

一种自适应邻域选择半监督判别分析算法

刘云东¹, 李 鸿¹, 白万荣², 刘 罡³

LIU Yundong¹, LI Hong¹, BAI Wanrong², LIU Gang³

1. 宿州学院 信息工程学院, 安徽 宿州 234000

2. 兰州理工大学 计算机与通信学院, 兰州 730050

3. 中国人民解放军 68611 部队 装备处

1. School of Information Engineering, Suzhou University, Suzhou, Anhui 234000, China

2. College of Computer and Communication, Lanzhou University of Technology, Lanzhou 730050, China

3. Department of Equipment, No. 68611 Troops, The Chinese People's Liberation Army

LIU Yundong, LI Hong, BAI Wanrong, et al. Semi-supervised discriminant analysis algorithm based on adaptive neighborhood selection. *Computer Engineering and Applications*, 2011, 47(35): 180-183.

Abstract: A new semi-supervised discriminant analysis algorithm adaptive neighborhood selection algorithm based on local linearity is proposed for the disadvantage of Marginal Fisher Analysis (MFA), which can only make use of a few labeled samples and construct a reasonable neighborhood for each point. An adaptive algorithm to expand or narrow neighbor coefficient k is adopted to keep the local linear structure. The MFA can make use of small amount of labeled samples and the UDP can study a large numbers of unlabeled samples, so the method can use semi-supervised dimensionality reduction algorithm for high dimensional data of face. Finally, the effectiveness of the proposed methods is validated through the experimental results on ORL and YALE face databases.

Key words: Marginal Fisher Analysis (MFA); Unsupervised Discriminant Projection (UDP); semi-supervised; local linear structure; neighborhood selection

摘 要: 为克服边界 Fisher 判别分析 (MFA) 只利用少量有标记样本和构建邻域不能充分反映流形学习对邻域要求的缺点, 提出一种基于局部线性结构的自适应邻域选择半监督判别分析的算法。采用自适应算法扩大或者缩小近邻系数 k 来构建邻域以保持局部线性结构。MFA 通过少量有类别标签样本进行降维的同时 UDP 对大量无标签样本进行学习, 以半监督的方法对高维人脸数据进行维数约减。最后, 在 ORL 和 YALE 人脸数据库通过实验结果验证了该算法的有效性。

关键词: 边界 Fisher 判别分析; 无监督鉴别投影; 半监督; 局部线性结构; 邻域选择

DOI: 10.3778/j.issn.1002-8331.2011.35.051 文章编号: 1002-8331(2011)35-0180-04 文献标识码: A 中图分类号: TP391

1 引言

由于人脸识别在身份认证、安全控制和视频检索等领域的巨大应用前景, 目前已成为模式识别、计算机视觉以及图像处理等多个领域的一个研究热点。人脸具有“小样本、高维数”的特点, 因此如何有效的维数约减来避免“维数灾难”是解决问题的关键。基于此, 众多度量可分性准则的算法中, 主成分分析 (PCA)^[1] 和线性判别分析 (LDA)^[2] 是应用最广泛的两个线性维数约减算法。

近几年涌现出诸如等距映射 (ISometric MAPping, ISOMAP)^[3]、局部线性嵌入 (Locally Linear Embedding, LLE)^[4]、拉普拉斯特征映射 (Laplacian Eigenmap, LE)^[5] 等的流形学习算法。但是, 以上三种方法应用于人脸识别存在 Out-of-sample 问题^[6]。流形学习算法的线性化可以解决这个问题, 是将每个

