

增量式鉴别非负矩阵分解算法及其 在人脸识别中的应用

蔡 竞^{1,2,3}, 王万良¹, 郑建炜¹, 李吉明³

(1. 浙江工业大学计算机科学与技术学院, 浙江 杭州 310023;

2. 浙江警察学院刑事科学技术系, 浙江 杭州 310053;

3. 基于大数据架构的公安信息化应用公安部重点实验室, 浙江 杭州 310053)

摘 要: 针对在线学习的人脸识别效率问题, 提出了一种增量式鉴别非负矩阵分解算法。在以往无监督学习模式下的增量式非负矩阵分解算法基础上, 利用初始训练样本数据和新增训练样本的类别信息, 将同类训练样本对应的系数向量均值作为初始迭代值, 并在类内欧氏距离最小的约束下建立目标泛函, 从而获得更具鉴别性的特征并使优化求解时所需迭代次数明显减少。通过在 ORL 和 PIE 人脸数据库上的实验验证了该算法收敛速度快、分类精度高, 且较批量式算法有更高的效率优势。

关 键 词: 人脸识别; 有监督学习; 非负矩阵分解; 增量学习

中图分类号: TP 391.4

DOI: 10.11996/JGj.2095-302X.2017050715

文献标识码: A

文 章 编 号: 2095-302X(2017)05-0715-07

Incremental Discriminant Non-Negative Matrix Factorization and Its Application to Face Recognition

CAI Jing^{1,2,3}, WANG Wanliang¹, ZHENG Jianwei¹, LI Jiming³

(1. College of Computer Science and Technology, Zhejiang University of Technology, Hangzhou Zhejiang 310023, China;

2. Department of Forensic Science, Zhejiang Police College, Hangzhou Zhejiang, 310053 China;

3. Key Laboratory of Police Information Application Based on Big Data Architecture Ministry of Public Security, Hangzhou Zhejiang 310053, China)

Abstract: Aiming at the efficiency and efficacy of online feature learning for face recognition, a novel incremental discriminant learning algorithm of non-negative matrix factorization is proposed. Compared with former unsupervised online matrix factorization methods, our approach takes good advantage of the label information of training samples. Coefficient vector means of the same class were used for initialization, then the algorithm iterates with constraints on minimizing Euclidean distance of in-class samples. Which results more discriminative features and less iterations in computation. Experiments on ORL and PIE face datasets demonstrated that the proposed algorithm achieved better classification accuracy and converged faster than former batch based non-negative matrix factorization algorithms.

Keywords: face recognition; supervised learning; non-negative matrix factorization; incremental learning

高维度的原始数据在计算机视觉、信号处理以及模式识别等领域中是极为常见的现象。以人

脸识别为例, 每一幅人脸图像的维度等同于该图像的像素点数量, 因此高维度、小样本是人脸识

收稿日期: 2016-11-30; 定稿日期: 2016-12-24

基金项目: 国家自然科学基金项目(61379123); 浙江省自然科学基金项目(LY12F02018); 浙江省教育厅科研资助项目(Y201431023)

第一作者: 蔡 竞(1985-), 男, 浙江杭州人, 讲师, 博士。主要研究方向为图像处理、计算机视觉。E-mail: caijing@zjtcxy.cn

通信作者: 王万良(1957-), 男, 江苏高邮人, 教授, 博士, 博士生导师。主要研究方向为计算机智能自动化。E-mail: ww1@zjut.edu.cn

