基于非线性重构模型的植物叶片图像集分类方法

刘孟南 杜吉祥

(华侨大学计算机科学与技术学院 厦门 361021)

摘 要 提出一种基于非线性重构模型的植物叶片图像集的分类识别方法。该方法首先使用高斯受限玻尔兹曼机(GRBMs)通过非监督预训练来初始化模型的权值;然后针对每一个植物叶片图像集用初始化的模型训练得到一个特定的模型;最后根据测试样本的最小重构误差和测试样本集的最多投票策略来判定测试样本集的类别。该方法通过图像预处理来处理图像,避免了图像在缩放时发生形变,并采用基于k-means的特征提取方法来提取植物叶片图像特征。实验结果表明,该方法能够准确地对植物叶片图像集进行分类识别。

关键词 非线性重构模型,高斯RBMs,k-means特征提取,图像预处理

中图法分类号 TP391 **文献标识码** A

Plant Leaf Image Set Classification Approach Based on Non-linear Reconstruction Models

LIU Meng-nan DU Ji-xiang

(School of Computer Science and Technology, Huaqiao University, Xiamen 361021, China)

Abstract In this paper, a plant leaf image set identification approach was proposed based on non-linear reconstruction models. This approach initializes the parameters of model by performing unsupervised pre-training using Gaussian restricted Boltzmann machines(GRBMs). Then, the pre-initialized model is separately trained for images of each plant set and class-specific models are learnt. At last, based on the minimum reconstruction error from the learnt class-specific models, majority voting strategy is used for classification. Besides, in order to avoid occurring deformation during the image scaled, this paper normalized plant image by image preprocessing and a method of feature extraction was used based on k-means. The experimental results show that this approach can accurately classify the class of plant image set.

Keywords Non-linear reconstruction models, Gaussian restricted Boltzmann machines, K-means feature extract, Image preprocessing

1 引言

公认自然界存在超过40万种植物[1-2],它们形态各异,结构差异很大,生存环境也各不相同。为了能更好地认识和利用植物,必须对植物进行分类识别。我国农业在国民经济中一直占有重要地位,对植物进行分类能够促进植物学、农业现代化的发展,对生态环境和生物多样性等方面的保护也起到了积极的作用。

传统的植物分类技术的测试集和训练集中每类植物权包含单张或者少量样本图像,因此识别率很大程度上取决于样本的好坏[3-5]。随着技术的进步,我们可以获得大量的植物叶片图像。此外,基于图像集的植物分类研究更有能力处理研究对象各方面的变化,包括类内差异、光线改变、多视角、非刚性形变、遮挡物等。成熟有效的植物叶片图像集分类识别算法对园林植物识别、医药植物识别和国民经济有重要意义。

从图像集建模的角度,基于图像集的物体识别方法大致分为两类:基于模型的参数化方法[7-10]和模型无关的非参数方法[11-13]。存在的基于图像集的识别方法大多将类内图像的变化信息建模在非线性流形上,如格拉斯曼流形[8,10]、黎曼流形[12]。但是这种建模方法需要假设物体图像分布在某种特定的流。本文提出一种基于非线性的重构模型的植物叶片图像集的分类识别方法。与其他基于图像集的方法相比,该方法能够自动学习和发现每类植物叶片图像潜在的非线性流形结构,而无需先验假设。与一些基于深度学习的方法相比,该方法使用高斯受限玻尔兹曼机(GRBMs)通过非监督预训练来初始化模型的权值,能够有效避免梯度弥散和陷入局部极小值。由于输出层的分类效果不好,且添加新数据后需要重新训练网络,该方法为每一个植物叶片图像集用初始化的模型训练得到一个特定的模型,当需要插入新的训练样本集时,无需重新训练整个网络,只需为该训练样本集训练特定的模型;然后根据测试样本的最小重构误差和测试样本集的最多投票策略来判定测试样本集的类别。另外,本文通过图像的预处理来标准化图像,避免了图像在缩放时发生形变,并采用基于k-means的特征提取方法来提取叶片图像的特征。

