实验采用峰值信噪比 (Peak Signal to Noise Ratio, PSNR) 和均方误差 (Root-mean-square error, RMSE) 比较各算法效果; 从实验结果数据可以看出, 大多数情况下, 提出的算法具有最高的峰值信噪比和最低的均方根误差, 从实验结果图可以看出, 提出的算法的纹理保留的最好, 图像自然性最好, 且运行时间也少于其他几种较新的算法, 表明提出的算法更适合用于解决实际问题。

**关键词:** 完备字典; 稀疏线性组合; 超分辨率; 单帧; 局部自相似; 局部回归

## A Single Frame Super Resolution Algorithm Based on Fusion of Regression Function and Local Self-similarity

Zhao Li<sup>1,2</sup>, Qi Xingbin<sup>1</sup>, Li Xuemei<sup>1</sup>

(1. School of Computer, Shanxi University, Taiyuan 030013, China;

2. School of Computer, Beijing University of Aeronautics and Astronautics, Beijing 100191, China)

**Abstract:** Inspired by that high resolution patches, which is the sparse linear combining of the over complete dictionary, can well match the low resolution patches. A new super resolution algorithm based on regression function and local self-similarity is proposed. Compared with the general single-frame super resolution algorithm, the advantage of the proposed algorithm combines the learning of example patches and local self-similarity. Local regression of example patches can avoid the ill-posed problem of LR patches to HR patches. Another aspect, the first-order approximation of the nonlinear mapping function obtained by local self-similar example patches can get the pair of the LR patches corresponding to the HR patches. That overcomes the shortcomings of examples patch algorithms. In this paper, Peak Signal to Noise Ratio (PSNR) and Root-mean-square error (RMSE) is used to compare the results of the algorithms. The data results show that the proposed algorithm has the highest PSNR value and the lowest MSE value in most cases. The experimental graph results show that the image's texture can be reserved best, the nature of the images is very good. And the execution time of proposed algorithm is less than several other algorithms, which indicates the proposed algorithm is more suitable for applying to settle practical issue.

**Keywords:** over complete dictionary; sparse linear combining; super resolution; single frame; local self-similarity; local regression

## 0 引言

超分辨率 (super-resolution, SR)<sup>[1]</sup>在实际应用中十分广泛和活跃, 例如军事超视距设备不仅装备了非常好的高清摄像头, 还有较好的 SR 嵌入式算法<sup>[2]</sup>; SR 在地球卫星上的应用也比较早<sup>[3]</sup>; SR 在医学上的微成像<sup>[4]</sup>也相当重要。从硬件设备上提高分辨率已经基本到了极限, 从软件算法上获得高分辨

率 (high resolution, HR) 图像是代价低, 实用性好的途径。

SR 的目标是从一个或多个低分辨率 (low resolution, LR) 图像产生一个或多个 HR 图像的过程。SR 算法一般分为 3 大类: 基于插值的算法<sup>[5]</sup>、基于重建的算法<sup>[6-7]</sup>和基于学习的算法<sup>[8-10]</sup>。

本文给出一种新的单帧图像 SR 算法, 不同于之前的先验单帧 SR, 本文使用基于字典的局部回归和局部自相似相结合方法。使用局部自相似<sup>[10]</sup>从 LR 图像重建训练一个字典; 然后使用得到的字典学习从 LR 图像块到 HR 图像块的非线性映射的一阶近似, 有效避免了从 LR 到 HR 图像块映射的病态性问题。

## 1 数学模型

一般情况下, 超分辨率问题采用前向的数据模型来表达。其表达方式有多种, 比较受欢迎的有文献 [11] 的形式。其修

收稿日期: 2015-10-16; 修回日期: 2015-12-04。

基金项目: 山西省基础研究项目计划—青年科技研究基金 (2014021039-6)。

作者简介: 赵丽 (1980-), 女, 硕士, 副教授, 主要从事算法设计、图像处理等方向的研究。

李雪梅 (1962-), 女, 教授, 主要从事算法设计、图像处理等方向的研究。

改后的模型表达式为:

$$Y_k = D_k H_k F_k X + n_k, k = 1, \dots, N \quad (1)$$

式中,  $F_k$  是  $X$  与第  $k$  帧  $Y_k$  的几何运动算子, 大小  $r^2 M^2 \times r^2 M^2$ 。 $r$  是分辨率变化因子。 $X$  可以写成向量形式, 大小  $r^2 M^2 \times r^2 M^2$ 。 $Y_k$  大小是  $M^2 \times 1$ 。点扩散函数用模糊矩阵  $H_k$  表示, 大小为  $r^2 M^2 \times r^2 M^2$ 。 $D_k$  代表抽样算子, 大小为  $M^2 \times r^2 M^2$ 。 $n_k$  是系统加性噪声, 大小为  $M^2 \times 1$ 。 $N$  是可用于处理的 LR 图像帧数。在式 (1) 中,  $n_k$  和  $H_k$  分别代表噪声和模糊矩阵, 这两项都是已经假设好的, 例如  $n_k$  大多用高斯白噪声代表,  $H_k$  大多以匀速直线运动模糊为研究对象, 或者直接不研究将其置为单位矩阵。另外当  $k > 1$  时, 模型就是多帧超分辨率问题, 当  $k = 1$  时, 模型是单帧超分辨率问题。