别的一个显著特点。然而过高的维度不仅增加了空间存储需求,也提高了计算复杂度,并且会导致维度灾难 (curse of dimensionality)^[1]等问题,严重影响后续的分类识别效果。针对以上情况,最为常用的方法是对原始人脸图像数据采用降维算法以减少样本的特征数量,如主成分分析(principal component analysis, PCA)^[2]、独立成分分析(independent component analysis, ICA)^[3]、线性 Fisher 判别(linear Fisher discriminant, LFD)^[4]等算法都是在人脸识别领域广泛应用的线性降维技术。1999 年,LEE 和 SEUNG^[5-6]在《Nature》上提出了一种新的降维算法——非负矩阵分解(non-negative matrix factorization, NMF)。区别于之前几种传统的降维算法,NMF 通过优化求解时的乘性迭代避免了分解量中负值的出现,使分解得到的结果可解释性强,符合人们对人脸图像“整体是由部分构成”的理解认识。之后,国内外学者针对 NMF 算法进行了各个方面的改进和研究^[7-9],如 LIU 等^[10]将含部分样本类别信息的强约束施加于 NMF 上,提出了一种强约束的非负矩阵分解(constrained non-negative matrix factorization, CNMF)算法,实现了 NMF 的半监督学习。GUAN 等^[11]将 Fisher 判别分析与投影非负矩阵分解(discriminant projective non-negative matrix factorization, DPNMF)相结合,提出了一种鉴别 DPNMF 算法,有效提高了人脸识别的分类精度。杜海顺和张旭东^[12]通过将图嵌入正则项引入 DPNMF,提出了一种图嵌入正则化投影非负矩阵分解(graph embedding regularized projective non-negative matrix factorization, GEPNMF)算法,使降维后得到的子空间不仅保持了数据空间流形几何结构,同时实现了样本类间距离最大化。舒振球和赵春霞^[13]利用了训练样本的局部结构信息与少量样本的类别信息,提出了基于局部学习的受限非负矩阵分解(constrained non-negative matrix factorization based on local learning, CNMFLL)算法,较传统的 NMF 具备更强的鉴别能力。

然而上述算法都存在一个同样的问题,即均是以批处理学习为假设前提,当新训练样本加入后需要放弃之前的所有训练结果,对分解因子矩阵进行重新运算,以致消耗大量的时间、空间。为此,BUCAK 和 GUNSEL^[14]在 NMF 的基础上提出了增量式非负矩阵分解(incremental non-negative matrix factorization, INMF)算法,利

用单个新增训练样本对基矩阵整体表达影响较小的特性,将上一步分解得到的基矩阵继续参与后续运算,有效避免了新训练样本加入后对基矩阵的重新运算。在此算法基础上,ZHENG 等^[15]提出了增量式局部保留非负矩阵分解(incremental locality preserving non-negative matrix factorization, ILPNMF)算法,将增量学习的思想运用在了局部保留 NMF 上,使 NMF 在增量学习的同时提高局部保留能力。王万良和蔡竞^[16]提出了基于稀疏约束的增量式非负矩阵分解(incremental non-negative matrix factorization with sparseness constraints, INMFSC)算法,通过对 INMF 算法施加稀疏约束,有效提高分解后数据的稀疏性,进一步减少了迭代所需的运算时间。

虽然以上方法均有效改善了人脸识别的在线学习的效率等问题,但由于没有利用初始训练样本和新增训练样本的类别信息导致鉴别力不足,在人脸识别的分类精度上有所欠缺。因此,本文提出了一种增量式鉴别非负矩阵分解(incremental discriminant non-negative matrix factorization, IDNMF)算法,在初始训练样本数据规模庞大的情况下,不仅避免了新训练样本加入时的大规模重复运算,同时有效利用了初始训练样本和新增训练样本的类别信息,使之在较低迭代次数下可获得较高的数据分类精度。

1 增量式非负矩阵分解

NMF 算法和传统的机器学习算法类似,每当有新的训练样本加入时需要放弃之前的学习成果,将新增训练样本及之前的所有样本整合并进行重新学习训练,以满足在线处理的要求。这样不仅会消耗大量的运算时间及存储空间,随着训练样本的不断增多,其对时间、空间的需求也不断提高,最终导致学习速度无法赶上样本增加的速度。因此,文献[14]在 NMF 的基础上提出了 INMF 算法,大大降低了新增训练样本时的计算复杂度,其算法思想如下:

假设初始训练样本集合由 k 个 n 维非负列向量组成,用矩阵 V 表示,即 $V = [v_1, v_2, \dots, v_k]$ ($V \in R^{n \times k}$)。NMF 是将非负矩阵 V 近似的分解成 2 个非负矩阵 W_k 和 H_k 的乘积,即 $V \approx W_k H_k$, 其中 W_k 为 $n \times r$ 维,称为基矩阵; H_k 为 $r \times k$ 维,称为系数矩阵。当 r 值满足 $r \ll nk/(n+k)$ 时,矩阵 V 就