样本的近邻样本局部邻域视为线性空间。较为典型的算法包括局部保持投影 (Locality Preserving Projection, LPP)^[7]、无监督判别投影 (Unsupervised Discriminant Projection, UDP)^[8] 和边界 Fisher 分析 (Marginal Fisher Analysis, MFA)^[9]。LPP 是 Laplacian Eigenmaps 的线性逼近, 通过保持高维数据的邻域关系来对数据集进行降维。UDP 是在 LPP 的基础上改进的算法, 除了保持近邻样本的邻域关系外还保持非近邻样本之间的疏远关系。MFA 是有监督的, 将同类样本中近邻的样本拉近, 同时将异类中近邻的样本推远作为可分性准则。虽然这些算法在人脸识别中取得了较好的识别效果, 但是当有类别标签的样本数据不足时, 有监督算法的泛化能力降低。需要说明的是, 获取样本的类别信息十分耗时, 而无标签的数据相对来说容易得到, 半监督分类利用大量廉价的无标签样本信

基金项目: 国家自然科学基金 (the National Natural Science Foundation of China under Grant No.20871089); 安徽省高校优秀青年人才基金项目 (No.2009SQZ171); 安徽省教育厅自然科学研究项目 (No.KJ2009B121); 安徽省高校优秀青年人才基金项目 (No.2010SQRL192)。

作者简介: 刘云东 (1979—), 男, 讲师, 主研方向: 信息处理; 李鸿 (1964—), 男, 教授, 博士; 白万荣 (1985—), 男, 硕士研究生; 刘罡 (1979—), 男, 在职研究生。E-mail: szxylyd@126.com

收稿日期: 2011-07-04; **修回日期:** 2011-09-23

息来增加分类的精确度^[10]。此外,现有的算法构建邻域是通过 k 近邻或 ε 近邻,这两个参数需要事前根据经验设定。流形学习算法对其参数比较敏感,参数过大或者过小都会对算法的性能产生影响。

为此,本文针对有标记样本不足和邻域选择问题,提出了一种基于局部线性结构的自适应邻域选择的半监督判别分析算法,是在监督算法 MFA 的基础上,将 UDP 的局部和非局部散度矩阵加入到目标函数中,改进为半监督的算法。该算法能够将监督算法浪费的无标签样本和无监督算法没有利用分类的标签信息充分利用,同时更精确地通过自适应算法求取近邻样本数据,进一步提高了分类的鲁棒性。

2 相关算法

2.1 边界 Fisher 判别分析

MFA 的目标是将 k_1 近邻的样本拉近的同时将 k_2 近邻的样本推远。其好处是避免少数几个相距较远的样本主导,避免了 LDA 满足高斯分布这一条件。假设 $\{(x_1, l_1), (x_2, l_2), \dots, (x_N, l_N)\}$ 为训练样本数据集,其中, $x_i \in R^D$ 表示一个 D 维向量, $l_i \in L = \{1, 2, \dots, c\}$ 是样本 x_i 的类别标签, L 为类别标签集。数据点 x_i 通过投影矩阵 $A_{D \times d}$ 可以得到低维映射 $y_i \in R^d, d < D$, 即 $y_i = A^T x_i$ 。

MFA 定义类内散布矩阵 S_w 来表示同类数据点的集中程度:

$$S_w = \sum_{i=1}^N \sum_{j \in N_{k_1}(i)} \left\| A^T x_i - A^T x_j \right\|^2 = 2A^T X(D - W)X^T A \quad (1)$$

其中, W 表示同类数据相似度邻接矩阵, $W_{ij} = \begin{cases} 1, & i \in N_{k_1}(j) \text{ 或 } j \in N_{k_1}(i) \\ 0, & \text{otherwise} \end{cases}$, $N_{k_1}(j)$ 表示 k_1 个与 x_j 同类的近邻点,

D 是一个对角阵, $D_{ii} = \sum_{j \neq i} W_{ij}$ 。同时,定义类间散布矩阵 S_b 来表示异类数据点的离散程度:

$$S_b = \sum_{i=1}^N \sum_{(i,j) \in P_{k_2}(l_i) \text{ 或 } (i,j) \in P_{k_2}(l_j)} \left\| A^T x_i - A^T x_j \right\|^2 = 2A^T X(D^p - W^p)X^T A \quad (2)$$

