

基于 GPU 并行加速的多特征融合的超图降维方法

洪朝群 陈旭辉 王晓栋 李士锦 吴克寿

(厦门理工学院计算机与信息工程学院 厦门 361024)

摘 要 基于图的学习方法目前广泛用于降低特征维度。然而,对于多特征数据而言,不同特征之间的不同关联性很难结合到单个图中。针对多特征数据提出了新的半监督降维方法。首先,以超图中的超边作为片,使超图应用到片对齐框架中。然后,通过统计片中相邻的特征对的距离计算超边的权重,使得不同特征下的片得到结合。其次,由于欧氏距离和矩阵乘法的计算在拉普拉斯矩阵的构造过程中占用了大部分的时间,因此使用 GPU 对其进行加速。实验结果表明了所提方法在分类性能和学习速度上的提升效果。

关键词 降维,多特征融合,片对齐框架,超图学习,基于 GPU 的并行加速

中图法分类号 TP391.4 文献标识码 A DOI 10.11896/j.issn.1002-137X.2015.11.018

Hypergraph Dimensionality Reduction with Multiple Feature Fusion Based on GPU Parallel Acceleration

HONG Chao-qun CHEN Xu-hui WANG Xiao-dong LI Shi-jin WU Ke-shou

(College of Computer and Information Engineering, Xiamen University of Technology, Xiamen 361024, China)

Abstract Graph-based learning methods are currently popular for dimensionality reduction. However, for multiple feature data, different relationships from different features are hard to be integrated into a single graph. In this paper, a novel semi-supervised dimensionality reduction method was proposed for multiple feature data. First, the hyperedges in hypergraph are assumed as patches. In this way, hypergraph is applied to patch alignment framework. Then, the weights of hyperedges are computed with statistics of distances between neighboring pairs and the patches from different features are integrated. Second, the speed of computing Euclidean distances and matrix multiplication is improved by using GPU, since they take most of time in constructing the Laplacian matrix. The experimental results demonstrate the improvement on both classification performance and learning speed.

Keywords Dimensionality reduction, Multiple feature fusion, Patch alignment framework, Hypergraph learning, GPU-based parallel acceleration

1 引言

图像或者图像中的物体可以用多种多样的特征进行描述,例如颜色、形状、轮廓、纹理等。可以说,不同的特征用于描述图像不同的属性。因为单一种类的特征无法完整地描述图像,所以研究者提出了结合不同特征进行机器学习的方法,并且称之为多特征融合(Multiple Feature Fusion)或者多视角学习(Multi-view Learning)。多特征融合引起了广泛的关注并且已成为当前的研究热点,分类、检索、聚类等方法都因为获益于多种特征的使用,所以在性能上得到了提升^[1,2]。然而,用于描述图像的特征经常存在于较高的维度空间,从而产生了所谓的“维度灾难(curse of dimensionality)”问题。由于该问题的存在,机器学习方法的时间消耗和空间消耗都会受到维度数量的影响。部分研究者也致力于解决该问题,提出了降低特征维度的方法。主成分分析(Principal Component Analysis)^[3]是一种传统的降维方法,它采用无监督的学

习模式,没有考虑到不同特征之间的联系,因此无法用于多特征融合情况下的降维。线性判别分析(Linear Discriminant Analysis)是另外一种被广泛应用的方法^[4]。这是一种有监督的降维方法,但是线性判别分析的全局线性假设制约了其在非线性分布情况下的效果。

目前流行的降维方法大多基于流形学习(Manifold Learning)^[5-9]。其中,拉普拉斯特征图谱(Laplacian Eigenmaps)是一种基于图的学习方法。该方法将图像的特征作为节点,将特征之间的联系作为边,从而构造关联图。如果两个节点之间通过边进行连接,则表示两者具有某种相似性。因此,基于图的降维方法的核心在于如何构造关联图。基于图的方法可以将不同的特征用节点和边的形式进行统一化的描述,因此可以用于多特征融合的学习。学习的结果是一系列描述了关联图结构的矩阵,被称为拉普拉斯矩阵。