得到了有效压缩。求解 $\mathbf{W}_k$ 和 $\mathbf{H}_k$ 则通过求解基于欧氏距离的约束目标函数实现, 即

$$F_k = \frac{1}{2} \|\mathbf{V} - \mathbf{W}_k \mathbf{H}_k\|^2 = \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^k \left(V_{ij} - (\mathbf{W}_k \mathbf{H}_k)_{ij} \right)^2 \quad (\mathbf{W}_k \geq 0, \mathbf{H}_k \geq 0) \quad (1)$$

当初始训练样本数 k 足够大时, 单个新训练样本的加入对于基矩阵 $\mathbf{W}_k$ 的影响很小, 且随着训练样本数量的不断增加, 这种影响会持续减小。因此其对应的系数矩阵 $\mathbf{H}_k$ 也同样受影响较小。于是当第 $k+1$ 个训练样本加入后, 目标函数 F_{k+1} 可作如下近似

$$\begin{aligned} F_{k+1} &= \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^{k+1} \left(V_{ij} - (\mathbf{W}_{k+1} \mathbf{H}_{k+1})_{ij} \right)^2 \\ &= \frac{1}{2} \sum_{i=1}^n \left(\sum_{j=1}^k \left(V_{ij} - (\mathbf{W}_{k+1} \mathbf{H}_k)_{ij} \right)^2 + \left((v_{k+1})_i - (\mathbf{W}_{k+1} \mathbf{h}_{k+1})_i \right)^2 \right) \\ &\cong F_k + \frac{1}{2} \sum_{i=1}^n \left((v_{k+1})_i - (\mathbf{W}_{k+1} \mathbf{h}_{k+1})_i \right)^2 \\ &\cong F_k + f_{k+1} \end{aligned} \quad (2)$$

最后采用文献[6]提出的乘性迭代法对基矩阵 $\mathbf{W}_{k+1}$ 和系数矩阵的增量部分 $\mathbf{h}_{k+1}$ 进行交替迭代求解, 其更新规则为

$$(\mathbf{h}_{k+1})_a \leftarrow (\mathbf{h}_{k+1})_a \frac{(\mathbf{W}_{k+1}^T \mathbf{v}_{k+1})_a}{(\mathbf{W}_{k+1}^T \mathbf{W}_{k+1} \mathbf{h}_{k+1})_a} \quad (3)$$

$$(\mathbf{W}_{k+1})_{ia} \leftarrow (\mathbf{W}_{k+1})_{ia} \frac{(\mathbf{V}_k \mathbf{H}_k^T + \mathbf{v}_{k+1} \mathbf{h}_{k+1}^T)_{ia}}{(\mathbf{W}_{k+1} \mathbf{H}_k \mathbf{H}_k^T + \mathbf{W}_{k+1} \mathbf{h}_{k+1} \mathbf{h}_{k+1}^T)_{ia}} \quad (4)$$

2 增量式鉴别非负矩阵分解算法

与传统非负矩阵分解算法类似, INMF 算法属于无监督学习, 并未考虑训练样本的类别信息, 因此在人脸识别分类问题上缺乏较好的鉴别性。

本文提出的 IDNMF 算法通过对 INMF 算法的目标函数添加类别信息约束, 能够有效提高测试样本在求解目标函数时低迭代次数下的分类精度, 降低较高精度下训练时间需求, 其算法描述如下:

假设初始的 k 个训练样本及其分别对应的类别信息用矩阵 $\mathbf{V}$ 表示, 则有

$$\mathbf{V} = \{v_1^1, v_2^1, \dots, v_{K_1}^1, v_1^2, v_2^2, \dots, v_{K_2}^2, \dots, v_1^C, v_2^C, \dots, v_{K_C}^C\} \quad (5)$$

其中, C 为样本中类别总数; K_c 为属于第 c 类数据的样本个数; v_i^c 为属于第 c 类数据中第 i 个样本向量。

同样, 矩阵 $\mathbf{V}$ 经非负分解后, 得到的包含类别信息的系数矩阵 $\mathbf{H}$, 即

$$\mathbf{H} = \{h_1^1, h_2^1, \dots, h_{K_1}^1, h_1^2, h_2^2, \dots, h_{K_2}^2, \dots, h_1^C, h_2^C, \dots, h_{K_C}^C\} \quad (6)$$