其中, W^p 表示异类数据相似度邻接矩阵, $W_{ij}^p = \begin{cases} 1, & (i,j) \in P_{k_2}(l_i) \text{ 或 } (i,j) \in P_{k_2}(l_j) \\ 0, & \text{otherwise} \end{cases}$, $P_{k_2}(l_i)$ 表示 k_2 个与 x_i 异类的

近邻点, D 是一个对角阵, $D_{ij}^p = \sum_{j \neq i} W_{ij}^p$ 。MFA 的目标函数可写为如下所示:

$$J(A)_{MFA} = \arg \max_a \frac{A^T X(D^p - W^p)X^T A}{A^T X(D - W)X^T A} \quad (3)$$

2.2 无监督鉴别投影

UDP 是 Yang 等^[8]人提出的一种流形学习的线性化算法。除了反映样本间的内在数据关系外,还能够对样本进行有效分类。UDP 的目标就是最大化非局部散度与局部散度的比,得到有效的分类方向,从而样本数据点在该方向上投影。为此,定义一个 $N \times N$ 的邻接矩阵 H 如下所示:

$$H_{ij} = \begin{cases} 1, & x_i \in N_k(x_j) \text{ 或 } x_j \in N_k(x_i) \\ 0, & \text{otherwise} \end{cases}$$

$x_j \in N_k(x_i)$ 表示 x_j 是 x_i 的 k 近邻。

局部散度 $J_L(A)$ 能够将高维空间中靠的近的样本点降到低维空间中任然保持近邻关系,其定义如下:

$$J_L(A) = \frac{1}{2NN} \sum_{i=1}^N \sum_{j=1}^N H_{ij} (y_i - y_j)^2 = \frac{1}{2NN} \sum_{i=1}^N \sum_{j=1}^N H_{ij} (A^T x_i - A^T x_j)^2 = A^T \left[\frac{1}{2NN} \sum_{i=1}^N \sum_{j=1}^N H_{ij} (x_i - x_j)^2 \right] A \quad (4)$$

非局部散度 $J_N(A)$ 不同于局部散度,是将高维空间中非近邻的样本点降维后保持疏远关系。其定义如下:

$$J_N(A) = \frac{1}{2NN} \sum_{i=1}^N \sum_{j=1}^N (1 - H_{ij}) (y_i - y_j)^2 = \frac{1}{2NN} \sum_{i=1}^N \sum_{j=1}^N (1 - H_{ij}) (A^T x_i - A^T x_j)^2 = A^T \left[\frac{1}{2NN} \sum_{i=1}^N \sum_{j=1}^N (1 - H_{ij}) (x_i - x_j)^2 \right] A \quad (5)$$

局部散度矩阵 S_L 、非局部散度矩阵 S_N 分别定义为:

$$S_L = \frac{1}{2n^2} \sum_i \sum_j H_{ij} (x_i - x_j)(x_i - x_j)^T \quad (6)$$

$$S_N = \frac{1}{2n^2} \sum_i \sum_j (1 - H_{ij}) (x_i - x_j)(x_i - x_j)^T \quad (7)$$

基于 UDP 准则思想,最小化局部散度的同时最大化非局部散度。其目标函数定义如下:

$$J_{UDP}(A) = \arg \max_a \frac{A^T S_N A}{A^T S_L A} \quad (8)$$

无论 MFA 还是 UDP 得到的子空间中,使用最近邻分类器,可以得到比较高的数据的分类精度。但是也发现以下两个问题:其一, MFA 和 UDP 算法的样本近邻点是使用 k 近邻的方法来选取的,由于参数 k 的确定比较困难,其确定的邻域不足以反映流形学习算法的局部性。其二, MFA 是一种完全监督的算法,当有标签样本相对较少时, MFA 的降维效果对于分类来说并不理想。而 UDP 是无监督的,没有充分利用已知的类别标签信息。为此,本文提出了基于局部线性结构的自适应邻域选择半监督判别分析算法。

