

基于 SNPE 和 SVM 的人脸识别

郭 锋¹,吕 凝¹,陈绵书²,刘丽丽¹

GUO Feng¹,LV Ning¹,CHEN Mian-shu²,LIU Li-li¹

1.长春工业大学 计算机科学与工程学院,长春 130012

2.吉林大学 通信工程学院,长春 130022

1.College of Computer Science and Engineering, Changchun University of Technology, Changchun 130012, China

2.College of Communications Engineering, Jilin University, Changchun 130012, China

E-mail:guofeng8219134@gmail.com

GUO Feng,LV Ning,CHEN Mian-shu,et al. Face recognition based on SNPE and SVM. *Computer Engineering and Applications*, 2008, 44(9):202–204.

Abstract: For face recognition, most of traditional methods which reduce the high dimensional data are linear. Support Vector Machine can enhance the generation ability of study, and can overcome the disadvantage of overfitting. The paper proposes a method for face recognition based Supervised Neighborhood Preserving(SNPE) and Support Vector Machine(SVM). The K of NPE is confirmed with supervised mode. SNPE aims at preserving the local manifold structure. Also, comparing to the recently proposed manifold learning algorithms such as Locally Linear Embedding, SNPE is defined everywhere, rather than only on the training data points, and it's more applied. With SVM framework for multiple sequences, experiment results on ORL database demonstrate the algorithm is fast, steady and effective.

Key words: face recognition; Supervised Neighborhood Preserving Embedding(SNPE); Support Vector Machine(SVM)

摘要:在人脸识别方面,传统的特征提取方法大都是线性方法,不能很好保持样本的拓扑结构。分类方面,支持向量机能够尽量提高学习的泛化能力,防止过学习,是一种很好的分类器。提出了一种基于 SNPE 和 SVM 的人脸识别方法。采用有监督模式确定 NPE 算法中的 K 值。SNPE 算法旨在保持数据的局部流型结构,而且相对于近期提出的 LLE 算法,它能够适用于训练样本和测试样本,具有更大的实用型。结合两分类支持向量机级联模型进行人脸识别,在 ORL 人脸数据库上实验表明,算法具有稳健性、快速性等优点,实验效果令人满意。

关键词:人脸识别;有监督近邻保持嵌入(SNPE);支持向量机(SVM)

文章编号:1002-8331(2008)09-0202-03 文献标识码:A 中图分类号:TN911.73

人脸识别在人机交互系统、公安(罪犯识别等),安全验证系统、视频会议等方面的巨大应用前景越来越成为当前模式识别和人工智能领域的一大研究热点。人脸的机器自动识别是一个难度极大的课题,它涉及到模式识别、图像处理及生理、心理学等方面诸多知识。与其他人体生物特征识别系统相比,人脸识别系统更加直接、友好。

人脸识别是一个模式识别问题,特征提取是模式识别中的分类系统均需要解决的一个重要环节,其主要目标是在于获得最优、最显著特征的同时丢弃无关或次要信息,降低数据的维数以减低分类系统的复杂性,这就涉及到所谓的流型学习问题。流型学习中经典的技术例如主成分分析法(PCA)来实现流型的线性或接近于线性嵌入;当有可用的类信息时,线性判别分析法(LDA)^[1]可以寻找一个最优的线性的子空间以用来分类。与此同时,近几年一些非线性算法被提出,这些算法主要发

现流型中的非线性结构,例如拉普拉斯特征匹配法、局部线性嵌入(LLE)^[2]和 Isomap^[3]。非线性的方法能够保持样本的拓扑结构,但是计算量大,而且这种方法只适用于训练样本,怎么使单个测试样本降维一直是个难点。基于核的算法也被提出,例如 KPCA、KLDA,这些算法产生非线性映射,但是却没有考虑到样本数据的流型结构,致使降维效果并不十分理想。

传统的人脸识别方法有最近邻法、欧氏距离法、马氏距离法和神经网络法等。相对于其维数而言,人脸样本很少,是一个小样本问题。对于人脸识别这种小样本问题,传统的分类方法一方面容易出现过学习(overfitting)现象,导致算法泛化能力差;另一方面,传统的分类方法学习性能差,无法胜任人脸分类这个非线性很强的分类模式。支持向量机(SVM)^[4]是为解决小样本问题学习和分类提出的,可以克服神经网络等方法所固有的过学习和欠学习问题,又有很强的非线性分类能力。