由于属于同一类别的两个样本应具有较小的类内方差, 因此其通过 NMF 后得到的对应系数向量之间的类内方差也应较小。即样本 v_i^c 和 v_j^c 分解后对应的系数向量 $\mathbf{h}_i^c$ 和 $\mathbf{h}_j^c$ 具有较小的欧式空间距离。基于此思想可知, 新增训练样本的系数向量 $\mathbf{h}_{k+1}^c$ 应和已知隶属第 c 类的所有训练样本均值向量具有较小的类内距离。于是可对原 INMF 的目标函数作如下约束

$$F_{k+1} = F_k + f_{k+1} + \frac{\lambda}{2} \left\| \mathbf{h}_{k+1}^c - \overline{\mathbf{h}}_k^c \right\|_F^2 \quad (7)$$

其中, $\overline{\mathbf{h}}_k^c = \frac{1}{K_c} \sum_{j=1}^{K_c} \mathbf{h}_j^c$, $\overline{\mathbf{h}}_k^c$ 为第 c 类训练样本系数矩阵的均值向量。根据梯度下降法可得到 $\mathbf{h}_{k+1}^c$ 的更新规则为

$$(\mathbf{h}_{k+1}^c)_a \leftarrow (\mathbf{h}_{k+1}^c)_a - \eta_a \frac{\partial f_{k+1}}{\partial (\mathbf{h}_{k+1}^c)_a} \quad (8)$$

其中, $a = 1, \dots, r$ 。

式(8)中求导部分计算方法如下

$$\begin{aligned} \frac{\partial F_{k+1}}{\partial (\mathbf{h}_{k+1}^c)_a} &\cong \frac{\partial}{\partial (\mathbf{h}_{k+1}^c)_a} \left(F_k + f_{k+1} + \frac{\lambda}{2} \left\| \mathbf{h}_{k+1}^c - \overline{\mathbf{h}}_k^c \right\|_F^2 \right) = \frac{\partial}{\partial (\mathbf{h}_{k+1}^c)_a} \left(f_{k+1} + \frac{\lambda}{2} \left\| \mathbf{h}_{k+1}^c - \overline{\mathbf{h}}_k^c \right\|_F^2 \right) \\ &= \frac{\partial}{\partial (\mathbf{h}_{k+1}^c)_a} \left[\frac{1}{2} \sum_{i=1}^n \left(\left((v_{k+1}^c)_i - (\mathbf{W}_{k+1} \mathbf{h}_{k+1}^c)_i \right)^2 + \lambda \left((\mathbf{h}_{k+1}^c)_i - \frac{1}{K_c} \sum_{j=1}^{K_c} (\mathbf{h}_j^c)_i \right)^2 \right) \right] \\ &= \frac{\partial}{\partial (\mathbf{h}_{k+1}^c)_a} \left[\frac{1}{2} \sum_{i=1}^n \left(\left((v_{k+1}^c)_i - \sum_{k=1}^r (\mathbf{W}_{k+1})_{ik} (\mathbf{h}_{k+1}^c)_i \right)^2 + \lambda \left((\mathbf{h}_{k+1}^c)_i - \frac{1}{K_c} \sum_{j=1}^{K_c} (\mathbf{h}_j^c)_i \right)^2 \right) \right] \\ &= \sum_{i=1}^n \left(\left((v_{k+1}^c)_i - (\mathbf{W}_{k+1} \mathbf{h}_{k+1}^c)_i \right) (-\mathbf{W}_{k+1})_{ia} \right) + \lambda \left((\mathbf{h}_{k+1}^c)_a - \frac{1}{K_c} \sum_{j=1}^{K_c} (\mathbf{h}_j^c)_i \right) \\ &= -(\mathbf{W}_{k+1}^T \mathbf{v}_{k+1}^c)_a - \frac{\lambda}{K_c} \sum_{i=1}^n \sum_{j=1}^{K_c} (\mathbf{h}_j^c)_i + (\mathbf{W}_{k+1}^T \mathbf{W}_{k+1} \mathbf{h}_{k+1}^c)_a + \lambda (\mathbf{h}_{k+1}^c)_a \end{aligned} \quad (9)$$