数学模型建立好之后, 要解决的问题就是如何获得潜在的高质量图像  $X$ , 实质上这就是一个估计问题。一个未知的 HR 估计并不仅仅取决于 LR 图像的质量。它同时也取决于很多假设, 例如噪声和运动模型。这些模型并不一定都正确, 只是一些常用的经验知识, 不过可以做近似处理。

本文研究的是单帧超分辨率问题, 即  $k = 1$ , 没有运动模糊和复杂的几何运动, 即  $H_k$  和  $F_k$  为单位矩阵, 因为本文讨论的是结合字典的学习方法, 研究分辨率因子增强后的图像纹理和自然性的变化, 因此式 (1) 可以简化为:

$$Y = DX + n \quad (2)$$

定义 LR 图像  $X_0 \in R^{K_1 \times K_2}$  是  $Y_0 \in R^{K_1 \times K_2}$  通过高斯滤波后的低频图像。使用立方插值, 采样因子为  $r$ , 对  $X_0$  上采样得到  $Y \in R^{K_1 \times K_2}$ 。 $Y$  是未知 HR 图像  $X \in R^{K_1 \times K_2}$  的低频图像的近似图像。本文的目标是从  $X_0$ ,  $Y_0$ ,  $Y$  中的已知信息估计  $X$ 。

图 1 是本文的 SR 问题描述图。在位置  $(i, j)$  中, 对于图像  $Y$  中的每个图像块  $y$ , 它对应的自相似的图像块  $y_0$  在  $Y_0$  中的位置应该是  $i_s = \lfloor i/r + 0.5 \rfloor$ ,  $j_s = \lfloor j/r + 0.5 \rfloor$ 。类似地, 可以从  $X_0$  中获得  $x_0$ , 该图像块  $x_0$  是  $y_0$  的 HR 模块。图像块对  $\{y_0, x_0\}$  包含 LR/HR 图像先验样本对, 从中可以用一阶回归模型来估计 HR 图像块  $x$  对应 LR 图像块  $y$ 。使用图像  $Y$  的重叠块来重复这个过程, 这样集合所有获得的图像块  $x$  就获得 HR 的图像  $X$ 。




图 1 本文单帧 SR 问题描述

## 2 提出的算法

### 2.1 局部回归

基于图像块的单帧 SR 问题可以看做是一个回归问题, 例如寻找从 LR 图像块空间到 HR 图像块空间的非线性映射关系。由于反问题的病态性<sup>[12]</sup>, 学习这种非线性映射函数需要很好的图像先验知识和适当的正则化。自相似图像块是推理

HR 图像中  $y$  的非常好的先验知识<sup>[13]</sup>。假设映射函数  $f$  是连续可导的, 则有下列的泰勒表达式:

$$\begin{aligned} x &= f(y) = f(y_0 + y - y_0) = \\ &f(y_0) + \nabla f^T(y_0)(y - y_0) + O(\|y - y_0\|_2^2) \approx \\ &x_0 + \nabla f^T(y_0)(y - y_0). \end{aligned} \quad (3)$$

等式 (3) 是映射函数  $f$  的一阶近似。这样做的好处显而易见, 因为直接学习函数  $f$  本身比较麻烦, 而学习映射函数  $f$  的梯度  $\nabla f$  将使问题变得简单直接。

具体方法是使用先验实例对  $\{y_0, x_0\}$  构建的字典来学习映射梯度  $\nabla f$ , 给定 LR 输入图像块  $y$ , 首先搜索它的自相似实例块对  $\{y_0, x_0\}$ , 然后使用训练字典寻找  $\nabla f(y_0)$ , 最后运用一阶近似来计算 HR 图像块  $x$ 。由于上采样和下采样的离散重采样过程, 本文期望找到在  $(i_s, j_s)$  的  $3 \times 3$  邻域多个近似的实例图像块, 即 9 个图像块。为了降低回归方差, 通过加权平均对每个结果回归且合并。给定局部自相似实例图像块对  $\{y_0, x_0\}_{i=1}^9$ , 可以得出:

$$x = \sum_{i=1}^9 (x_{0i} + \nabla f^T(y_{0i})(y - y_{0i})) w_i \quad (4)$$

式 (4) 中,  $w_i = (1/z) \exp\{-\|y - y_{0i}\|_2^2 / 2\sigma^2\}$ ,  $z$  为归一化因子。

### 2.2 字典学习

映射梯度  $\nabla f$  的字典方法是由文献 [15] 提出, 目的是保证细节增强。这种方法使用高分辨率图像建立一个完备字典  $D_h \in R^{m \times K}$ , 即一个  $n \times K$  的矩阵, 其中  $K$  列代表一个尺寸为  $K$  的“原子”, 一个“原子”就是一个稀疏系数向量。在 HR 图像  $X$  中的图像块  $x \in R^n$  可以被重新表示为以下字典  $D_h$  的原子的稀疏线性组合形式:

$$x \approx D_h \alpha, \text{ 其中 } \|\alpha\| \ll K, \alpha \in R^K \quad (5)$$

在观测 LR 图像中, 图像块  $y$  可以使用相应的 LR 字典  $D_l$  和相同的稀疏系数向量  $\alpha$  组合表示。这是由于 HR 图像块的字典  $D_h$  和对应的 LR 图像块的字典  $D_l$  联合训练的结果。