基金项目:吉林省科技发展计划重点项目(No.20060330)。

作者简介:郭锋(1982-),男,硕士研究生,研究方向:模式识别、分布式多媒体系统;吕凝(1959-),男,教授,硕士生导师,研究方向:分布式多媒体系统。

收稿日期:2007-07-12 修回日期:2007-10-10

本文提出了一种基于有监督近邻保持嵌入(Supervised Neighborhood Preserving Embedding, SNPE)和支持向量机(Support vector machine, SVM)结合人脸识别方法。NPE^[5]是一种线性的降维算法,不同于PCA旨在保持全局的欧氏结构,NPE旨在保持局部流型结构,如图1所示,NPE不会像PCA那样数据外围层那么敏感。在SVM分类方面,本文提出了一种两分类级联模型来实现多类模式分类。并在ORL人脸库上进行实验。

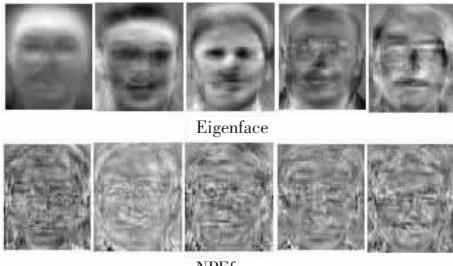


图1 Eigenfaces 和 NPEfaces

1 有监督近邻保持嵌入(SNPE)

1.1 NPE 算法

NPE的基本思想是:在周围空间中给定一组数据样本,首先构造一个权值矩阵用来描述各数据样本之间的关系。对于每一个数据样本点,用它近邻的数据样本的线性组合来表示,组合系数就构成了权值矩阵。然后寻找最优的嵌入使得这种近邻结构也能够保持在低维空间中。

给定一组样本点 $x_1, x_2, \dots, x_N, X \in R^D$, 寻找变换矩阵 A , 使得 N 个样本点映射到低维数据集 $y_1, y_2, \dots, y_N, Y \in R^d$ ($d \ll N$) 中, 使得 $y_i = A^T x_i$ 。算法的流程如下:

步骤1 构造 K 近邻(KNN):有两种方法找出 K 近邻。

K 最近邻法:直接找出相对于第 i 个样本点 x_i 的 K 近邻样本点 x_j 。

ε 近邻:通过公式 $\|x_j - x_i\| \leq \varepsilon$ 构造 K 近邻。

在实际应用中,很难去选择一个理想的 ε 值,所以在文中,采用 KNN 方法去构造 K 近邻。

步骤2 计算权值:令 W 代表权值矩阵,则 W_{ij} 为第 i 个样本到第 j 个样本的权值,当第 j 个样本不属于第 i 个样本的 K 近邻时, W_{ij} 为 0。通过最小化^[6]一下目标函数可以计算出权值。

$$\min \sum_i \|x_i - \sum_j W_{ij} x_j\|^2 \quad (1)$$

约束条件为

$$\sum_j W_{ij} = 1, j=1, 2, \dots, N \quad (2)$$

步骤3 计算映射:求解下列泛化特征向量问题:

$$X M X^T \alpha = \lambda X X^T \alpha \quad (2)$$

这里

$$X = (x_1, x_2, \dots, x_N)$$

$$M = (I - W)^T (I - W) \quad (3)$$

$$I = diag(1, \dots, 1)$$

很容易得出 M 对称和半正定阵。令列向量 $\alpha_0, \alpha_1, \dots, \alpha_{d-1}$

为式(2)对应于特征值排序后的解, $\lambda_0 \leq \lambda_1 \leq \dots \leq \lambda_{d-1}$, 则嵌入为:

$$x_i \rightarrow y_i = A^T x_i \quad (4)$$

$$A = (\alpha_0, \alpha_1, \dots, \alpha_{d-1})$$

y_i 是一个 d -维向量, A 为 $N \times d$ 的矩阵。

1.2 SNPE 算法

在 NPE 算法中, K 值的选择非常重要,也是一个难点。若 K 太小,降维时就不会体现任何的全局特性;若 K 太大,降维时就体现不出局部流型结构。故文中提出了有监督的 NPE 算法,即利用已知的类别信息及类内样本数来确定 K 值。这样就避免了 NPE 算法中的第一步,既能保证 K 值选择的准确性,做到最优的降维,又能很大程度上减少算法的运行时间。