为保证迭代更新过程中数据的非负性, 同样采用乘性迭代规则得到梯度下降的步长为

$$\eta_a = \frac{(h_{k+1}^c)_a}{(W_{k+1}^T W_{k+1} h_{k+1}^c)_a + \lambda (h_{k+1}^c)_a} \quad (10)$$

于是得到 h_{k+1}^c 最终更新规则为

$$(h_{k+1}^c)_a \leftarrow (h_{k+1}^c)_a \frac{(W_{k+1}^T v_{k+1}^c)_a + \frac{\lambda}{K_c} \sum_{i=1}^n \sum_{j=1}^{K_c} (h_j^c)_i}{(W_{k+1}^T W_{k+1} h_{k+1}^c)_a + \lambda (h_{k+1}^c)_a} \quad (11)$$

由于增加的约束项对 W_{k+1} 求导并没有影响, 因此基矩阵 W_{k+1} 的更新规则依然为

$$(W_{k+1})_{ia} \leftarrow (W_{k+1})_{ia} \frac{(V_k H_k^T + v_{k+1}^c (h_{k+1}^c)^T)_{ia}}{(W_{k+1} H_k H_k^T + W_{k+1} h_{k+1}^c (h_{k+1}^c)^T)_{ia}} \quad (12)$$

IDNMF 算法描述如下:

输入: 上一次增量计算得到的基矩阵 W_{k+1} 、系数矩阵 H_k 、系数 λ 、隶属 c 类的新增训练样本 v_{k+1}^c 及该类别训练样本对应的系数均值向量 $\bar{h}^c$ 。

输出: 更新后的基矩阵 W_{k+1} 和系数矩阵 H_{k+1} 。

步骤 1. 初始化系数向量 h_{k+1}^c 为 $\bar{h}^c$ 。

步骤 2. 新增一个隶属 c 类的训练样本 v_{k+1}^c 时, 按以下规则更新 W_{k+1} 和 h_{k+1}^c , 直至满足收敛条件

$$(h_{k+1}^c)_a \leftarrow (h_{k+1}^c)_a \frac{(W_{k+1}^T v_{k+1}^c)_a + \bar{h}_k^c}{(W_{k+1}^T W_{k+1} h_{k+1}^c)_a + \lambda (h_{k+1}^c)_a}$$

$$(W_{k+1})_{ia} \leftarrow (W_{k+1})_{ia} \frac{(V_k H_k^T + v_{k+1}^c (h_{k+1}^c)^T)_{ia}}{(W_{k+1} H_k H_k^T + W_{k+1} h_{k+1}^c (h_{k+1}^c)^T)_{ia}}$$

步骤 3. 更新系数矩阵 $H_{k+1} = [H_k, h_{k+1}^c]$ 。其中, $i=1, \dots, n$; $j=1, \dots, m$; $a=1, \dots, r$, λ 为非负常数。

3 实验结果及分析

3.1 数据描述及参数设置

实验分别在 ORL 和 PIE 两个国际通用标准人脸库上进行验证, 实验环境为 Matlab 7.11 软件在 Intel Core i3-370M 2.40 GHz, 3 G 内存 PC 机的 Windows 7 32 位系统上。

ORL 人脸数据库是由剑桥大学 AT&T 实验室

创建的, 该数据库包含 40 人每人 10 幅共 400 幅人脸图像, 同一人脸图像在姿态、表情以及面部饰物上均有一定程度的变化, 如图 1 所示。每幅图像的原始分辨率为 112×92 像素, 本实验通过预处理将图像统一裁剪压缩为 32×32 像素的分辨率。根据 ORL 人脸数据库规模特点, 选取其中每人前 4 幅图像作为初始训练样本, 中间 3 幅图像作为增量训练样本, 后 3 幅图像作为测试样本。子空间维数 r 取 50, 初始样本训练迭代次数为 100。为保证类别信息约束项具有和目标函数相适应的权重, 参数 λ 取值为 10^8 。



图 1 ORL 人脸数据库部分样本示例


PIE 人脸数据库由美国卡耐基梅隆大学创建, 该数据库包含 68 人的 41 368 幅人脸图像, 同一人脸图像在姿势、表情和光照等方面均有不同程度变化, 如图 2 所示。本实验选取了其中的 50 人共 5 000 幅姿态、表情、光照各异的人脸图像用于实验, 并通过预处理同样将图像裁剪压缩为 32×32 像素的分辨率。根据 PIE 人脸数据库规模特点, 选取其中每人前 6 幅图像作为初始训练样本, 中间 2 幅图像作为增量训练样本, 后 2 幅图像作为测试样本。子空间维数 r , 初始样本训练迭代次数以及参数的 λ 的取值均不变。