对于给定的输入 LR 图像块  $y$ , 可以定义稀疏解向量为:

$$\alpha^* = \min_{\alpha} \|GD_l \alpha - Gy\|_2^2 + \lambda \|\alpha\|_1 \quad (6)$$

式 (6) 中,  $G$  是特征提取算子用于增强高频成分, 式 (7) 是本文使用的一维滤波器:

$$\begin{aligned} g_1 &= [-1, 0, 1]; g_2 = [-1, 0, 1]^T; \\ g_3 &= [1, 0, -2, 0, 1]; g_4 = [1, 0, -2, 0, 1]^T \end{aligned} \quad (7)$$

$G$  作为上述一维图像滤波器的串联响应。解向量  $\alpha^*$  的稀疏性由  $\lambda$  控制。为了在抑制噪声和其他锯齿同时, 增强纹理细节, 需要求解解向量  $\alpha^*$  的非零系数的数目, 因为增加非零系数的数目提高了纹理信息, 而且也提高了噪声的抵抗性。本文使用图像块的标准偏差 ( $\sigma$ ) 来表征局部纹理,  $\lambda$  的经验值表示如下:

$$\lambda = \begin{cases} 0.5, & \text{如果 } \sigma < 15 \\ 0.1, & \text{如果 } 15 \leq \sigma \leq 25 \\ 0.02, & \text{其他情况} \end{cases} \quad (8)$$

这些  $\sigma$  的范围划分适用于 8 比特灰度图像, RGB 彩色图像与之类似, 只不过多了两个通道。对于给定  $y_0$  映射梯度  $\nabla f$  表示为  $\nabla f(y_0) = D_h \alpha^*$ 。

由于本文的目标是在抑制噪声的同时, 增强纹理信息和图像自然性, 因此利用双边滤波器作为降采样因子, 而不是高斯模糊算子。字典训练开始于对应 LR 图像和 HR 图像的自相似实例图像块组  $\{y_0, x_0\}_{i=1}^m$  的采样。产生的 HR 图像块向量为  $\mathbf{X}_h = \{x_{0_1}, x_{0_2}, \dots, x_{0_m}\}$ , LR 图像块的特征向量为  $\mathbf{Y}_h = \{y_{0_1}, y_{0_2}, \dots, y_{0_m}\}$ , 图像块差的向量为  $\mathbf{E} = \{x_{0_1} - y_{0_1}, x_{0_2} - y_{0_2}, \dots, x_{0_m} - y_{0_m}\}$ , 训练使用图像块差向量  $\mathbf{E}$ , 而不使用 HR 图像块向量  $\mathbf{X}_h$ , 残差图像块具有更好的表征能力, 其中级联的字典定义如下:

$$\mathbf{X}_c = \left[ \frac{\sqrt{N/(N+M)}\mathbf{E}}{\sqrt{M/(N+M)}\mathbf{Y}_l} \right], \mathbf{D}_c = \begin{bmatrix} \mathbf{D}_h \\ \mathbf{D}_l \end{bmatrix} \tag{9}$$

式中,  $N$  和  $M$  是 LR 和 HR 图像块的向量形式的元素个数。优化字典可以被计算如下:

$$\min_{D_h, D_l, Z} \|\mathbf{X}_c - \mathbf{D}_c \mathbf{Z}\|_2^2 + \lambda \|\mathbf{Z}\|_1$$
$$s.t. \|\mathbf{D}_{c_i}\|_2 \leq 1, \quad i = 1, \dots, K \tag{10}$$

训练的方式采用迭代方法, 使用文献 [14] 的技术交替优化  $\mathbf{Z}$  和  $\mathbf{D}_c$ 。

3 实验与分析

仿真实验在配置为 Windows XP 操作系统、intel 酷睿 II 处理器、2.53 GHz 主频、4 GB RAM 的笔记本计算机进行。使用 MATLAB 7.0 平台。

3.1 算法参数设置及评价函数

本文选择的图像块尺寸为  $a = 3$ , 迭代缩放因子为  $r = 2$ 。输入的 LR 图像  $X_0$  双 3 次插值生成目标 HR 图像  $X$ , 滤波标准差为 0.4, 输入的 LR 图像  $X_0$  的低频分量的低频分量  $Y_0$ 。对于干净的图像, 本文使用最近邻图像块一阶回归, 而在噪声图像的情况下, 使用所有 9 个邻域图像块回归的稳健估计, 其中  $\sigma$  是用于计算权重  $w_i$ , 且唯一需要调整变量, 如式 (4) 中所示。原子数  $K$  取 512, 用来训练和构建字典  $D_h$  和  $D_l$ 。

本文使用图像的峰值信噪比 (peak signal to noise ratio, PSNR) 和均方差表征估计得到 HR 图像的好坏, PSNR 定义如下:

$$PSNR = 10\log(\frac{255^2}{MSE}) \tag{11}$$

$$MSE = \frac{\sum_{i=0}^{W-1} \sum_{j=0}^{H-1} (g(i, j) - G(i, j))^2}{W * H} \tag{12}$$