现有方法往往将特征之间的相关性定义为成对的关系。在大部分情况下,具备某种相关性的特征数量往往超过 2。

收稿日期:2014-11-29 返修日期:2015-01-10 本文受国家自然科学基金(61202145),福建省自然科学基金(2014J01256)资助。

洪朝群(1984—),男,博士,副教授,主要研究方向为计算机视觉、高性能计算、物联网技术,E-mail:cqhong@xmut.edu.cn;陈旭辉(1972—),男,博士,教授,主要研究方向为计算机网络、脑机交互;王晓栋(1983—),男,硕士,讲师,主要研究方向为图像处理、计算机视觉;李士锦 男,主要研究方向为图像图形处理;吴克寿(1975—),男,博士,教授,主要研究方向为软件体系结构、嵌入式系统安全、云计算及其应用。

为了避免成对关系的定义所带来的问题,研究者们又进一步提出了超图的概念^[10]。在超图中,一条超边(hyperedge)可以连接的节点数量大于2。实际上,某个超边所连接的节点构成了全部节点的一个子集。每条超边被赋予一个权重值。

当前,基于超图的多特征融合的降维方法仍然存在如下问题:

1)多种特征的相关性基于不同的衡量标准,如何合理设置超边的权重就是最关键的问题,现有方法往往需要递归的优化过程以获得合理的融合结果;

2)基于图的方法学习过程需要进行复杂的矩阵运算,在应对大量数据之时,难以在可接受的时间范围内获得结果。

为了解决以上问题,本文针对多特征融合提出了一种新的降维方法。本方法的贡献有:

1)将超图的构造过程应用于片对齐框架(Patch Alignment Framework),从而提出了新的半监督降维方法,该方法可以将不同特征的超边结合在一起,将维度降低后的信息嵌入到结合后的拉普拉斯矩阵中;

2)利用 GPU 基于 CUDA 实现快速的拉普拉斯矩阵构造,使得该方法在数据量较大的时候仍然适用。

2 基于片对齐框架的多特征融合超图学习

片对齐框架由 Zhang 等人提出^[11]。该方法将基于频谱分析的降维方法,如 LLE/NPE/ONNP^[5]、ISOMAP^[6]、LE/LPP^[7]、HLLE^[8]、LTSA/LLTSA^[9]、PCA^[3]和 LDA^[4],定义为统一的框架,从而成为降维方法的分析与开发工具。在该框架下,关联图的构造过程分为两个阶段。在局部优化阶段,不同的方法针对不同的片(patch)有不同的优化标准。每个片实际上包含了部分具有相关性的节点。在全局对齐阶段,将所有已经优化的片进行结合,最终获得每个独立的片的全局坐标。不同的降维方法在全局对齐阶段基本相同,而在局部优化阶段各有特点。

本文提出了将超图引入片对齐框架的降维方法,其过程遵循片对齐框架的两个阶段。由于超图的复杂性,其相关定义列举在表1中。

表1 超图中符号的定义

符号	定义
u, v	超图中的节点
e	超图中的超边
$\omega(e)$	超边 e 的权重
$\delta(e)$	超边 e 的度数,表明有多少个节点通过 e 连接
$d(v)$	节点 v 的度数,对连接到该节点的所有超边的权重进行求和
D_v	保存了节点度数的对角线矩阵
D_e	保存了超边度数的对角线矩阵
H	体现节点与超边从属关系的矩阵,如果 $H(u, e)=1$, 表明 v 被 e 连接,即 $v \in e$
Ω	保存了超边权重的对角线矩阵
V	节点的集合
E	超边的集合

2.1 局部优化阶段

构建超图的全局组合优化问题可以由以下的实数形式进行近似:

$$\arg \min_{f \in \mathbb{R}^{|V|}} \frac{1}{2} \sum_{e \in E} \sum_{u, v \in e} \frac{\omega(e)}{\delta(e)} \left(\frac{f(u)}{\sqrt{d(u)}} - \frac{f(v)}{\sqrt{d(v)}} \right)^2 \quad (1)$$