3 自适应邻域选择的半监督算法

3.1 自适应邻域选择算法

在流形学习算法中,一般采用 k 近邻或 ε 近邻选择训练样本的邻域来保持局部性特点。然而一个好的邻域选择是邻域内的点都在某一 d 维线性子空间内,而且每个邻域尽可能多的包含样本点。根据文献[11],给定容忍阈值 $\eta \in (0.5, 1]$, 则有:

$$\frac{\sum_{i=1}^d \lambda_i}{\sum_{i=1}^D \lambda_i} \geq \eta \quad (9)$$

其中, λ_i 是对数据集 X 依据 PCA 方法做协方差矩阵所得到的特征值。如果式(9)成立,认为 X 中的点都在某一 d 维线性子空间内。

因此,依据式(9)来衡量局部点集的线性化程度,本文采用的自适应邻域选择算法来选取每个点的邻域,使其局部具有线性结构或近似线性结构。该算法依据线性程度可动态缩

小或扩大邻域。其策略是初始化时给每个点分配较大的邻域,如若该邻域不能够保持局部线性结构,则删除破坏其结构的节点。反之,初始情况下就已经是线性结构,然后每次将新的节点再加入到该邻域,直到不能保持线性结构为止。其具体算法如下:

算法1 确定每个点的邻域参数

输入:高维数据集 X , 初始邻域参数 K , 流形维数 d , 容忍阈值 η 。

输出:每个点的自适应邻域集 $N(x_i)$ 。

初始化:对每个 x_i , 将其 k 近邻加入到 $N(x_i)$, 对每个邻域 $N(x_i)$, 假设 $\|x_i - x_{i_1}\| \leq \|x_i - x_{i_2}\| \leq \dots \leq \|x_i - x_{i_k}\|$, 其中 x_{i_j} ($j=1, 2, \dots, K$) $\in N(x_i)$, 令 $k=K$, 矩阵 $X_i^{(k)} = (x_i, x_{i_1}, \dots, x_{i_k})$ 。

(1) $\bar{X}_i^{(k)} = X_i^{(k)}(I - (1/k)ee^T)$, 其中 e 为全1列向量。

(2) 计算协方差矩阵 $\bar{X}_i^{(k)}\bar{X}_i^{(k)T}$ 的特征值 λ_d ($0 < d \leq D$)。

(3) while(式(9)不成立) {

$k=k-1$, 计算步骤①中的 $\bar{X}_i^{(k)}$ 并通步骤(2)求出特征值 λ_d ($0 < d \leq D$)。

} //缩小邻域

if ($k \neq K$) return $N(x_i) = \{x_{i_j} : 1 \leq j \leq k\}$;

while(式(9)成立) {

求出 x_i 的第 $k+1$ 个近邻样本点, 步骤(2)计算样本集 $N(x_i) \cup x_{i_{k+1}}$ 的协方差矩阵的特征值 λ_d ($0 < d \leq D$);

if 式(9)成立, 将 $x_{i_{k+1}}$ 加入到 $N(x_i)$, $k=k+1$;

} //扩大邻域

return $N(x_i) = \{x_{i_j} : 1 \leq j \leq k\}$;

3.2 自适应邻域半监督算法

由于MFA仅仅使用有标记样本作为训练样本,浪费了大量无标记样本。而UDP只使用没有采用训练样本的类别信息,因而是无监督的方法。本文将MFA和UDP进行结合,在仿照UDA^[12]的基础上,提出一种半监督算法。该算法是将同类样本的近邻点在降维过程中进行拉近,同时将异类样本的近邻点推远。此外,将高维空间中近邻的样本点在低维空间中任然保持近邻关系,高维空间中非近邻点在低维空间中推远。其目标函数如下所示:

$$J(A) = \arg \max_A \frac{A^T(S_b + \alpha S_N)A}{A^T(S_w + \beta S_L)A} \quad (10)$$