式中,  $g(i, j)$  代表原始图像每个元素灰度值, 处理后,  $(i, j)$  位置对应的像素灰度值为  $G(i, j)$ , 处理前后图像大小不变, (原始图像进行下采样, 再上采样, 处理前后尺寸大小不变) 宽高分别为  $W, H$ 。

本文所用均方差 RMSE 形式如下:

$$RMSE = \sqrt{\frac{\sum_{i=0}^{256} (bins(i) - Mean)^2}{256^2}} \tag{13}$$

式中,  $bins(i)$  代表亮度为  $i$  的直方图条块的高度, 图像亮度分量均值表达形式为:

$$Mean = \frac{\sum_{i=0}^{256} bins(i)}{256} \tag{14}$$

3.2 定量结果比较

实验所用图像大多采自文献 [11, 15] 和 Matlab 平台常用图像, 比较的算法是文献 [7] 提出的 IPER 算法, 文献 [8] 提出的 MSS 算法和文献 [10] 提出 SIS 算法。

为了获得客观的测量结果, 首先使用均方误差 RMSE 表征结果, 如表 1 所示。从表 1 可以看出立方插值的结果最差, 因为立方插值假设图像是平滑先验的。IPER 的效果明显好于立方插值, RMSE 明显低于立方插值的 RMSE 值。SIS 和 MSS 的效果差不多, RMSE 的值相差不大, 由于这两种算法都采用了局部自相似块从 LR 图像学习 HR 图像块。本文算法大多数情况下 RMSE 值最低, 这是由于该方法组合了局部实例图像块和对应的局部相似性, 用于学习字典, 获得更好的结果。

表 1 分辨率增强因子为 2 时各算法 RMSE 结果

图像	立方插值	SIS	MSS	IPER	本文算法
Starfish	6.03	5.11	5.10	5.25	4.73
Lena	7.97	6.14	7.16	6.51	5.82
Peppers	9.98	8.17	9.20	7.52	7.54
Cameraman	11.37	10.01	10.16	9.12	8.24
Parthenon	11.61	11.03	11.01	10.64	7.97
Parrots	13.31	12.42	11.65	11.97	10.41
Zebra	14.93	13.24	12.92	13.23	11.12
Bike	16.25	14.71	15.86	14.50	13.49

表 2 是 PSNR 的值测量结果, PSNR 值越高表示图像的高频成分越多, 从表 2 可以看出本文算法除了一幅图像外 PSNR 值略低于 IPER 算法重建的效果, 其他重建图像的 PSNR 值均最高, 与原始图像的 PSNR 值相差最少, 丢失的高频纹理信息最少, 效果最好。

表 2 分辨率增强因子为 2 时各算结果的 PSNR 值 dB

图像	原 PSNR 值	立方插值	MSS	SIS	IPER	本文算法
Starfish	32.71	24.25	28.47	28.15	29.77	30.01
Lena	31.90	23.85	28.04	29.14	30.57	30.19
Peppers	32.10	23.96	29.01	29.75	30.71	31.02
Cameraman	32.92	24.58	28.04	30.76	30.94	31.47
Parthenon	31.99	24.65	29.41	29.89	30.43	30.95
Parrots	31.47	23.47	28.98	27.94	29.97	30.19
Zebra	32.15	24.02	29.10	28.47	30.29	31.03
Bike	32.56	24.47	30.02	27.98	30.47	30.94

3.3 定性结果比较

图 2、图 3 和图 4 分别显示了不同算法在 “Starfish”, “Bike” 和 “Parrots” 的结果, 可以看出, 从 “Starfish” 图像上, MSS 和 SIS 的算法给出了过多的尖锐图像, 造成了视觉的不舒服, IPER 算法造成有些模糊的感觉, 同样的效果出现在 “Bike” 图像中, 立方插值的效果最差。IPER 同样在

“Bike” 图像上的细节有些模糊。从对比可以看出，本文算法没有牺牲图像的自然性就能恢复局部纹理细节。




图 2 第一层左起原始图像，立方插值图像，MSS，第二层左起 SIS，IPER 和本文算法的效果（缩放因子为 3）



图 3 第一层左起原始图像，立方插值图像，MSS，第二层左起 SIS，IPER 和本文算法的效果（缩放因子为 4）




图 4 第一层左起原始图像，立方插值图像，MSS，第二层左起 SIS，IPER 和本文算法的效果（缩放因子为 2）

### 3.4 算法处理速度比较

一个好的 SR 算法应该满足以下 3 大方面：图像纹理、图像自然性和算法处理的速度。本文算法的时间主要集中在字典  $D_l$  和  $D_h$  的建立上，由于映射函数  $f$  的学习用其梯度函数  $\nabla f$  学习取代，变得较为简单。从表 3 是 50 幅图像重建的平均时间比较。可以看出，插值算法依然最快，因为算法比较简单。对于  $256 \times 256$  的图像“Boy”，“Parthenon”和“Camera-man”，在 Matlab7.0 平台上，运行时间比 IPER 的快。这是因为本文局部自相似实例图像块学习获得的非线性映射函数的一阶近似来获得低分辨率图像块相对应的高分辨率图像块。SIS 与 MSS 算法有不少时间用在各个尺度上的图像块匹配。