参数 d 的值对降维效果影响也很大。如果 d 太低,数据可能会产生重叠;如果 d 太高,降维时就会增加不必要的噪声。由文献[6]算法知道,嵌入空间的理想的维数 d 应该比总类别数少 1。

2 支持向量机(SVM)及分类算法

2.1 支持向量机

支持向量机(Support Vector Machine, SVM)是最优线性分类和核函数方法混合应用的产物。通过核映射,支持向量机首先将输入样本空间非线性变换到另一个高维数的空间(特征空间),然后在这个新的空间中求取样本的最优线性分类面,而这种非线性变换是通过定义适当的内积函数(核函数)实现的。

特征空间最优线性分类面函数可用式(5)描述:

$$g(x) = \sum_{j=1}^n \alpha_j y_j K(x, x_i) + b \quad (5)$$

其中, (x_i, y_i) 是样本空间中的两类可分样本集, $i=1, 2, \dots, n$, $x_i = [x_i^1, x_i^2, \dots, x_i^d], x_i \in R^d, y_i \in \{+1, -1\}$ 是特征空间的类标记, b 是分类阈值, $K(x, x_i)$ 是通过满足 Mercer 条件而引入的代替特征空间内积的非线性核函数。

通过求取下列函数 $Q(\alpha)$ 的最优化解 α_i ($i=1, 2, \dots, n$) 来确定最优分类面函数。

$$\max_{\alpha} Q(\alpha) = \sum_{i=1}^n \alpha_i - 0.5 \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (6)$$

α 的取值满足式(7)

$$\begin{cases} \sum_{i=1}^n y_i \alpha_i = 0, & i=1, 2, \dots, n \\ 0 \leq \alpha_i \end{cases} \quad (7)$$

式(6)是不等式约束下的二次函数极值求解,由核函数 $K(x, x_i)$ 的正定性决定了 $Q(\alpha)$ 是凸函数,由于其局部最优解也是全局最优解,因此解是唯一的。最优化过程实际上就是使分类间隔最大的过程。

支持向量机的最优分类函数为

$$f(x) = \text{sgn}(g(x)) = \text{sgn} \left\{ \sum_{j=1}^n \alpha_j y_j K(x, x_i) + b \right\} = \text{sgn} \left\{ \sum_{i=1}^s \alpha_i^{svm} y_i^{svm} K(x, x_i^{svm}) + b \right\} \quad (8)$$

2.2 分类算法

在获得有效的特征后,设计一个好的分类器就成为解决问题

题的关键。SVM 是一种泛化能力很强的分类器,它在解决小样本问题方面表现出了许多特有的优势,已成为国际上模式识别领域的研究热点。

在实际应用中,由于噪声的存在,不可能完全没有训练误差,其中还会存在线性不可分的情况,因此需要在分类器中引入间隔优化因子,即惩罚系数 C 。这样才能在算法复杂度和错分样本的比例之间寻求折衷,以实现有效分类。

采用图 1 所示的两分类支持向量机级联模型来实现多分类模式分类。假设共有 K 类样本,前 $K-1$ 类的每一类分别与第 K 类构造一个 SVM 分类器,及总共需构造 $K-1$ 个两分类 SVM 分类器。这种分类算法的优点是所需的支持向量数较少,而且一旦加入一个新类时,只需在最前端添加一个经过训练的两分类支持向量机即可,而不必更改或者重新训练原有的支持向量机群组,因此有效减少了计算量。

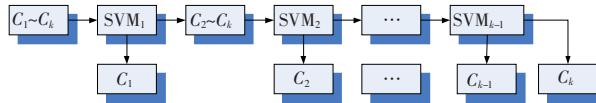


图 1 多分类支持向量机示意图

本文选择三种核函数进行计算,通过比较找出适合于本文算法的最优的核函数。由此得到四种支持向量机。4 种核函数的形式如下:

(1) 线性核函数: $K(x, x_i) = x \cdot x_i$, 此时得到的支持向量机是一个线性分类器。

(2) 多项式核函数: $K(x, x_i) = [(x \cdot x_i) + 1]^q$, 得到的支持向量机是一个 q 阶多项式分类器。

(3) 径向基核函数:

$$K(x, x_i) = \exp\left(-\frac{|x - x_i|^2}{\sigma^2}\right), \text{此时得到的支持向量机是一个径向基函数分类器。}$$