2 基于非线性重构模型的植物叶片图像集的分类识别方法

非线性重构模型能够学习数据潜在的非线性流结构。对

本文受国家自然科学基金项目(61175121),福建省自然科学基金项目(2013J06014),华侨大学中青年教师科研提升资助计划项目(ZQN-YX108)资助。

刘孟南(1990-),男,硕士生,主要研究方向为模式识别与图像处理,E-mail:1125220118@qq.com;杜吉祥(1977-),男,博士,教授,硕士生导师,主要研究方向为图像处理、神经网络、数据挖掘等,E-mail:jxdu@hqu.edu.cn(通信作者)。

于网络，适当的权值初始化是必要的，这里采用高斯 RBMs 通过非监督预训练的方法逐层训练得到模型的初始化权值，每个类用得到的权值初始化模型参数，并用各自的训练集训练模型，得到各自的模型参数。最后根据测试样本的最小重构误差和测试集的最多投票策略进行类别的判定。

2.1　建立非线性重构模型

非线性重构模型结构是一个自动编码器，由编码器和解码器组成。编码器和解码器分别含有两个隐含层，其中共享第二个隐含层。非线性重构模型如图 1 所示。

编码器：

$$h_1=s(W_e^{(1)}x+b_e^{(1)})$$
$$h=s(W_e^{(2)}h_1+b_e^{(2)}) \tag{1}$$

解码器：

$$x''=s(W_d^{(1)}h+b_d^{(1)})$$
$$x'=s(W_d^{(2)}x''+b_d^{(2)}) \tag{2}$$

其中，$W_e^{(i)}\in\mathbb{R}^{d_{i-1}\times d_i}$ 是网络的权值矩阵，第 i 层有 d_i 个节点，$b_e^{(i)}\in\mathbb{R}^{d_i}$ 是偏差向量，$s(\cdot)$ 表示非线性激活函数。编码器部分是为了找到输入数据的一种紧凑的低维表示。编码器的参数是结合编码器和解码器并联合训练编码-解码结构通过最小化代价函数来得到的。因此，可以将解码器定义为结合非线性函数从编码器的输出重构输入数据。模型的参数表示为 $\theta=\{\theta_W,\theta_b\}$，其中 $\theta_W=\{W_e^{(i)},W_d^{(i)}\}^2$，$\theta_b=\{b_e^{(i)},b_b^{(i)}\}^2$。

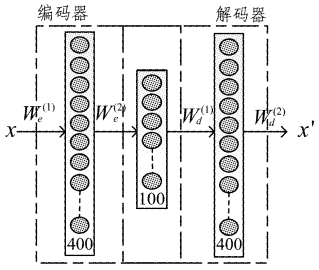

图 1　非线性重构模型

2.2　模型参数的初始化

为每一类训练一个特定的模型，但是不适当的模型初始化权值会使训练的模型陷入局部极小值，或者出现梯度弥散的问题。因此采用高斯 RBMs 通过非监督的预训练的方法来逐层初始化模型的权值。由于标准的 RBM 的节点只能取 0 或 1，因此通过修改其能量函数将其扩展到实数域。修改后的能量函数为：

$$E_{GRBM}(v,h)=\sum_i\frac{(v_i-b_i)^2}{2\sigma_i^2}-\sum_j c_jh_j-\sum_{ij}w_{ij}\frac{v_i}{\sigma_i}h_j \tag{3}$$

其中，σ_i 是可视层实值输入数据的标准差。由于对比差异的方法不适合高斯 RBM 参数的学习，修改的高斯 RBM 的概率分布如下：

$$p(h_j=1|v)=sigmoid(\sum_i w_{ij}v_i+c_j) \tag{4}$$

$$p(v_i|h)=\frac{1}{\sigma_i\sqrt{2\pi}}\exp(\frac{-(v_i-u_i)^2}{2\sigma_i^2}) \tag{5}$$