表 3 各算法的平均运行时间比较

立方插值	SIS	MSS	IPER	本文算法
0.4	5.4	5.8	4.9	4.4

## 4 结论与展望

本文提出一种鲁棒的基于一阶回归模型的单帧图像 SR 算

法，巧妙地结合了自相似性。其优势是在同一个图像中结合了从实例图像块的学习和局部自相似图像块的学习，实例图像块的局部回归避免了从 LR 到 HR 图像块映射的病态性问题。另一方面，通过局部自相似图像块的学习，回归模型可以克服实例图像不足的问题。仿真实验表明本文算法结果更接近真实结果，纹理更加清晰，图像更加自然，而且运行时间也略快于其他先进算法。

未来将重点研究基于视频流的，将该方法扩展到多帧情况下，其中主要解决多帧下的字典建立问题和映射函数的学习。

### 参考文献：

[1] 苏衡, 周杰, 张志浩. 超分辨率图像重建方法综述 [J]. 自动化学报, 2013, 39 (8): 1202–1213.

[2] 杨文波. 航空图像超分辨率重构技术研究 [D]. 中国科学院研究生院 (长春光学精密机械与物理研究所), 2014.

[3] 许宗敏. 基于冗余字典和稀疏表示的卫星图像超分辨率重建 [D]. 北京: 北京交通大学, 2013.

[4] Peng J, Xu Q F, Feng Y Q, et al. 自适应正则化超分辨率磁共振图像重建 [J]. 南方医科大学学报, 2011, 31 (10): 1705–1708.

[5] Mallat S, Yu G. Super-resolution with sparse mixing estimators [J]. IEEE Transactions on Image Processing, 2010, 19 (7): 2889–2900.

[6] Freedman G, Fattal R. Image and video upscaling from local self-examples [J]. ACM Transactions on Graphics, 2011, 30 (2): 474–484.

[7] Yang J, Lin Z, Cohen S. Fast image super-resolution based on in-place example regression [A]. IEEE Conference on Computer Vision & Pattern Recognition [C]. 2013, 9 (4): 1059–1066.

[8] 潘宏序, 禹晶, 胡少兴, 等. 基于多尺度结构自相似性的单幅图像超分辨率算法 [J]. 自动化学报, 2014, 40 (4): 594–603.

[9] 吴炜, 郑成林, 张莹莹, 等. 广义非局部均值和自相似性的超分辨率算法 [J]. 西安电子科技大学学报, 2014, 27 (4): 100–107.

[10] Yang C, Huang J, Yang M. Exploiting self-similarities for single frame super-resolution [J]. Lecture Notes in Computer Science, 2011, 29 (15): 497–510.

[11] Milanfar S F D R M E P. Fast and robust multi-frame super-resolution [J]. IEEE Transactions on Image Processing, 2003, 13 (10): 1327–1344.

[12] 王乐洋, 于冬冬. 病态总体最小二乘问题的虚拟观测解法 [J]. 测绘学报, 2014, 43 (6): 575–581.

[13] 李俊山, 朱英宏, 朱艺娟, 等. 红外与可见光图像自相似性特征的描述与匹配 [J]. 激光与红外, 2013, 43 (3): 339–343.

[14] 兰诚栋, 陈亮, 卢涛. 利用位置权重稀疏表示的人脸超分辨率算法 [J]. 武汉大学学报 (信息科学版), 2013, 38 (1): 27–30.

[15] Yang J, Member S, Wright J, et al. 1 Image Super-Resolution via Sparse Representation [J]. IEEE Transactions on Image Processing, 2010, 19 (11): 2861–2873.

# DTN 中基于贝叶斯的节点相遇概率预测方法

马继红<sup>1</sup>, 杨文涛<sup>2</sup>, 白跃彬<sup>2</sup>

(1. 邯郸职业技术学院 机电工程系, 河北 邯郸 056001; 2. 北京航空航天大学 计算机学院, 北京 100191)

**摘要:** DTN 网络由于频繁的网络断开、高延迟和异构性等原因, 导致网络可用性较低; 为了提高 DTN 网络可用性, 一方面要提高数据包送达目的节点的比例, 另一方面也要注意控制网络中的副本数量; 着重研究在便携设备交换网 (PSN) 和移动规律性较弱的车载网络 (VAN) 等网络中对节点相遇概率直接预测的方法; 提出了一种利用贝叶斯概率的方法进行相遇概率预测, 这种方法基于数据集的历史数据, 不依赖于具体的数据集, 具有较好的适应性和准确性。

**关键词:** DTN 网络; 贝叶斯网络; 节点; 相遇概率

## A Prediction Method of Node Encounter Probability Using Bayesian in DTN

Ma Jihong<sup>1</sup>, Yang Wentao<sup>2</sup>, Bai Yuebin<sup>2</sup>

(1. Department of Mechanical and Electrical Engineering, Handan Polytechnic College, Handan 056001, China

2. School of Computer Science and Engineering, Beihang University, Beijing 100191, China)

**Abstract:** Due to the frequent network disconnection, high latency and heterogeneity, DTN network has resulted in low network availability. In order to improve the availability of DTN network, it should increase the proportion of the data packets to the destination node. On the other hand, it also should control the number of copies in the network. The method of direct prediction of node encounter probability in the network, such as PSN, and weak regularity VAN, is studied. It presents a prediction method of Bayesian probability of encounter probability. This method is based on the historical data of data sets, which is not dependent on specific data sets, with better flexibility and accuracy.