在局部优化阶段,片被定义为由一个超边连接的节点集合,局部优化即为:

$$\arg \min_{f \in \mathbb{R}^{|V|}} \sum_{u, v \in e} \frac{\omega(e)}{\delta(e)} \left(\frac{f(u)}{\sqrt{d(u)}} - \frac{f(v)}{\sqrt{d(v)}} \right)^2 \quad (2)$$

对于每个片,需计算:

$$\sum_{u, v \in e} \frac{\omega(e)}{\delta(e)} \left(\frac{f(u)}{\sqrt{d(u)}} - \frac{f(v)}{\sqrt{d(v)}} \right)^2 \quad (3)$$

即选取超边 e 所连接的任意两个节点,并对以下公式的结果求和:

$$\frac{\omega(e)}{\delta(e)} \left(\frac{f(u)}{\sqrt{d(u)}} - \frac{f(v)}{\sqrt{d(v)}} \right)^2 \quad (4)$$

为求解局部优化,式(3)可展开为:

$$\begin{aligned} & \frac{\omega(e)}{\delta(e)} \left(\frac{f(1)}{\sqrt{d(1)}} - \frac{f(2)}{\sqrt{d(2)}} \right)^2 + \frac{\omega(e)}{\delta(e)} \left(\frac{f(1)}{\sqrt{d(1)}} - \frac{f(3)}{\sqrt{d(3)}} \right)^2 + \\ & \dots + \frac{\omega(e)}{\delta(e)} \left(\frac{f(1)}{\sqrt{d(1)}} - \frac{f(n)}{\sqrt{d(n)}} \right)^2 + \frac{\omega(e)}{\delta(e)} \left(\frac{f(2)}{\sqrt{d(2)}} - \frac{f(1)}{\sqrt{d(1)}} \right)^2 + \\ & \frac{\omega(e)}{\delta(e)} \left(\frac{f(2)}{\sqrt{d(2)}} - \frac{f(3)}{\sqrt{d(3)}} \right)^2 + \dots + \frac{\omega(e)}{\delta(e)} \left(\frac{f(2)}{\sqrt{d(2)}} - \frac{f(n)}{\sqrt{d(n)}} \right)^2 + \\ & \dots + \frac{\omega(e)}{\delta(e)} \left(\frac{f(n)}{\sqrt{d(n)}} - \frac{f(1)}{\sqrt{d(1)}} \right)^2 + \frac{\omega(e)}{\delta(e)} \left(\frac{f(n)}{\sqrt{d(n)}} - \frac{f(2)}{\sqrt{d(2)}} \right)^2 + \\ & \dots + \frac{\omega(e)}{\delta(e)} \left(\frac{f(n)}{\sqrt{d(n)}} - \frac{f(n-1)}{\sqrt{d(n-1)}} \right)^2 \end{aligned} \quad (5)$$

其中, n 是超边 e 所包含的节点数量。也就是说, n 是矩阵 H 中第 e 列的和。根据片对齐框架,式(5)的矩阵形式为:

$$\begin{aligned} & A_1^T H_{u,e} \frac{\Omega}{E_e} H_{u,e} A_1 + A_2^T H_{u,e} \frac{\Omega}{E_e} H_{u,e} A_2 + \dots + \\ & A_N^T H_{u,e} \frac{\Omega}{E_e} H_{u,e} A_N \end{aligned} \quad (6)$$

其中, $H_{u,e}$ 表示第 e 列的第 u 个项, $H_{u,e}=1$ 说明节点 u 包含在超边 e 中。 N 是整个超图中的节点数量。 A_n 为:

$$\begin{aligned} A_1 &= [0 \quad \frac{f(1)}{\sqrt{d(1)}} - \frac{f(2)}{\sqrt{d(2)}} \quad \frac{f(1)}{\sqrt{d(1)}} - \frac{f(3)}{\sqrt{d(3)}} \quad \dots \\ & \quad \frac{f(1)}{\sqrt{d(1)}} - \frac{f(N)}{\sqrt{d(N)}}] \\ A_2 &= [0 \quad 0 \quad \frac{f(2)}{\sqrt{d(2)}} - \frac{f(3)}{\sqrt{d(3)}} \quad \dots \quad \frac{f(2)}{\sqrt{d(2)}} - \frac{f(N)}{\sqrt{d(N)}}] \end{aligned} \quad (7)$$

$$A_n = [0 \quad 0 \quad 0 \quad \dots \quad \frac{f(n)}{\sqrt{d(n)}} - \frac{f(N)}{\sqrt{d(N)}}]$$