其中，$u_i=b_i+\sigma_i^2\sum_j w_{ij}h_j$。

由于编码层学习的权值分别与相对应的解码层的权值关联，则有：$W_d^{(2)}=W_e^{(1)^{\mathrm{T}}}$，$W_d^{(1)}=W_e^{(2)^{\mathrm{T}}}$。至此得到了非线性重构模型的初始化权值。

2.3　学习特定的类模型

预训练得到模型的初始化权值后，对于 K 个类，分别为每个类训练微调模型的权值，得到 K 个特定的模型。通过随机梯度下降法来最小化类 X_c 中所有训练样本 $x^{(t)}$ 的重构误差，得到每一个模型的参数 $\theta(c)$。

$$J(\theta;x^{(t)}\in X_c)=\sum_{x^{(t)}}\|x^{(t)}-x'^{(t)}\|^2 \tag{6}$$

为了避免过拟合和提高可扩展性，引入正则化的代价函数，添加权重延迟判罚项 J_{wd} 和稀疏约束项 J_{sp} 的代价函数：

$$J_{reg}(\theta;x^{(t)}\in X_c)=\sum_{x^{(t)}}\|x^{(t)}-x'^{(t)}\|^2+\lambda_{wd}J_{wd}+\lambda_{sp}J_{sp} \tag{7}$$

其中，λ_{wd}，λ_{sp} 为正则化参数，J_{wd} 确保所有隐含层的权重值较小，其函数形式为：

$$J_{wd}=\sum_i^2\|W_e^{(i)}\|_F^2+\sum_i^2\|W_d^{(i)}\|_F^2 \tag{8}$$

J_{sp} 确保第 i 个隐含层的第 j 个单元的平均激活度 $\bar{\rho}_j^{(i)}$ 尽可能地接近稀疏目标值 ρ（一个很小的值），它是根据 KL 散度定义的，其函数形式为：

$$J_{sp}=\sum_i^3\sum_j KL(\rho\|\bar{\rho}_j^{(i)})=\sum_i^3\sum_j\rho\log\frac{\rho}{\bar{\rho}_j^{(i)}}+(1-\rho)\log\frac{1-\rho}{1-\bar{\rho}_j^{(i)}} \tag{9}$$

类特定模型参数 $\theta(c)$ 是通过用训练集 X_c 训练正则化的非线性重构模型得到的。

$$\theta(c)=\min_\theta J_{\mathrm{reg}}(\theta;x^{(t)}\in X_c) \tag{10}$$

2.4　分类

给定一个测试样本集 $X_{test}=\{x^{(1)},x^{(2)},\cdots,x^{(N_{test})}\}$，通过所有的类模型参数 $\theta(c)(c=1,\cdots,k)$ 来重构每一个测试样本 $x^{(t)}\in X_{test}$。如果 $x'^{(t)}(c)$ 是 $x^{(t)}$ 通过模型参数 $\theta(c)$ 重构得到的，则重构误差为：

$$r^{(t)}(c)=\|x^{(t)}-x'^{(t)}(c)\|_2 \tag{11}$$

根据最小重构误差来判定测试样本 $X^{(t)}$ 的类标签：

$$y^{(t)}=\arg\min_c r^{(t)}(c) \tag{12}$$

测试样本的最小重构误差只有从使用与本测试样本相同的训练集训练的模型中获得，据此，测试集 X_{test} 的标签 y_{test} 由测试样本投票最多的类决定：

$$y_{test}=\arg\max_c\sum_t\delta_c(y^{(t)})$$
$$\delta_{(c)}(y^{(t)})=\begin{cases}1, & y^{(t)}=c\\ 0, & \text{otherwise}\end{cases} \tag{13}$$