**Keywords:** DTN; Bayesian network; node; encounter probability

## 0 引言

容迟容断网络 DTN 是主要针对端到端连接和节点资源都有限时的一种网络解决方案, 用以满足随意的异步消息的可靠传递。PROPHET 路由协议借助历史数据对相遇概率进行估算, 根据和目的节点的相遇概率进行转发, 取得了较好的效果。两个节点的相遇概率预测是 DTN 预测的核心问题。对于星际网络 (IPN) 和规律性较强的车载网络 (VAN)<sup>[1]</sup> 等移动规律较为固定和已知的网络形态中, 节点相遇的时间可以通过对节点的运动建模计算得到较为精确的时间, 因此, 在这种网络形态下不需要进行相遇概率的预测。而对于便携设备交换网 (PSN) 和移动规律性较弱的车载网络 (VAN) 等网络, 由于无法对节点的移动规律进行建模, 所以目前此类网络中的路由主要通过划分社区或直接计算等多种方式对节点间相遇概率进行预测, 并利用预测结果作为路由选择的依据。本文将着重研究在后一种情况下对节点相遇概率直接预测的方法。

目前还不存在一种可以对相遇概率进行直接预测且预测准确率较高的算法, 同时上述预测方法考虑因素较为单一, 在不同数据集中表现具有较大区别, 在具体不同的网络环境下通用

性较差。本文提出了一种利用贝叶斯概率的方法进行相遇概率预测, 这种方法基于数据集的历史数据, 不依赖于具体的数据集, 具有较好的适应性和准确性。

## 1 基于贝叶斯网络的 DTN 节点相遇知识学习方法

### 1.1 节点相遇知识挖掘

节点相遇知识是指 DTN 中任意两节点间存在的两节点在过去一段时间内的相遇情况的特征, 包括节点接触频率、平均接触时长、平均接触时间间隔等。这些参数中有些参数属于受节点影响的主要原因, 有些则受其它因素影响。为了得到影响节点相遇的主要因素, 通过构建贝叶斯网络对节点间相遇情况的特征进行学习。

表 1 节点相遇知识特征参数

特征名称	特征定义
接触频率	两节点接触的频率。
平均接触时长	两节点平均每次接触的时间长度。
节点流行度	两节点连接的其它节点的总个数, 表示节点在网络中的活跃程度。
节点相似度	两节点在网络中共同连接的节点在两节点所有直接相连节点中的所占比例。

### 1.2 构建贝叶斯网络模型

通过结构学习和参数学习过程, 可以构建出一个基于网络性能参数变量的贝叶斯网络结构模型, 如图 1 所示。从图中可以看出主要因素有接触频率、平均接触时长、被影响因素为节点流行度和节点相似度。贝叶斯网络模型表示出了各个网络参

收稿日期:2015-10-17; 修回日期:2015-10-30。

**基金项目:**国家自然科学基金项目(61073076); 河北省科技计划支撑项目(13200326D)。

**作者简介:**马继红(1977-), 女, 河北定州人, 在读硕士, 副教授, 主要从事计算机控制方向的研究。

白跃彬(1962-), 男, 河北石家庄人, 教授, 博士生导师, 主要从事计算机网络及分布式系统方向的研究。

数之间的依赖关系，同时可以得出它们具体参数值之间的概率关系。




图 1 贝叶斯网络结构图

2 基于贝叶斯概率的 DTN 节点相遇概率预测方法

对相对概率的预测，是指在两个节点处在没有接触的情况下，根据节点的历史数据信息及所处网络环境对两节点在未来一段时间内相遇的概率进行预测。将用到表 2 中的符号。

表 2 符号定义表

符号	含义
$Tf$	预测的时间长度，即在未来 $Tf$ 时间内是否会有新的接触
$Tl$	两节点从上次接触到现在的時間间隔
$Ic$	两节点从上次接触到下次实际接触时间的時間间隔

预测两个节点是否会在未来的某段时间  $Tf$  内相遇，其实就是预测目前两节点在最近接触后  $Tl$  时间时，再等待  $Tf$  时间内两节点是否会有新的接触，即二者所处接触间隔的长度  $Ic$  是否短于  $Tf + Tl$ 。

$$P(\text{节点在 } Tf \text{ 内相遇}) = P(Ic < Tf + Tl)$$

$Tf$  和  $Tl$  都是已知量，故整个问题转化为对间隔长度  $Ic$  的估计。由于目前已经等待了  $Tl$  的时间，故  $Ic > Tl$ 。所以：