式(5)可以重写为:

$$\begin{aligned} & \frac{1}{2} (B_1^T H_{u,e} \frac{\Omega}{E_e} H_{u,e} B_1 + A B_2^T H_{u,e} \frac{\Omega}{E_e} H_{u,e} B_2 + \dots + \\ & B_N^T H_{u,e} \frac{\Omega}{E_e} H_{u,e} B_N) \end{aligned} \quad (8)$$

其中 B_n 为:

$$\begin{aligned} B_1 &= [0 \quad \frac{f(1)}{\sqrt{d(1)}} - \frac{f(2)}{\sqrt{d(2)}} \quad \frac{f(1)}{\sqrt{d(1)}} - \frac{f(3)}{\sqrt{d(3)}} \quad \dots \\ & \quad \frac{f(1)}{\sqrt{d(1)}} - \frac{f(N)}{\sqrt{d(N)}}] \end{aligned}$$

$$B_2 = \begin{bmatrix} \frac{f(2)}{\sqrt{d(2)}} - \frac{f(1)}{\sqrt{d(1)}} & 0 & \frac{f(2)}{\sqrt{d(2)}} - \frac{f(3)}{\sqrt{d(3)}} & \dots \\ \frac{f(2)}{\sqrt{d(2)}} - \frac{f(N)}{\sqrt{d(N)}} \end{bmatrix} \quad (9)$$

$$B_n = \begin{bmatrix} \frac{f(n)}{\sqrt{d(n)}} - \frac{f(1)}{\sqrt{d(1)}} & \frac{f(n)}{\sqrt{d(n)}} - \frac{f(2)}{\sqrt{d(2)}} & 0 & \dots \\ \frac{f(n)}{\sqrt{d(n)}} - \frac{f(N)}{\sqrt{d(N)}} \end{bmatrix}$$

最后,每个超边的片优化公式为:

$$\frac{1}{2} \sum_{v \in e} \frac{F}{D_v^{\frac{1}{2}}} E H_e' \frac{\Omega}{D_e} H_e E' \frac{F}{D_v^{\frac{1}{2}}} \quad (10)$$

其中,矩阵 E 为:

$$\begin{bmatrix} -\vec{e}^T \\ I \end{bmatrix} \quad (11)$$

其中, $\vec{e}^T = [1, \dots, 1]^T$, I 为 $n \times n$ 的单位矩阵。

2.2 全局对齐阶段

在全局对齐阶段,每类特征的所有超边都会进行计算,并且用于构成完整的超图。该构造过程需要计算超边的权重矩阵 Ω 。矩阵中的每个项即为对应的超边的权重,其值通过计算超边中的所有节点相似度之和获取。任意两个节点的相似度定义为:

$$\text{dist}(u, v) = \exp\left(-\frac{1}{\beta} \|\text{feat}(u), \text{feat}(v)\|\right) \quad (12)$$

其中, $\text{feat}(u)$ 为某种特征表示的节点 u , $\|\text{feat}(u), \text{feat}(v)\|$ 为两个特征的欧氏距离, β 为距离的标准差。获得了超边的权重矩阵,多特征融合的超图拉普拉斯矩阵可以通过对式(10)进行求和获得,即:

$$\frac{1}{2} \sum_{e \in E} \sum_{v \in e} \frac{F}{D_v^{\frac{1}{2}}} E H_e' \frac{\Omega}{D_e} H_e E' \frac{F}{D_v^{\frac{1}{2}}} \quad (13)$$

2.3 实现过程

结合以上的超图构造过程,具体的实现过程分为以下几步:

- 1) 对于已标记的训练样本,利用欧氏距离寻找 k_i 个来自相同类别的相邻样本和 k_d 个来自不同类别的相邻样本,以上两部分样本用于构造一个超边;
- 2) 对于未标记的训练样本,利用欧氏距离寻找 k_u 个相邻样本,用于构造一个超边;
- 3) 对所有特征进行以上两个步骤的处理,从而根据表1的定义初始化 H 、 D_v 、 D_e 和 Ω ;
- 4) 根据式(13)求解多特征融合的超图拉普拉斯矩阵;
- 5) 对拉普拉斯矩阵进行标准特征分解,获得投影矩阵,选取特征值最小的 d 个特征矢量,即获得维度数量为 d 的降维特征矢量。

3 GPU 加速的超图学习

根据对以上学习过程的分析,时间消耗主要集中在:

- 1) 计算特征之间的欧氏距离;
- 2) 求解矩阵乘法。

因此,本文的方法特别针对以上两个部分通过 GPU 的并行计算进行加速优化。优化过程采用 CUDA^[12] 实现。

3.1 欧氏距离的计算

两个矢量之间的欧氏距离定义为:

$$\|p - q\| = \sqrt{\sum_{i=1}^k (p_i - q_i)^2} \quad (14)$$

其中, k 为矢量的维度数。如果要对两个矩阵即两组多个矢量进行求和,式(14)需求解 $l \times m$ 次, l 和 m 分别为矩阵 P 和 Q 中包含的矢量数量。为快速求解,将式(14)展开,可得:

$$\|p - q\| = \text{sqrt}(\|p\|^2 + \|q\|^2 - 2 \times p \cdot q) \quad (15)$$

对于矩阵的情况,其过程为:

- 1) 计算 $P \cdot P$ 和 $Q \cdot Q$,并对各自的结果按列求和,得 S_P 与 S_Q ;
- 2) 计算 $P \cdot Q$,得 S_{PQ} ;
- 3) 将 S_P 按列复制 m 次,将 S_Q 按列复制 l 次,得 C_P 与 C_Q ;
- 4) 计算 $\text{sqrt}(C_P + C_Q - 2 \times S_{PQ})$ 。

以上过程只需进行一次矩阵乘法,其他均为对矩阵中各个项或者各个矩阵中对应位置上的项进行计算。因此可通过创建网格,利用多个线程块和每个线程块下的多线程,使用核函数进行快速并行计算。

3.2 矩阵乘法的优化

在本方法中,矩阵乘法优化的基本思想为:

- 1) 每个块负责一个输出矩阵中 16×16 小块的结果运算;
 - 2) 利用共享存储器实现对全局存储器的合并访问和存储。
- 线程块、线程的分配与矩阵中的项索引关系如图1所示。




图1 矩阵乘法优化的项索引

4 实验结果

4.1 数据集与实验设置

本文使用 PASCAL VOC2007 数据集^[13],通过图像分类的准确率进行方法的验证。PASCAL VOC2007 是具有较强挑战性的数据集,因为其图像类别多种多样,物体所处的背景也比较复杂。由于全局特征的图像内容表达能力有限,目前使用全局特征的方法取得的正确率普遍较低。本文在实验中选取了6个类别(person、airplane、train、boat、motorbike 和 horse)大约1200张图片。由于在 PASCAL VOC2007 中,每张图片可能包含多个物体,因此图片所属的类别根据其包含的最大的物体进行指定。数据集被分为两个子集,一个用于训练,另一个用于测试。使用支持向量机(Support Vector Machines)^[14]对图片的特征进行分类。

本文使用的特征有以下3种:

- 1) HSV 色彩直方图^[15],其特征维度数量为4096;
- 2) Dense SIFT 特征^[16],在固定的尺度和梯度方向上将图像分割为稠密的网格进行 SIFT 特征的计算,并利用 Bag of Words 统计直方图,其特征维度数量为1000;
- 3) GIST 特征^[17],通过 Gabor 滤波器提取图像不同频率