基于非线性重构模型的植物叶片图像集的分类识别流程如图 2 所示。

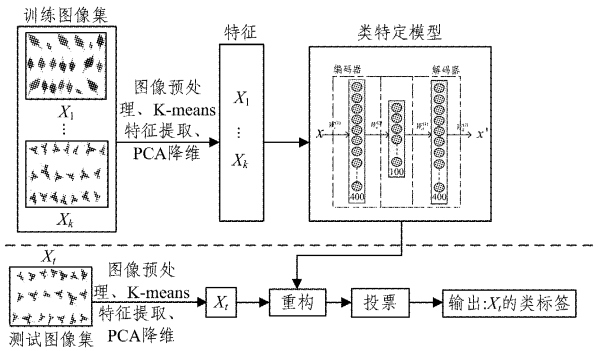

图 2　基于非线性重构模型的植物叶片图像集的分类识别流程图

3　图像的预处理和基于 k-means 的特征提取

3.1　图像的预处理

图像的预处理包含彩色图像灰度化、目标对象的提取，假

设提取后的图像为 $x\in R^{N\times M}$，$N\leqslant M$，需要标准化块大小 $L\times L$，根据 $M'=L$，$N'=N*L/M$ 来缩放目标图像，最后将缩放后的图像放置于标准化块的中心，从而得到预处理后的图像。预处理过程如图 3 所示。

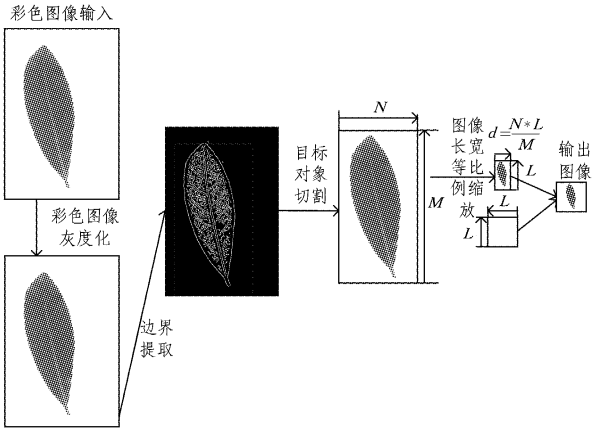

图 3 图像预处理

3.2 基于 k-means 的植物叶片特征提取

从图像集中随机提取 m 个图像块 $x\in\mathbb{R}^{w\times w}$，$N=w\times w$ 并列向量化构成块矩阵 $X=\{x^{(1)},\cdots,x^{(m)}\}$，$x^{(i)}\in\mathbb{R}^N$，然后进行白化处理，根据 k-means 聚类方法对白化处理后的块矩阵进行聚类，得到 k 个聚类中心 $c^{(k)}$。对于特征映射 $f:\mathbb{R}^N\rightarrow\mathbb{R}^K$，采用非线性映射函数：

$$f_k(x)=\max\{0,\mu(z)-z_k\} \tag{14}$$

其中，$z_k=\|x-c^{(k)}\|_2$，$\mu(z)$ 表示 z 的均值。该激活函数将图像块中的各像素值到对应的 k 个中心的距离大于其相对应均值的值赋值为 0。

对于预处理后的大小为 $L\times L$ 的图像，根据非线性映射函数 f 和大小为 $w\times w(w<L)$ 的子块，得到该子块的非线性表示 $y\in\mathbb{R}^K$。则当步长 $s=1$ 时，对于整幅图像可以得到 $(L-w+1)\times(L-w+1)\times K$ 的特征矩阵。然后将特征矩阵按 4 个象限分别池化并级联池化的结果，得到 $4K\times 1$ 维的特征向量。最后运用 PCA 算法进一步降低特征的维度。特征提取过程如图 4 所示。

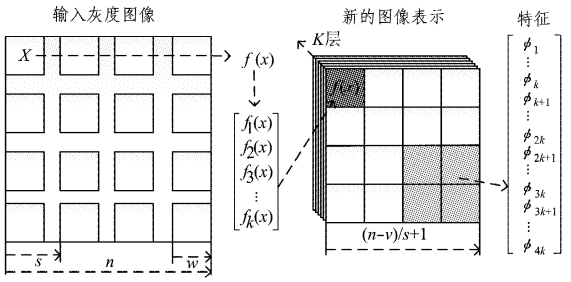

图 4 特征提取过程

4 实验

实验采用 64 位 window7 系统，3.30GHz 的 Intel(R)Core(TM)i3 四核处理器，系统内存为 8GB，matlab 为 2014a 版本。