$$P(\text{节点在 } Tf \text{ 内相遇}) = P(Ic < Tf + Tl \mid Ic > Tl)$$

由条件概率公式可得：

$$P(Ic < Tf + Tl \mid Ic > Tl) = P(Ic < Tf + Tl \ \& \ Ic > Tl) / P(Ic > Tl)$$

综合以上公式可得：

$$P(\text{节点在 } Tf \text{ 内相遇}) = f(Tl < Ic < Tl + Tf) / f(Tl < Ic)$$

上式中的  $f(a)$  为发生  $a$  事件的频率。在这个场景中，频率可通过统计历史数据获得。综上，可利用历史数据对相遇概率进行预测。

3 实验结果

3.1 方法有效性验证

对于实验可能会出现的结果可以分为 4 种情况，如表 3 所示。

表 3 实验结果类型

		预测情况	
		发生接触	未发生接触
实际 情况	发生接触	A1	A2
	未发生接触	A3	A4

对于预测准确性的度量可以参考信息检索中的查全率 (Recall Ratio) 和检准率 (Accuracy)。二者的定义如下所示：

$$\text{Recall Ratio} = A1 / (A1 + A2)$$

$$\text{Accuracy} = A1 / (A1 + A3)$$

公式中所用符号均如表 3 所示。对于路由过程存在多个消息副本的 DTN 路由协议来说，查全率较为重要；对于单个消息副本的 DTN 路由协议来说，检准率更为重要。在实际应用中可以根据需求灵活选择参数，获得较好的路由效果。

实验均采用 Huggle-6 数据集，为防止异常数据的影响只对接触时间超过一个数据采集周期 (120 s) 的接触进行分析。预测的目标都是在未来 1 小时内是否会有新的接触发生。由于未限定求相遇概率的原因，因此实验并未根据实际需求取阈值，而是将所有阈值 (每隔 0.1% 进行取样) 下的查全率和检准率进行对比，以图的形式展示。其中查全率用虚线表示，检准率用实线表示。

图 2 为 PROPHET 路由算法中提供的相遇概率预测方法所得到的查全率和检准率的对比。其中横坐标为根据算法的预测概率区分是否会相遇的阈值，纵坐标为在该阈值下的查全率 (虚线) 和检准率 (实线)。其中，这里 PROPHET 预测路由算法中的参数采用 ONE 仿真软件中的默认设置。从结果可知，随着阈值的提高，所预测的检准率会逐渐提升，但查全率始终维持在 0.5 左右的水平。

图 3 为本文算法所预测的相遇概率预测。从图中可以看出在默认取 0.5 做分割阈值时，无论是查全率还是检准率都明显高于 PROPHET 算法。而且查全率和检准率有较为明显的负相关，可以通过选择不同阈值满足不同路由协议的需求。




图 2 PROPHET 概率预测方法阈值选取对查全和检准率的影响




图 3 贝叶斯概率预测方法阈值选取对查全率和检准率的影响

3.2 方法普适性验证

上面的方法验证了贝叶斯方法的有效性, 为了验证说明方法的普适性, 在另外 4 种不同类型的数据集中将贝叶斯方法同另外两种方法分别进行对比验证。4 种数据集主要参数如表 4 所示。

表 4 数据集及相关参数

Haggle3	NUS	Reality	Sassy	
节点数目	41	3 000	91	25
数据集时间/s	280 000	280 000	17 000 000	6 420 000
接触频率下限	30	10	50	60
接触时间下限/s	50	3 599	20	5
预测时长/s	1 201 000	1 201 000	1 201 000	1 201 000
	3 600	3 600	3 600	3 600
	5 000	5 000	5 000	5 000
	10 000	10 000	10 000	10 000
	80 000	80 000	80 000	80 000
			600 000	600 000
			2 400 000	2 400 000

Haggle 数据集<sup>[2]</sup>是剑桥大学通过将自制的蓝牙设备 (iM-otes) 部署到人身上进行数据采集得到的。

NUS 数据集<sup>[3]</sup>是新加坡国立大学通过手机采集的的数据。

Reality 数据集<sup>[4]</sup>是麻省理工学院利用一百部诺基亚 6600 手机收集的数据。

Sassy 数据集<sup>[5]</sup>是圣安德鲁斯大学利用自制的 IEEE802.15 设备 (T-mote) 进行的数据采集,

对于每组实验主要有 3 个参数: 数据集、预测方法及预测时间。根据上表的参数可以看出, 我们一共进行了 84 组实验。每组实验进行 100000 次抽样, 保证平均每个阈值样本所代表的参数为 100 个。

为了综合考虑查全率和检准率, 在这里定义综合准确率为查全率和检准率的几何平均值, 这个值在二者差距较大的情况下较客观的反映了预测质量。取每次实验各阈值对应的综合准确率中的最大值作为这次实验预测质量的代表。各组实验结果如图 4~图 7 所示。其中黑色实线代表贝叶斯方法在不同预测时长的综合准确率, 虚线和灰色十字分别代表 PROPHET 路由中的预测方法和基于指数分布的预测方法在不同预测时长的综合准确率。




图 4 Haggle3 数据集 3 种方法对比




图 5 NUS 数据集 3 种方法对比




图 6 Sassy 数据集 3 种方法对比




图 7 Reality 数据集 3 种方法对比

从图中可以看出, 基于贝叶斯概率的节点相遇概率计算方法在各不同种类的数据集中的预测中的各种预测时长准确性均优于其他两种预测方法。

表 5 3 种算法准确率对比 %

预测方法	Haggle3	NUS	Reality	Sassy	平均准确率
贝叶斯概率	71.7	73.2	57.2	64.3	66.6
PROPHET 方法	54.2	35.7	46.5	54.6	47.7
指数分布方法	44.7	39.4	33.4	34.0	37.9