图 2 PIE 人脸数据库部分样本示例

3.2 算法收敛性比较

在 ORL 和 PIE 两个人脸数据库上比较 INMF 算法和 IDNMF 算法的收敛效果, 将目标函数的求解迭代次数均设为 50 次, 其目标函数值与迭代次数的变化曲线分别如图 3、4 所示。从 2 种算法目标函数的收敛曲线可知, 本文提出的 IDNMF 算法的收敛速度比 INMF 算法更快, 尤其在低迭代次数下, 收敛效果尤为明显。




(a) INMF 算法收敛函数




(b) IDNMF 算法收敛函数

图3 ORL 人脸库中2种算法收敛函数对比



(a) INMF 算法收敛函数



(b) IDNMF 算法收敛函数

图4 PIE 人脸库中2种算法收敛函数对比

3.3 算法识别率比较

算法将不同人脸数据库中的训练样本矩阵 V 经非负分解后获得基矩阵 W , 利用公式 $H_{test} = W^{-1}V_{test}$ 将测试样本矩阵 V_{test} 投影至其特征子空间上, 并用 K 近邻(K-Nearest Neighbor)分类器进行分类测试, K 值统一取 3, 其相似性度量以式(13)为标准, 即

$$d(H_{test}, H_i^c) = \|H_{test} - H_i^c\|_F^2 \quad (13)$$


在不同训练迭代次数下, NMF、INMF 和 IDNMF 3 种算法作用于 ORL 和 PIE 两个人脸数据库的识别精度分别如图 5、6 所示。

从图 5、6 可以看出, NMF 算法对于迭代次数的要求较高, 在 ORL 和 PIE 两组人脸数据上均需要约 50 次左右的迭代才能基本达到较好的识别效果。这是由于 NMF 因子矩阵的初始化采用随机赋值的方式, 每当新训练样本加入后都需放弃之前的迭代运算结果, 对基矩阵和系数矩阵进行初始化并开始重新迭代。而 INMF 算法是在初始训练数据已充分迭代的基础上再进行运算, 因此所需的迭代次数大大减少。传统的 INMF 算法需要约 5 次左右的迭代, 而本文提出的 IDNMF 算法仅需要 1 次迭代即可获得较为理想的识别效果, 且随着迭代次数的增加始终可以保持高于 INMF 算法的识别率。并且在迭代次数为 1 次的情况下, INMF 算法的识别率随着新样本数量的增多不断下降, 而 IDNMF 算法的识别率则依然保持增长趋势。


此外, 相较于 NMF 算法的识别率随训练样本数量增加而波动幅度较大的现象, IDNMF 算法有效利用了之前的矩阵分解结果, 且在固定迭代次数下具备更快的收敛速度, 因而更易得到较为稳定的最优解, 其识别率随训练样本的增加保持相对稳定且成增长趋势。考虑到迭代次数严重影响目标函数的优化求解时间, 因此在相同的时间代价下, IDNMF 算法在分类方面较其他两种算法有着较大的优势。

3.4 算法耗时比较


在 ORL 库初始训练样本数为 160 幅人脸图像的情况下, NMF、INMF 以及本文提出的 IDNMF 3 种算法执行一次所消耗的平均时间见表 1; 在 PIE 库初始训练样本为 3 000 幅人脸图像的情况下, 3 种算法的时间消耗情况见表 2。




(a) 迭代 1 次




(b) 迭代 5 次




(c) 迭代 15 次




(d) 迭代 50 次




(a) 迭代 1 次



(b) 迭代 5 次



(c) 迭代 15 次



(d) 迭代 50 次

图 5 ORL 人脸库中不同新增训练样本数量下的识别率变化

图 6 PIE 人脸库中不同新增训练样本数量下的识别率变化

表1 ORL库不同增量迭代次数下算法耗时比较(s)