其中: S_b 和 S_w 通过有标签训练样本计算而来,即MFA算法中的类间散布矩阵和类内散布矩阵。 S_N 和 S_L 是通过全部数据集计算出来的,即UDP算法中的非局部散布矩阵和局部散布矩阵。 α 和 β 用来调节 S_N 和 S_L 的贡献度的常系数。

通过算法1可以动态自适应选择位于流形上数据点的近邻点。利用数据点的类别信息和算法1,可构造同类数据点的相似度邻接矩阵 W_w 如下:

$$W_{w_{ij}} = \begin{cases} 1, & x_j \in N_{w_k}(x_i) \text{ 或 } x_i \in N_{w_k}(x_j) \\ 0, & \text{otherwise} \end{cases}$$

这里 $N_{w_k}(x_i)$ 表示 k 个与 x_i 同类别的数据点构成的邻域, k 是通过算法1在同类数据集中动态确定的。

同样,异类数据点的相似度邻接矩阵 W_b^p 构造如下:

$$W_{b_{ij}}^p = \begin{cases} 1, & x_j \in N_{b_k}(x_i) \text{ 或 } x_i \in N_{b_k}(x_j) \\ 0, & \text{otherwise} \end{cases}$$

其中, $N_{b_k}(x_i)$ 表示 k 个与 x_i 异类的数据点构成的邻域,此处 k 是通过算法1在异类数据集中确定的。

定义数据点的邻接矩阵 H_i :

$$H_{ij} = \begin{cases} 1, & x_j \in N_{ik}(x_i) \text{ 或 } x_i \in N_{ik}(x_j) \\ 0, & \text{otherwise} \end{cases}$$

这里 $N_{ik}(x_i)$ 是由 x_i 的 k 个近邻的数据点构成的邻域, k 是通过算法1在整个数据集中自动确定的。

式(10)的解就是下列等式中的最大特征值对应的特征向量:

$$(S_b + \alpha S_N)A = \lambda(S_w + \beta S_L)A \quad (11)$$

算法2 自适应邻域选择半监督算法

步骤1 对任意 $x_i \in X_N$, 通过算法1选择同类点邻域,异类点邻域以及全局邻域,可得到 W_w , W_b^p , H_i 。

步骤2 构造邻接矩阵,通过式(1)、(2)求出 S_b 和 S_w , 式(6)、(7)求出 S_N 和 S_L 。

步骤3 对式(11)求解特征值和特征向量。得到 D 个非零的特征值所对应的特征向量,其特征向量可记为 $a_1, a_2, \dots, a_d, a_{d+1}, \dots, a_D$, 其中 a_1, a_2, \dots, a_d 是 d 个最大的特征值所对应的特征向量。

步骤4 令 $A = [a_1, a_2, \dots, a_d]$, 是 $D \times d$ 的投影矩阵。 D 维空间中的样本通过 $y = A^T x$ 变换即可投影到 d 维空间中。

4 人脸识别实验

在ORL和YALE人脸库上分别进行实验来验证本文算法的性能,并与PCA, LDA, LPP, UDP, MFA进行对比。实验中,参数 α 和 β 均设置为0.1,容忍阈值 $\eta=0.95$,初始邻域 $K=4$,实验用最近邻分类器来分类,识别率取10次实验的最大平均值。所有人脸图像为灰度图像,将其进行缩放为 32×32 。

4.1 ORL人脸数据库的实验

ORL人脸库由40人,每人10张共400张在不同时间采集的人脸图像组成。其中包括不同视角、不同表情(睁眼、闭眼、微笑、生气、高兴、吃惊等)和不同面部细节(不同发型、戴或不戴眼镜、有或无胡须),同时包含一些倾斜和不超过 20° 的旋转。ORL人脸库中的某一人10张图像如图1所示。