和方向上的信息,再将滤波的图像划分为 4×4 规则网格,对每个网格取均值,级联形成全局 Gist 特征,其特征维度数量为 512。

本文实验在 MATLAB 下进行。其中利用 CUDA 进行并行优化的函数用 C 语言编写,并使用 MEX 编译为 MATLAB 下可用的函数。实验所使用的软硬件环境如表 2 所列。

表 2 实验环境

项目	配置
操作系统	Microsoft Windows 7
开发环境	MATLAB R2013b+MEX
CPU	Intel Core i7-2640M @ 2.8GHz 四核
内存	4GB
GPU	GeForce GT 520M
显存	2GB
CUDA 版本	CUDA 6.0

4.2 降维方法的实验结果

本节将本文的方法与 PCA、MSE、LRR 等方法进行多特征融合,并将特征降低到不同的维度后进行分类准确率的比较。由于 PCA 方法本身并无对多特征进行融合处理的能力,为了使 PCA 可以用在多特征融合的数据之上,该方法的实验过程对特征进行了两种预先处理。一种是将不同类别的特征拼接成一个长矢量,另一种是计算不同特征的准确率并求平均值。结果如图 2 所示,可见本文的方法在大部分情况下比现有的方法准确率更高,特别是当特征的维度数量小于 100 时,本文提出的方法性能远高于其他两种方法。可能由于维度的降低与局部性的保持存在冲突,本文的方法在特征维度为 100 时出现了明显的性能下降,然而其平均准确率仍然达到了 37.4%。相比之下,PCA(长矢量)准确率为 31.3%,PCA(平均)为 28.5%,MSE 为 28.8%,LRR 为 29.7%。




图 2 准确率的比较

4.3 GPU 加速的实验结果

本节通过不同训练集大小下的超图构造时间消耗展示加速的结果,如图 3 所示。从图中可见,利用 GPU 加速的训练过程的时间消耗远低于原始的未使用并行优化的 CPU 计算方法,加速比达到 18~157 倍。GPU 加速后的时间消耗随着训练集增大呈现缓慢的线性增加的趋势,而 CPU 计算的时间消耗呈现指数级的增加。因此,GPU 加速使得所提方法在数据量较大的情况下仍然可以适用。




图 3 运行时间的比较

结束语 本文基于片对齐框架提出了一种多特征融合的降维方法。首先,该方法利用超图描述数据之间的关联性,并且通过局部优化阶段将不同特征下构造的片进行结合,从而获得拉普拉斯矩阵。其次,利用 GPU 加速优化了欧氏距离和矩阵乘法的计算,使得数据量增大时运算时间仍然处于很短的范围内。在 PASCAL VOC2007 上的实验表明,文中所提方法比现有方法有明显的性能提升。

参考文献

[1] Yu Jun, Tao Da-cheng, Rui Yong, et al. Pairwise constraints based multiview features fusion for scene classification[J]. Pattern Recognition, 2013, 46(2): 483-496

[2] Yu Jun, Wang Meng, Tao Da-cheng. Semisupervised multiview distance metric learning for cartoon synthesis[J]. IEEE Transactions on Image Process, 2012, 21(11): 4636-4648

[3] Jolliffe I. Principal component analysis[M]. New York: Springer-Verlag, 1986

[4] Belhumeur P N, Hespanha J P, Kriegman D J. Eigenfaces vs. Fisherfaces: Recognition using class specific linear projection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1997, 19(7): 711-720

[5] Roweis S, Saul L. Nonlinear dimensionality reduction by locally linear embedding[J]. Science, 2000, 290(5500): 2323-2326

[6] Tenenbaum V S J, Langford J. A global geometric framework for nonlinear dimensionality reduction [J]. Science, 2000, 290(5500): 2319-2323

[7] Belkin M, Niyogi P. Laplacian eigenmaps and spectral techniques for embedding and clustering[M]// Advances in Neural Information Processing System 14. Cambridge: MIT Press, 2001: 585-591

[8] Donoho D L, Grimes C. Hessian Eigenmaps: New Locally Linear Embedding Techniques for High-dimensional Data[J]. National Academy of Sciences, 2003, 100(10): 5591-5596