增量迭代次数	NMF	INMF	IDNMF
1	0.116	0.004	0.004
5	0.158	0.014	0.015
15	0.269	0.046	0.045
50	0.679	0.159	0.158

表2 PIE库不同增量迭代次数下算法耗时比较(s)

增量迭代次数	NMF	INMF	IDNMF
1	0.689	0.004	0.004
5	1.631	0.019	0.018
15	4.453	0.067	0.068
50	13.077	0.168	0.169

由表1、2可知,在不同增量迭代次数下, IDNMF算法的运算速度与INMF算法相似,而明显高于相同样本规模下NMF算法的运算速度,且该优势随着增量迭代次数的增加而更为显著。此外,当新增训练样本不断加入时, NMF算法的时间开销呈线性增长趋势,而IDNMF算法的时间开销则一直维持在一个较低水平,如图7所示(以ORL库为例)。由此可知,在初始训练数据规模较大,迭代次数较高的情况下, IDNMF算法相较于批量式学习算法具有极大的优势。




图7 ORL人脸库新增训练样本执行时间比较

4 结束语

为了进一步优化INMF算法,本文提出了一种IDNMF算法,利用初始样本数据及新增样本数据的类别信息建立目标泛函,以新增样本数据及其同类初始样本数据的类内欧氏距离最小为约束,并将同类训练样本对应的系数向量均值作为迭代初始值,不仅加快了算法的收敛速度,同时也实现了分类精度的提高,且在低迭代次数下效果尤为明显。通过在ORL和PIE两组人脸数据库上

的实验证明了该算法的有效性。

参考文献

- [1] POWELL W B. Approximate dynamic programming: solving the curses of dimensionality [M]. New York: John Wiley & Sons, 2007: 92-99.
- [2] TURK M, PENTLAND A. Eigen faces for recognition [J]. Journal of Cognitive Neuroscience, 1991, 3(1): 71-86.
- [3] BARTLETT M S, LADES H M, SEJNOWSKI T J. Independent component representations for face recognition [J]. Proceedings of the International Society for Optical Engineering, 1998, 2399(3): 528-539.
- [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] LEE D, SEUNG H S. Learning the parts of objects by non-negative matrix factorization [J]. Nature, 1999, 401(6755): 788-791.
- [6] LEE D, SEUNG H S. Algorithms for non-negative matrix factorization [C]//Proceedings of Advances in Neural Information Processing Systems. Cambridge: MIT Press, 2000: 556-562.
- [7] WANG Y X, ZHANG Y J. Nonnegative matrix factorization: a comprehensive review [J]. IEEE Transactions on Knowledge & Data Engineering, 2013, 25(6): 1336-1353.
- [8] CORSETTI M A, FOKOUÉ E. On the complexity of nonnegative matrix factorization [J]. Open Journal of Statistics, 2015, 5(7): 777-786.
- [9] ZHAO R B, TAN V Y F. Online nonnegative matrix factorization with outliers [J]. IEEE Transactions on Signal Processing, 2016, 65(3): 555-570.
- [10] LIU H, WU Z, CAI D, et al. Constrained nonnegative matrix factorization for image representation [J]. IEEE Transactions on Software Engineering, 2012, 34(7): 1299-1311.
- [11] GUAN N, ZHANG X, LUO Z, et al. Discriminant projective non-negative matrix factorization [J]. Plos One, 2013, 8(12): 1524-1528.
- [12] 杜海顺, 张旭东. 图嵌入正则化投影非负矩阵分解人脸图像特征提取[J]. 中国图象图形学报, 2014, 19(8): 1176-1184.
- [13] 舒振球, 赵春霞. 基于局部学习的受限非负矩阵分解算法[J]. 华中科技大学学报: 自然科学版, 2015(7): 82-86.
- [14] BUCAK S S, GUNSEL B. Incremental subspace learning via non-negative matrix factorization [C]//Pattern Recognition. New York: CAM Press, 2009: 788-797.
- [15] ZHENG J, CHEN Y, JIN Y, et al. Incremental locality preserving nonnegative matrix factorization [C]//International Conference on Advanced Computational Intelligence. New York: IEEE Press, 2013: 135-139.
- [16] 王万良, 蔡竞. 稀疏约束下非负矩阵分解的增量学习算法[J]. 计算机科学, 2014, 41(8): 241-244.