4.1 植物叶片数据库

ICL 数据库是由中国科学院智能计算实验室创建，其包含 220 种 17000 张植物叶片图像。数据库中的植物叶片图像采集自不同时间、不同地点、不同角度的场景下，叶片图像包含受不同光照、视角、变形等因素影响的叶片，此外，还包括部分病叶和残叶。丰富的植物叶片图像资源使得本文实验研究的植物对象具有真实性、普遍性。本文实验中选择 85 种植物叶片图像组成新的植物叶片图像库，并保证每类图像数目不少于 260 张。植物数据库部分样本示例图如图 5 和图 6 所示。由于图像大小不一，通过预处理将图像灰度化并缩放到 80×80。

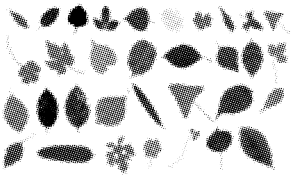

图 5 植物数据库部分样本示例图

图 6 植物数据库中一类的部分样本示例图

4.2 模型结构的变化对本算法分类准确率的影响

由于不同的网络结构对算法的识别率影响很大。为了进一步确定何种网络结构下算法的识别率最高，进行了两组实验。第一组：先确定第二层结构的节点数为 40，研究第一层节点数的变化对识别率的影响，训练集和测试集的样本数都设为 30，实验结果如图 7 所示。第二组：根据第一组的实验结果设置第一层节点数为 400，研究第二层节点数的变化对识别率的影响，训练集和测试集的样本数都设为 60，实验结果如图 8 所示。

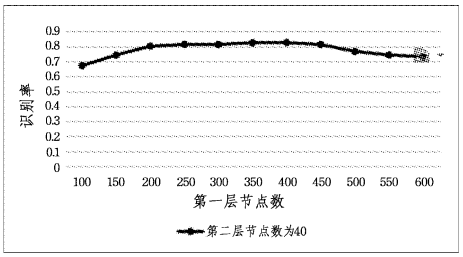

图 7 第一层节点数的变化对识别率的影响

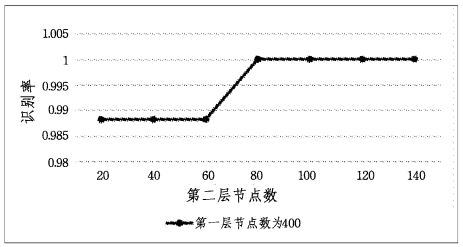

图 8 第二层节点数的变化对识别率的影响

从图 7、图 8 可以得到：当确定第二层节点数时，识别率随第一层节点数的增加先增加后减小，并在区间[350，450]达到最大；当确定第一层节点数时，识别率随第二层节点数的增加而增加，并在 80 之后达到最大。

4.3 样本数目的变化对本算法分类准确率的影响

在基于图像集的植物叶片图像分类研究中，假定图像数量是“充足”的，但是仍然需要考虑训练集、测试集中样本数目对基于非线性重构模型的植物叶片图像集的分类方法识别率的影响。通过改变训练集、测试集中每个集合的样本数目，模拟分析样本点的稀疏情况对算法识别率的影响。

实验中设定图像集的样本数目从 50 增加到 130，每次增加 10 个样本。每种数目下进行 10 次实验求平均值，实验结果如图 9 所示。

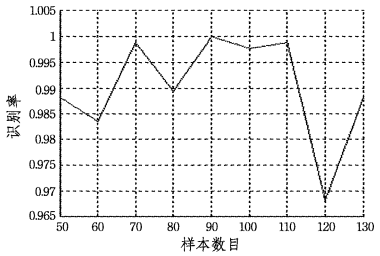

图 9　样本数目的变化对本算法分类准确率的影响

从图 9 可以看出，对于不同的样本个数，所提方法能够达到较高的识别率并具有很好的稳定性。

4.4　不同的特征对本算法分类准确率的影响

使用不同的特征提取方法提取图像不同的特征信息，这里采用另外 3 种纹理特征（GIST 特征、PHOG 特征、LBP 特征）作对比。实验中，样本的数目从 50 增加到 130，每次增加 10 个样本，其他 3 种特征的参数取值参照文献[15]，每种数目下进行 10 次实验求平均值。实验结果如图 10 所示。