表 5 为 3 种方法在 4 个数据集上的平均准确率, 可以看出贝叶斯方法在各个数据集中预测准确性最高。表 6 表明新的贝叶斯方法对 PROPHET 方法和指数分布这两种相遇概率预测方法的准确度分别提升了 39.62% 和 75.73%。

表 6 贝叶斯方法准确率提升百分比 %

预测方法	Haggle3	NUS	Reality	Sassy	平均准确率
PROPHET 方法	32.29	105.04	23.01	17.77	39.62
指数分布方法	60.40	85.79	71.26	89.12	75.73

3.3 实验结果分析

通过统计数据集中接触间隔，可以对基于贝叶斯的相遇概率预测方法预测概率提升的原因进行解释。

PROPHET 路由协议中的相遇概率预测方法在节点没有接触时，预测的两节点的相遇概率会随时间逐渐缩小；基于指数分布的相遇概率预测方法假设接触间隔服从指数分布，所预测的相遇概率也是随时间逐渐缩小。

Haggle 数据集里接触间隔和频率的关系如图 8 所示。其中横轴为接触间隔，单位为小时；纵轴为接触间隔的频数。从图中可以看出，在开始时，随着接触间隔的增长，接触间隔的频率即节点再次接触的概率逐渐减小，这一点上之前的两种路由算法是较为符合实际情况的。但是随着时间的增长，当接触间隔超过十个小时后，接触间隔的频率随间隔增长会逐渐增加，并在 18~24 个小时左右达到峰值。结合数据集采集的场景，在第一天会议结束后到第二天会议开始，之间的时间间隔大约就是 18~24 个小时。在这个阶段，PROPHET 路由协议中的相遇概率预测方法和基于指数分布的相遇概率预测方法均无法给出相应的预测。




图 8 Haggle 数据集接触间隔长度和频率的关系图




图 9 Reality 数据集接触间隔长度和频率的关系图

基于贝叶斯的相遇概率预测方法通过对历史数据的统计，可以有效拟合实际中的接触间隔变化规律。如当距离上次接触距离为五小时时，可以从图中的历史数据观察到未来五小时内会有新的接触发生的频率占接触间隔五小时以上的频率较小，因此发生接触的可能性也较小；当距离上次接触发生时间距离 15 小时时，虽然未发生接触时间间隔更长，但根据历史数据

可知这时未来五小时内可能发生新接触的概率反而会增大，因此所得到的相遇概率的预测值也会相应变大。

不同于 Haggle 数据集仅收集几天的数据，Reality 数据集连续收集了节点九个月的移动和接触数据，更便于观察节点接触的长期规律性。Reality 数据集接触间隔长度和频率的关系如图 9 所示，其中横轴单位为天。从图中可以看出，虽然节点接触时间总体来看具有长期规律性，即接触概率随接触间隔的增长而降低，但图中仍然可以看出间隔时间的分布并非平滑的曲线，而是存在众多明显的峰值，而且峰值的排列具有一定的规律性：大约每七天左右就会出现一个峰值。结合数据集采集的场景来看，在校园活动中存在较强的以星期为周期的规律性：课程、例会、周末社交活动，很多人会间隔七天左右再次见面。Reality 数据集的分析结果体现了这种规律性。

结合之前的分析可知，PROPHET 路由协议中的概率预测方法和基于指数分布的预测方法均无法预测这种间隔七天的规律性，而贝叶斯方法可以通过历史数据的统计获得这种规律性，得到更为准确的预测值。同时，贝叶斯方法对这种规律性的预测完全基于历史数据而不需基于任何先验知识，是的基于贝叶斯的相遇概率预测方法具有普适性。

4 结论

PROPHET 路由方法主要关注相遇概率相对大小，并不关注相遇概率的绝对值，因此即使在预测准确率偏低的情况下路由方法仍然有较好的表现。基于指数分布的预测方法目前多限于数据研究，并未作为路由的主要依据。两种预测方法的准确率都偏低，无法作为分簇的条件。贝叶斯概率预测方法预测相遇概率的准确性较高，已经可以作为 DTN 节点分簇的依据。

参考文献：

[1] Hull B, Bychkovsky V, Zhang Y, et al. CarTel: a distributed mobile sensor computing system [A]. Proceedings of the 4th international conference on Embedded networked sensor systems (SenSys' 06) [C]. 2006.

[2] Pan H, Chaintreau A, Scott J, et al. Pocket switched networks and human mobility in conference environments [A]. Proceedings of the 2005 ACM SIGCOMM workshop on Delay-tolerant networking (WDTN' 05) [C]. 2005.

[3] Natarajan A, Motani M, Srinivasan V. Understanding urban interactions from bluetooth phone contact traces [A]. PAM 2007, 8th Passive and Active Measurement Conference [C]. 2007.

[4] Nathan E, Pentland A. Reality mining: sensing complex social systems [J]. Journal of Personal and Ubiquitous Computing, 2006.

[5] Bigwood G, Rehunathan D, Bateman M, et al. Exploiting self-reported social networks for routing in ubiquitous computing environments [A]. Proceedings of IEEE International Conference on Wireless and Mobile Computing, Networking and Communication (WiMob '08) [C]. 2008.