图1 ORL人脸库图像示例

对于ORL人脸库,从每个人的图片中随机抽取 l ($l=2, 3, \dots, 6$) 张图片作训练样本,剩下的 $10-l$ 张图片作测试样本。需要说明的是,在本文算法训练时需要使用到不带有类别信息的测试样本。而监督算法LDA和MFA,在训练时仅仅利用带标签的训练样本。

从表1和图2可以看出,本文算法在ORL人脸库上能够取得最高的识别率。因为不仅采用自适应邻域选取样本近邻点,使得更精准地保持流形空间的局部性,而且在监督算法的基础上使用了无标签信息,因此识别率最高。同时可看出,UDP和MFA算法的识别率高于LDA和PCA算法的识别率。

表1 ORL人脸库上的识别结果比较

算法名称	样本数目及正确识别率/(%)				
	2	3	4	5	6
PCA	65.42	76.02	81.27	85.28	87.23
LDA	71.25	81.85	89.14	91.67	92.08
LPP	75.33	84.62	89.63	92.98	93.19
UDP	76.65	84.91	90.22	93.14	94.57
MFA	74.28	85.58	90.40	93.48	95.83
本文算法	84.63	91.69	95.37	97.16	98.06




图2 ORL人脸库的5Train的识别率

4.2 YALE人脸数据库的实验

为了进一步验证本文算法的有效性,在YALE人脸库上进行实验。YALE人脸库由15个人,每个人有11张共165张图像组成。这些图像在光照条件变化比较大,而且面部表情(正常、伤心、开心、眨眼和惊讶等)和细节(戴或不戴眼镜)也有比较明显的变化。图3所示的是来自YALE人脸库的某一个人的11张图像。



图3 YALE人脸库图像示例

在YALE人脸库中,从每个人的图像中随机选取1张作训练样本,而剩下11-1张作测试样本。

从表2和图4可以看出,由于YALE库的图像受光照、姿态、表情变化的干扰较大,所以文中所列的所有方法的识别率相

表2 YALE人脸库上的识别结果比较

算法名称	样本数目及正确识别率/(%)				
	2	3	4	5	6
PCA	41.37	49.02	53.24	56.43	58.80
LDA	46.51	58.87	69.10	73.52	78.21
LPP	56.30	68.85	76.16	77.64	80.83
UDP	55.84	68.32	77.15	79.53	82.46
MFA	54.29	68.25	77.67	81.16	83.08
本文算法	56.90	71.63	80.72	83.57	85.65




图4 YALE人脸库的5Train的识别率

对较低。PCA和LDA保持全局线性结构进行维数约减,不能很精确地描述非线性流形,识别率低于保持局部线性的UDP、MFA和本文算法,而本文算法的识别率又高于MFA和UDP。

4.3 实验分析

本文算法在MFA的基础上,采用自适应邻域选取算法来计算近邻点并将无标签样本作为训练样本,可得到利于有效分类的投影矩阵。实验表明,本文算法对于姿态、表情、光照等变化体现出极强的鲁棒性,相比其他几种算法,识别效果是最优的。作为识别来说,更多的特征将会引入不利于分类的信息,当维数达到一定的程度,识别率不再会因维数的增加而提高,甚至可能有所下降。而LPP、UDP和MFA由于近邻点的选取使用事前设定的参数k,而且仅仅利用有限的有标签样本或者不利用有标签样本,所以识别率低于本文算法。PCA的识别率低于LDA,这是由于PCA是无监督的。LPP总体上要低于UDP,这与UDP在LPP的基础上还保持了非近邻样本的疏远有关。LDA的识别率要比MFA和UDP低,这两个算法的识别率也比本文算法低,这说明自适应邻域选取的半监督算法能够取得比较理想的性能。