它与传统径向基函数(RBF)方法的基本区别是,这里每一个基函数的中心对应于一个支持向量,它们以及输出权值都是由算法自动确定。

3 实验系统及结果分析

实验采用的样本库为国际上常用的 ORL 人脸数据库(Olivetti Research Laboratory),库中人脸图像分别在不同的时间采集。该人脸库由 40 人,每人 10 幅 112×92 图像组成,图像的格式为 pgm,分别具有不同的表情(睁/闭眼、笑/不笑)、不同人脸细节(有/无眼镜)和不同姿态,如图 3 所示。



图 3 ORL 人脸库的图像样本

实验中,为了减少计算量,提高识别率,将人脸图像利用 bicubic 插值算法缩小为 32×32 像素,每个像素为 256 灰度级。于是,每幅人脸图像可用一个 1024 维向量来表示,根据不同视角、不同表情、不同人脸图像细节,每人选择 5 个模式作为训练集,另 5 个模式作为测试集,样本集和测试集分别包括 200 张人脸图像。实验时首先将高维数据利用 SNPE 算法降维到低维特征空间,然后利用 SVM 进行训练和识别,从而计算识别率。

3.1 实验系统设计

人像识别系统主要包括人脸定位模块、预处理模块、训练模块、识别模块。本文主要讨论训练模块和识别模块。设人脸样本集合为

$$\sum = \{f_1, f_2, \dots, f_N\}$$

每一幅人脸图像 f_i 经过预处理后可堆叠成 32×32 维向量。

(1) 训练模块

步骤 1 从 ORL 人脸库中读取每人 5 个模式,经过预处理(缩小为 32×32)后每一幅人脸图像堆叠成 32×32 维向量,组成训练样本集 $Xtrain_{1024 \times 200}$ 。

步骤 2 对 $Xtrain_{1024 \times 200}$ 进行 SNPE 变换,计算其变换矩阵 $A_{39 \times 1024}$ (因为总共有 40 个类别别人脸样本,故选取 $d=39$)。

步骤 3 由 $y_i = A^T x_i$ 对 $Xtrain_{1024 \times 200}$ 进行特征提取(降维),得到训练样本的特征参数 $Xtrain'_{39 \times 200}$ 。

步骤 4 基于 $Xtrain'_{39 \times 200}$ 构造两分类级联 SVM,实验中核函数的类型分别为 LINEAR, POLY, RBF 形式,取惩罚系数 $C=10$ 。

(2) 识别模块

步骤 1 从 ORL 人脸库中读取每人 5 个模式,经过预处理(缩小为 32×32)后每一幅人脸图像堆叠成 32×32 维向量,组成测试样本集 $Xtest_{1024 \times 200}$ 。

步骤 2 由 $y_i = A^T x_i$ 对 $Xtest'_{1024 \times 200}$ 进行特征提取(降维),得到测试样本的特征参数 $Xtest'_{39 \times 200}$ 。

步骤 3 将测试样本输入到训练好的 SVM 分类器中,进行识别。

3.2 实验结果及分析

分别采用 4 种不同核函数的 SVM 进行训练和识别,核函数的参数是经过大量实验确定的最优值。实验结果如表 1,2,3 所示。

表 1 基于 PCA 和 SVM 人脸识别的实验数据

SVM 类型	核函数参数	读取图像时间/s	PCA 时间/s	SVM 时间/s	识别率/%
LINEAR	无	8.781	0.297	17.453	80.5
RBF	$\sigma^2=0.85$	8.719	0.297	11.563	81.0
POLY	$q=2$	8.821	0.281	12.594	80.0

表 2 基于 LLE 和 SVM 人脸识别的实验数据

SVM 类型	核函数参数	读取图像时间/s	LLE 时间/s	SVM 时间/s	识别率/%
LINEAR	无	8.875	1.344	34.531	82.0
RBF	$\sigma^2=0.85$	8.922	1.344	13.469	82.0
POLY	$q=3$	8.922	1.344	12.438	78.5

表 3 基于 SNPE 和 SVM 人脸识别的实验数据

SVM 类型	核函数参数	读取图像时间/s	SNPE 时间/s	SVM 时间/s	识别率/%
LINEAR	无	8.875	0.547	6.047	79.0
RBF	$\sigma^2=0.85$	8.813	0.531	6.688	82.5
POLY	$q=2$	7.938	0.453	9.922	100.0