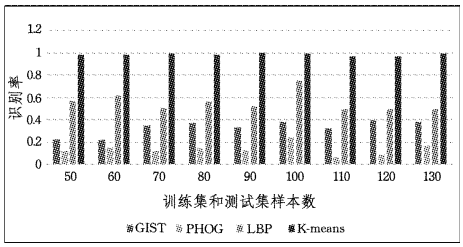

图 10　不同特征和样本大小对本算法识别率的影响

实验证明，基于 k-means 的特征明显优于其他 3 种方法提取的特征，并且随着训练样本和测试样本数目的增加先增加后减小，但识别率变化不大，并在训练样本和测试样本数目为 90 时取得最大值。

4.5　k-means 特征取不同的 K 值时对本算法分类准确率的影响

由于取不同的 K 值，k-means 提取的图像特征是不一样的，本节研究不同的 K 值提取的特征对算法识别率的影响。本文选取的 K 值范围为[100，1000]，间隔为 100。实验中，训练样本和测试样本的个数都是 90，网络的结构为[400 100 400]，每种 K 值下进行 10 次实验求平均值。实验结果如图 11 所示。

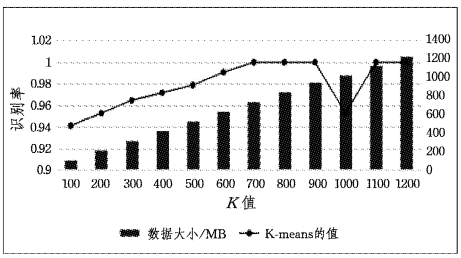

图 11　不同 K 值对本算法识别率的影响

实验证明，算法的识别率随着 K 值的增加先增加后降低而后又增加到最大值，在[700，900]之间取得最大值，并且随着 K 值的增加，数据的大小也近乎呈等差数列增加，每次实验所需的时间也随之增加。综合 K 值对识别率的影响、数据的存储量和实验所用时间因素，这里 K 值取 800。

4.6　添加不同比例的噪声对本算法分类识别率的影响

现实中图像集是包含噪声的。算法能否在不同的噪声比例下依然保持较高的识别率是判断算法鲁棒性的重要依据。因此，我们分别向训练集和测试集中加入不同比例的噪声来研究算法的鲁棒性，噪声是从所有样本中随机选取组成的噪声集。实验中，训练样本和测试样本的个数都是 90，网络的结构为[400 100 400]。添加噪声的比例及实验的结果如图 12 所示。

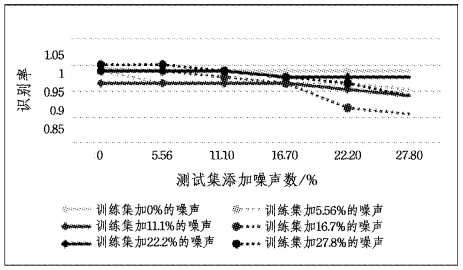

图 12　不同比例的噪声对本算法识别率的影响

从图 12 可以得出，对训练集和测试集加入不同比例的噪声，算法的性能随加入噪声比例的增加而略有下降，总体还是保持较高的识别率，对噪声具有较强的鲁棒性。

4.7　对比实验

本节将所提方法与多种基于图像集的识别方法做对比，这些方法包括互子空间方法（MSM）[14]、基于仿射包的图像集距离方法（AHISD）、基于凸包的图像集距离方法（CHISD）[6]、基于协方差判别分析方法（CDL）[12]。根据以上实验结果，所提方法（OUR）的网络结构设为[400 100 400]，K 值取 800。各实验的训练集和测试集中每类叶片都无重复随机选择 90 个样本，结果采用多次实验求平均值以保证算法的有效性。实验结果如表 1 所列。