5 结束语

针对流形学习算法中邻域选择和有标签样本不足问题,提出了一种自适应邻域选择半监督算法,该算法能够根据流形在不同点的曲率自适应地构建邻域,能够反映流形局部线性结构。同时,既能充分利用标记样本的监督信息,又挖掘隐藏在无标记数据中的潜在信息,很好地保持了数据的局部和全局信息。然而非线性程度较高是,所构建的邻域过小形成不连通的邻域图。通过核技巧将其扩展为非线性算法是今后研究的工作重点。

参考文献:

- [1] Turk M, Pentland A. Eigenface for recognition[J]. Journal of Cognitive Neuroscience, 1991, 3(1): 72-86.
- [2] Belhumeur P, Hespanha J, Kriegman D. Eigenfaces vs. Fisherfaces: recognition using class specific linear projection[J]. Pattern Analysis and Machine Intelligence, 1997, 19(7): 711-720.
- [3] Tenenbaum J B, De Silva V, Langford J C. A global geometric framework for nonlinear dimensionality reduction[J]. Science, 2000, 290(5500): 2319-2323.
- [4] Roweis S L, Saul L. Nonlinear dimensionality reduction by locally linear embedding[J]. Science, 2000, 290(5500): 2323-2326.
- [5] Belkin M, Niyogi P. Laplacian eigenmaps for dimensionality reduction and data representation[J]. Neural Computation, 2003, 15(6): 1373-1396.
- [6] Bengio Y, Palement J, Vincent P, et al. Out-of-sample extensions for LLE, isomap, MDS, eigenmaps, and spectral clustering[J]. Neural Computation, 2004, 16(10): 2179-2219.
- [7] He Xiaofei, Yan Shuicheng, Hu Yuxiao, et al. Face recognition using Laplacianfaces[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2005, 27(3): 328-340.

(下转 187 页)

设 H_1 为采用未优化拼接计算出的相邻影像的单应矩阵, H_2 为采用优化拼接计算出的与其对应单应矩阵, 本文采用以下三个范数来度量二者的差异:

相对 M 范数 RM :

$$\|H_2, H_1\|_{RM} = \frac{\max_{x,y} \text{abs}(H_{2x,y} - H_{1x,y})}{\max_{x,y} \text{abs}(H_{1x,y})} \quad (8)$$

相对 $L1$ 范数 $RL1$:

$$\|H_2, H_1\|_{RL1} = \frac{\sum_{x,y} \text{abs}(H_{2x,y} - H_{1x,y})}{\sum_{x,y} \text{abs}(H_{1x,y})} \quad (9)$$

相对 $L2$ 范数 $RL2$:

$$\|H_2, H_1\|_{RL2} = \frac{\sum_{x,y} (H_{2x,y} - H_{1x,y})^2}{\sum_{x,y} (H_{1x,y})^2} \quad (10)$$

因为是对多片影像进行拼接, 所以计算出的三个范数值有多个, 这里取它们各自的均值作为最终结果, 见表4~表6。

表4 数据1的各项指标

权值	时间/s	RM	RL1	RL2
未优化	181.969	0	0	0
(0,1)	53.172	0.006 39	0.006 53	0.006 45
(0.5,0.5)	43.734	0.007 17	0.007 63	0.007 45
(1,0)	36.469	0.006 82	0.007 61	0.007 06

表5 数据2的各项指标

权值	时间/s	RM	RL1	RL2
未优化	200.906	0	0	0
(0,1)	46.859	0.020 75	0.025 56	0.022 44
(0.5,0.5)	36.953	0.022 61	0.031 35	0.025 87
(1,0)	42.812	0.026 26	0.035 80	0.030 21

表6 数据3的各项指标

权值	时间/s	RM	RL1	RL2
未优化	58.875	0	0	0
(0,1)	27.109	0.010 51	0.010 67	0.010 76
(0.5,0.5)	17.219	0.011 36	0.011 68	0.011 78
(1,0)	9.813	0.036 04	0.041 06	0.039 58