[9] Zhang Z, Zha H. Principal manifolds and nonlinear dimension reduction via local tangent space alignment[J]. SIAM J. Scientific Computing, 2005, 26(1): 313-338

[10] Zhou Deng-yong, Huang Jia-yuan, Scholkopf B. Learning with hypergraphs: clustering, classification, and embedding [C] // Proc. of Advances in Neural Information Processing Systems. Cambridge: MIT Press, 2006: 1601-1608

[11] Zhang Tian-hao, Tao Da-cheng, Li Xue-long, et al. Patch alignment for dimensionality reduction [J]. IEEE Transactions on Knowledge and Data Engineering, 2009, 21(9): 1299-1313

[12] NVidia Corporation. CUDA C PROGRAMMING GUIDE v6.0 [M]. 2014

[13] Everingham M, Van Gool L, et al. The PASCAL Visual Object Classes Challenge 2007(VOC2007) Results[OL]. <http://www.pascal-network.org/challenges/VOC/voc2007/workshop/index.html>

[14] Vapnik V N. Statistical Learning Theory[M]. New York: Wiley-Interscience, 1998

[15] Agoston M K. Computer Graphics and Geometric Modeling: Implementation and Algorithms[M]. London: Springer, 2005: 300-306

表5 不同算法复原图 IV 所得清晰图像的定量分析结果比较

	综合判定结果	Tenen Grad 函数	Brenner 函数	方差函数	平方梯度函数	Vollath 函数	加窗梯度函数	熵函数
雾天图像	59.93	43.54	54.78	81.76	37.39	80.99	23.53	97.17
Tarel 算法	75.51	100	100	21.39	100	19.98	100	92.35
He 算法	83.90	73.47	71.89	95.38	77.44	95.19	86.74	98.17
本文算法	95.26	93.15	88.59	100	95.49	100	93.63	100

上述表中的综合判定结果是通过给 TenenGrad 函数、Brenner 函数、方差函数、平方梯度函数、Vollath 函数、加窗梯度函数和熵函数的输出值分别赋予 20%、20%、20%、10%、10%、10%、10% 的权值而得到的。

从中可以看出,本文算法的综合判定结果都是最高的,因此,利用本文提出的算法进行去雾得到的图像更清晰,更有效地抑制了 Halo 效应。虽然有些分析结果要低于 Tarel 算法,但是 Tarel 算法还原得到的图像的颜色过于饱和,出现了严重的颜色失真,而本文算法完好地保留了原图像的色度。

结束语 通过对图像中光晕的位置和结构特点进行大量的观察和分析,提出了一种基于 Sigmoid 函数的抑制 Halo 效应的有效算法。同时,引入了一种容差机制来分割出不满足暗通道先验的天空区域,弱化对于此区域的去雾,增加了算法的鲁棒性。本算法的特色在于所构造的模板仅仅处理出现光晕的区域,而不是处理整个图像区域,因此避免了传统方法中非光晕区域的颜色失真问题。最终通过大量实验表明,本算法有效、简单易行、运算速率快、复原效果好。

但是,本文算法引入了一些参数,而这些参数都是经验值,适用于大部分图像,对于少部分图像的处理效果不是特别理想。同时,本文算法虽然有效地抑制了 Halo 效应,但未完全消除,其难点在于准确确定光晕出现的位置及方向,构造更加合理的模板来消除 Halo 效应。因此,针对不同图像自适应获取这些参数,准确确定光晕出现的位置、方向及构造更加合理的模板是今后努力的方向。