表 1　对比实验结果

方法	识别率/%	运行总时间/s
MSM	88.8	1913
AHISD	96	1297
CHISD	89.8	1496
CDL	94.5	1252
OUR	100	740

从表 1 可以看出，在相同的情况下 OUR 的识别率高达 100%，而且 OUR 运行的总时间是最短的，几乎是其他方法运行时间的一半，且每类的训练时间平均为 8.16s，测试时间平均为 0.15s，能够很好地满足实时的要求。

结束语　文中提出了一种基于非线性重构模型的植物叶片图像集的分类识别方法。该方法为每类训练一个特定的模型，然后根据测试样本的最小重构误差和测试样本集的最多投票策略来判定测试样本集的类别。实验结果表明，所提方法有很高的准确度，对不同的样本数目及添加不同比例的噪声具有很好地稳定性，且该方法具有很好的实时性。基于 k-means 的特征提取方法能够很好地提取植物叶片图像的特征。今后将进一步研究该方法在其他方面的应用及网络结构对其识别率的影响。

参 考 文 献

[1] KNAPP A K，FAY P A，BLAIR J M，et al. Rainfall variability，carbon cycling，and plant species diversity in a mesic grassland [J]. Science，2003，298(5601)：2202-2205.

[2] POUNDS J A，PUSCHENDORF R. Ecology：clouded futures

[J]. Nature,2004,427(6970):107-109.
[3] 杜吉祥,汪增福. 基于径向基概率神经网络的植物叶片自动识别方法[J]. 模式识别与人工智能,2008,21(2):206-213.
[4] LEE K,HONG K. An implementation of leaf recognition system using leaf vein and shape[J]. International Journal of Bio-Science and Bio-Technology,2013,214(2):109-116.
[5] 翟传敏,汪青萍,杜吉祥. 基于叶缘与叶脉分数维特征的植物叶识别方法研究[J]. 计算机科学,2014,5(2):170-173.
[6] CEVIKALP H,TRIGGS B. Face recognition based on image sets[C]// IEEE Conference on Computer Vision& Pattern Recognition. IEEE,2010:2567-2573.
[7] Kim T K,Kittler J,CIPOLLA R. Discriminative Learning and Recognition of Image Set Classes Using Canonical Correlations [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence,2007,29(6):1005-1018.
[8] WANG R,SHAN S,CHEN X,et al. Manifold-Manifold Distance with application to face recognition based on image set[C]// IEEE Conference on Computer Vision & Pattern Recognition. 2008:1-8.
[9] WANG R,CHEN X. Manifold Discriminant Analysis[C]// IEEE Conference on Computer Vision & Pattern Recognition. 2009:429-436.
[10] HARANDI M T,SANDERSON C,SHIRA ZI S,et al. Graph embedding discriminant analysis on Grassmannian manifolds for improved image set matching[C]// IEEE Conference on Computer Vision & Pattern Recognition. 2011:2705-2712.
[11] HU Y,MIAN A S,OWENS R. Face Recognition Using Sparse Approximated Nearest Points between Image Sets[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence,2012,34(10):1992-2004.
[12] DAVIS L S. Covariance discriminative learning:A natural and efficient approach to image set classification[C]// IEEE Conference on Computer Vision & Pattern Recognition. 2012:2496-2503.
[13] YANG M,ZHU P,GOOL L V,et al. Face recognition based on regularized nearest points between image sets[C]// IEEE International Conference and Workshops on Automatic Face and Gesture Recognition. 2013:1-7.
[14] YAMAGUCHI O,FUKUI K,MAEDA K. Face Recognition Using Temporal Image Sequence[C]// Third IEEE International Conference on Automatic Face and Gesture Recognition. IEEE,1998:318-323.
[15] ZHANG Y H,DU J X,WANG J,et al. Reverse Training for Leaf Image Set Classification[M]// Advanced Intelligent Computing Theories and Applications. Springer International Publishing,2015:233-242.