从表4~表6可以看出: 经过速度优化的拼接方法在拼接时间上比起未经优化的拼接已大幅度减少, 之所以表4中权值为(1,0)的拼接时间比权值为(0.5,0.5)的时间长, 是因为数据2的影像特征不明显, 拼接过程中有计算单应矩阵失败的情况, 在迭代中花费了一定的时间, 这也验证了本文参数选择机制的有效性; 从各种范数的值可以看出随着尺度的变化, 单应

矩阵并没有明显的改变; 各种范数的值很小说明优化后计算出的单应矩阵与未优化计算出的单应矩阵相似性很高, 拼接结果图从直观上验证了以上结论。至于优化后计算出的单应矩阵与未优化计算出的单应矩阵之间的差异主要归结为两方面的原因: 一是缩小图像与原始影像的特征点的几何分布与数量不同; 二是SIFT算子采用插值拟合的办法来确定特征点的坐标, 所以其定位精度不高, 从而影响单应矩阵的解算结果。

5 结语

提出的改进方法与传统的基于SIFT的影像拼接方法相比可以大幅度提高无人机影像拼接的速度, 保证较好的拼接效果, 用户可以根据影像数据的特点及的应用需求通过参数的选择机制设计出合适的拼接参数。需要指出的是本文提出的改进方法主要是对影像拼接流程的改进, 如果利用其他的快速特征检测算子例如PCA-SIFT、SURF、CenSurE等代替文中的SIFT算子, 那么相同条件下拼接速度将会更快, 但是拼接效果有待进一步验证。本文只针对拼接速度的优化, 对影像拼接的其他问题没有顾及, 主要存在两个方面的不足: 一是缺少拼接畸变的控制策略; 二是不适合视差较大的影像的拼接, 下一步将针对这两个问题进行改进。

参考文献:

- [1] Evcarets J. The use of Unmanned Aerial Vehicles(UAV) for remote sensing and mapping[C]//the International Archives of the Photogrammetry, Remote Sensing and Spatial Information Science, Beijing, 2008: 1187-1192.
- [2] Zhang Yongjun. Photogrammetric processing of low altitude image sequences by unmaed airship[C]//the International Archives of the Photogrammetry, Remote Sensing and Spatial Information Science, Beijing, 2008: 751-757.
- [3] Lowe D G. Distinctive image features from scale-invariant keypoints[J]. International Journal of Computer Vision, 2004, 60(2): 91-110.
- [4] 宋海华, 邵志一. 基于改进型特征匹配的图像拼接方案设计[J]. 电视技术, 2008, 32(2): 19-20.
- [5] 刘立, 彭复员, 赵坤, 等. 采用简化SIFT算法实现快速图像匹配[J]. 红外与激光工程, 2008, 37(1): 181-184.
- [6] 刘小军, 杨杰, 孙坚伟, 等. 基于SIFT的图像配准方法[J]. 红外与激光工程, 2008, 37(1): 156-160.
- [7] 吴福朝. 计算机视觉中的数学方法[M]. 北京: 科学出版社, 2008: 68-70.

(上接183页)

- [8] Yang Jian, Zhang D, Yang Jingyu, et al. Globally maximizing, locally minimizing: unsupervised discriminant projection with applications to face and palm biometrics[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2007, 29(4): 650-664.
- [9] Yan Shuicheng, Xu Dong, Zhang Benyu, et al. Graph embedding and extensions: a general framework for dimensionality reduction[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2007,

29(1): 40-51.

- [10] 魏莱, 王守觉. 基于流形距离的半监督判别分析[J]. 软件学报, 2010, 21(10): 2445-2453.
- [11] 詹宇斌, 殷建平, 刘新旺, 等. 流形学习中基于局部线性结构的自适应邻域选择[J]. 计算机研究与发展, 2011, 48(4): 576-583.
- [12] Qiu H N, Lai J H, Huang J, et al. Semi-supervised discriminant analysis based on UDP regularization[C]//Proc of the 19th International Conference on Pattern Recognition. Tampa: IEEE, 2008: 1-4.