参考文献

- [1] 禹晶,徐东彬,廖庆敏. 图像去雾技术研究进展[J]. 中国图象图形学报,2011,16(9):1561-1575
Yu J, Xu D B, Liao Q M. Image defogging: a survey[J]. Journal of Image and Graphics, 2011, 16(9): 1561-1575
- [2] 郭瑶. 图像去雾方法和评价及其应用研究[D]. 长沙:中南大学, 2012
Guo P. Research on Image Defogging, Effect Assessment and Application[D]. Changsha: Central South University, 2012
- [3] Namer E, Schechner Y Y. Advanced visibility improvement based on polarization filtered images[C]// Proceedings of the Polarization Science and Remote Sensing, 2005. San Diego, USA; SPIE, 2005: 36-45
- [4] He K M, Sun J, Tang X O. Single image haze removal using dark channel prior[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2009. Miami, USA: IEEE, 2009: 1956-196
- [5] 钟乾龙. 单幅图像去雾处理算法研究及软件实现[D]. 成都: 西南交通大学, 2012
Zhong Q L. The Research of Single Image-Defogging Processing Algorithm and Software Implement[D]. Chengdu: Southwest Jiaotong University, 2012
- [6] Tarel J, Hauti N. Fast visibility restoration from a single color or gray level image[C]// Proceedings of IEEE International Conference on Computer Vision (ICCV), 2009. Kyoto, Japan: IEEE Computer Society, 2009: 2201-2208
- [7] 禹晶, 李大鹏, 廖庆敏. 基于物理模型的快速单幅图像去雾方法[J]. 自动化学报, 2011, 37(2): 143-149
Yu J, Li D P, Liao Q M. Physics-based Fast Single Image Fog removal[J]. Acta Automatica Sinica, 2011, 37(2): 143-149
- [8] 方帅, 王勇, 曹洋. 单幅雾天图像复原[J]. 电子学报, 2010, 38(10): 2279-2284
Fang S, Wang Y, Cao Y. Restoration of Image Degraded by Haze [J]. Acta Electronica Sinica, 2010, 38(10): 2279-2284
- [9] 褚宏莉, 李元祥, 周则明, 等. 基于黑色通道的图像快速去雾优化算法[J]. 电子学报, 2013, 41(4): 791-797
Chu H L, Li Y X, Zhou Z M, et al. Optimized Fast Dehazing Method Based on Dark Channel Prior[J]. Acta Electronic Sinica, 2013, 41(4): 791-797
- [10] Narasimhan S G, Nayar S K. Chromatic framework for vision in bad weather[C]// Proceedings of IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2000. Hilton Head Island, SC, USA: IEEE Computer Society, 2000: 1598-1605
- [11] Fattal R. Single image dehazing [J]. ACM Transaction on Graphics, 2008, 27(3): 1-9
- [12] 蒋建国, 侯天峰, 齐美彬. 改进的基于暗原色先验的图像去雾算法[J]. 电路与系统学报, 2011, 16(2): 7-12
Jiang J G, Hou T F, Qi M B. Improved Algorithm on Image Haze Removal Using Dark Channel Prior[J]. Journal of Circuits and Systems, 2011, 16(2): 7-12
- [13] Tan R. Visibility in bad weather from a single image[C]// Proceedings of IECVPR, 2008. Anchorage, Alaska: IEEE Computer Society, 2008: 1-8
- [14] 王一帆, 尹传历, 黄义明, 等. 基于双边滤波的图像去雾[J]. 中国图象图形学报, 2014, 19(3): 386-392
Wang Y F, Yin C L, Huang Y M, et al. Image Haze Removal Using a Bilateral Filter[J]. Journal of Image and Graphics, 2014, 19(3): 386-392
- [15] Bosch A, Zisserman A, Munoz X. Image classification using random forests and ferns[C]// Proceedings of International Conference on Computer Vision. New York: IEEE, 2007: 1-8
- [16] Siagian C, Itti L. Rapid Biologically-Inspired Scene Classification Using Features Shared with Visual Attention[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2007, 29(2): 300-312
- [17] Xia Tian, Tao Da-cheng, Mei Tao, et al. Multiview spectral embedding[J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics, 2010, 40(6): 1438-1446
- [18] Cheng Bin, Liu Guang-can, Wang Jing-dong, et al. Multi-task Low-rank Affinity Pursuit for Image Segmentation[C]// Proceedings of IEEE International Conference on Computer Vision. New York: IEEE, 2011: 2439-2446

(上接第 93 页)