(上接第 206 页)

(2)通常,分类算法的性能由重建误差表征,重建误差定义为$\frac{1}{N}\sum_{i=1}^{N}\|A_i-\widetilde{A}_1\|$,在 PCA 中 $\widetilde{A}_1=WY$,在 2DPCA 中 $\widetilde{A}_1=WY^{\mathrm{T}}$。图 11 给出了两种方法的重建误差。随着主元数逐渐达到最大,两种方法的重建误差趋于相等,这与图 10 中的重建图像质量的趋势也是一致的。

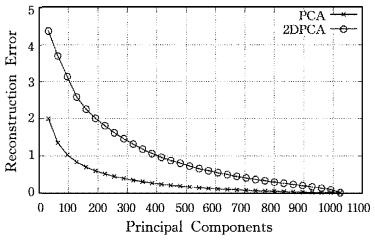

图 11 PCA 与 2DPCA 的重建误差

结束语 本文通过对 PCA 与 2DPCA 进行详细的理论分析,证明了 PCA 与 2DPCA 在准则 $J(W)$ 下具有相同的最优目标值。通过在 CMU-PIE 和 CK+库上进行了光照、姿态和表情变化的实验,并对实验结果进行了理论分析,最终证明了 PCA 与 2DPCA 在优化时具有相同的最优目标值,即两种方法选取的主元数趋于最大时,PCA 的错误率与 2DPCA 趋于一致。这有助于理解 PCA 和 2DPCA 之间的关系。

参 考 文 献

[1] PEARSON K. On Lines and Planes of Closest Fit to Systems of Points in Space [J]. Philosophical Magazine,1901,2(6):559-572.
[2] KIRBY M,SIROVICH L. Application of the KL Procedure for the Characterization of Human Faces [J]. IEEE Trans. Pattern Analysis and Machine Intelligence,1990,12(1):103-108.
[3] TURK M,PENTLAND A. Eigenfaces for Recognition[J]. Journal of Cognitive Neuroscience,1991,3(1):71-86.
[4] TURK M,PENTLAND A. Face recognition using eigenfaces [C]// Proc. IEEE Conf. on Computer Vision and Pattern Recognition. 1991:586-591.
[5] 甘玲,邹宽中,刘肖. 基于 PCA 降维的多特征级联的行人检测[J]. 计算机科学,2016,43(6):308-311.
[6] YANG J,ZHANG D,FRANGI A F,et al. Two-Dimensional PCA:A New Approach to Appearance-Based Face Representation and Recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2004,26(1):131-137.
[7] 张焕龙,郑卫东,舒云星,等. 基于区域协方差矩阵和 2DPCA 学习的视频跟踪方法研究[J]. 计算机科学,2015,42(9):278-281.
[8] WANG L,WANG X,ZHANG X,et al. The equivalence of two-dimensional PCA to line-based PCA[J]. Pattern Recognition Letter,2005,26(1):57-60.
[9] GAO Q,ZHANG L,ZHANG D,et al. Comments on On Image Matrix Based Feature Extraction Algorithms [J]. IEEE Trans. on Syst. Man & Cybern. B Cybern. ,2007,37(5):194-197.
[10] 张贤达. 矩阵分析与应用[M]. 清华大学出版社,2004:54-57.
[11] SIM T,BAKER S,BSAT M. The cmu pose,illumination,and expression (pie) database[C]// Proceedings of the IEEE International Conference on Automatic Face and Gesture Recognition. 2002.
[12] KANADE T,COHN J F,TIAN Y L. Comprehensive database for facial expression analysis[C]// Proceedings of the Fourth IEEE International Conference on Automatic Face and Gesture Recognition. 2000:46-53.
[13] LUCEY P,CHON J F,KANADE T,et al. The extended cohn-kanade dataset (ck+):A complete expression dataset for action unit and emotion-specified expression[C]// Proceedings of the Third International Workshop on CVPR for Human Communicative Behavior Analysis. 2010:94-101.