

文章编号: 1001-3806(2018)05-0666-07

加权联合降维的深度特征提取与分类识别算法

冯 玮, 王玉德*, 张 磊

(曲阜师范大学 物理工程学院, 曲阜 273165)

摘要: 为了降低卷积神经网络计算的复杂度,改善特征提取过程中的过拟合现象,解决经典网络模型不能有效处理大尺寸图片的问题,采用了加权联合降维的特征融合与分类识别算法,根据两特征的识别贡献率对主成分分析法(PCA)降维处理和随机投影(RP)处理结果进行加权融合,然后将结果提供给卷积神经网络进行处理,提取图像分类的高层特征,使用欧氏距离分类器对识别对象进行分类,并进行了理论分析和实验验证。结果表明,经过加权联合降维对数据进行预处理,PCA矩阵与RP降维矩阵之比重达到6:4,识别率高达96%以上。该算法有效提高了准确率,使大尺寸图片在深度学习网络中有良好的识别效果,改善了网络的适应性。

关键词: 图像处理; 分类识别; 加权特征融合; 识别贡献率; 卷积神经网络

中图分类号: TN911.73 文献标志码: A doi:10.7510/jgjs.issn.1001-3806.2018.05.016

Deep feature extraction and classification recognition algorithm based on weighting and dimension reduction

FENG Wei, WANG Yude, ZHANG Lei

(School of Physics and Engineering, Qufu Normal University, Qufu 273165, China)

Abstract: In order to reduce the computational complexity of convolution neural network, improve the over-fitting phenomenon in the process of feature extraction and solve the problem that the classic network model can not effectively deal with large size images, deep feature extraction and classification recognition algorithm based on weighting and dimension reduction was adopted. Based on recognition contribution rate of two features, the results of dimensionality reduction of principal component analysis (PCA) and random projection (RP) method were fused with weighted average, then the results were provided to convolution neural network and the high-level features of image classification were extracted. Euclidean distance classifier was used to classify the recognition objects. After theoretical analysis and experimental verification, the results show that the weight ratio of PCA matrix and RP reduction matrix is 6:4, and the recognition rate is over 96% after the preprocess of data by weighting and dimension reduction. This algorithm improves the accuracy effectively, makes large size pictures having good recognition effect in deep learning network and improves the adaptability of network.

Key words: image processing; classification recognition; weighted feature fusion; recognition contribution rate; convolutional neural network

引 言

深度学习是在浅层学习的基础上来挖掘数据更抽象的信息,自下而上地多层次学习,模拟人脑思维方式来建模,从而在本质上提高其学习特征的能力,区别于

过去的手动提取特征的方式^[1]。深度学习已有很多典型的成熟算法,如卷积神经网络(convolutional neural network, CNN)、深信度网络网络(deep belief networks, DBN)、递归网络(recurrent neural network, RNN)等,其中CNN网络因局部连接和权值共享这两大特点而被广泛应用。在图像识别方面也有很多成果,LLORCA等人使用最具有泛化能力的(histogram of oriented gradient, HOG)特征来识别人脸图像,有效增强了图像特征,但在复杂高维度数据的情况下大大降低了其实时性^[2]。QIAN提出了以主成分分析(principal component analysis, PCA)作为特征,方法简单但效果一般,尤其是在复杂的图像背景下^[3]。XU等人提

基金项目:国家自然科学基金资助项目(11505104);山东省高等学校科技计划资助项目(J15LN08)

作者简介:冯 玮(1993-),女,硕士研究生,主要研究方向为图像处理与分析。

* 通讯联系人。E-mail:wyude-01@163.com

收稿日期:2017-11-24;收到修改稿日期:2017-12-28

出了基于卷积神经网络的人脸表情识别,但在大批量的训练样本下会使网络出现过拟合现象^[4]。

卷积神经网络^[5-8]中在训练样本过大时,会出现网络无法收敛的情况,特征提取的效果差,增大了训练网络的难度。为了解决上述难题,提高识别率和网络稳定性、避免过拟合现象,作者在典型卷积神经网络的基础上提出了加权融合特征的深度学习算法,将图像分别进行 PCA 和随机投影(random projection, RP)降维处理,将降维后的矩阵进行加权融合,应用卷积神经网络进行处理提取图像分类的高层特征,将结果进行距离分类,得到分类结果。

1 深度学习网络

深度学习框架中卷积神经网络(CNN)的基本结构由输入层、卷积层、(下)采样层、全连接层、输出层构成,通常卷积层与池化层交替计算,中间层可以称为隐含层(CNN 网络并不区分全连接层与输出层)^[9-11]。卷积神经网络的 4 个关键的步骤:权值共享、池化、局部连接以及多网络层的使用。卷积层的计算可以降低输入数据的噪声信息,增强原始信息。池化是对卷积结果进行一个压缩处理,筛选特征,也就是下采样过程。全连接层为一个非线性特征映射过程来得到网络激活值。CNN 网络的滤波器(feature map)用于提取输入数据的特征,每个 feature map 都会有许多神经元连接下一层,但并不是全连接,降低了参量的规模,体现稀疏性,这是卷积神经网络的一大特点^[12-15]。卷积层的计算如下式所示:

$$x_j^i = f(\sum_{i \in M_j} x_i^{l-1} * k_{ij}^l + b_j^l) \quad (1)$$

式中, M_j 为输入的 maps 集合, x_i^{l-1} 采样与 k_{ij}^l 权重做卷积, $*$ 表示卷积运算, b_j^l 为偏移量, i 和 j 表示单元个数,上标 l 和 $l-1$ 表示网络层数,通过激活函数 f 进行逐层前向传输计算,可以得出网络的激活值与实际值的差^[16]。前向传播过程如图 1 所示。




Fig. 1 Process of forward propagation

图 1 中, x 表示输入层数据,上标表示网络层数,

$h_{w,b}(x)$ 为 3 层网络层处理后的数据,下标 W 为权值, b 为偏置值, $a_i^{(j)}$ 表示第 j 层、第 i 个单元的激活函数,如下式描述:

$$\begin{cases} a_1^{(2)} = f(W_{11}^{(1)} x_1 + W_{12}^{(1)} x_2 + W_{13}^{(1)} x_3 + b_1^{(1)}) \\ a_2^{(2)} = f(W_{21}^{(1)} x_1 + W_{22}^{(1)} x_2 + W_{23}^{(1)} x_3 + b_2^{(1)}) \\ a_3^{(2)} = f(W_{31}^{(1)} x_1 + W_{32}^{(1)} x_2 + W_{33}^{(1)} x_3 + b_3^{(1)}) \end{cases} \quad (2)$$

$$h_{w,b}(x) = a_1^{(3)} = f(W_{11}^{(2)} a_1^{(2)} + W_{32}^{(2)} a_2^{(2)} + W_{33}^{(2)} a_3^{(2)} + b_1^{(2)}) \quad (3)$$

式中, $b_i^{(j)}$, $W_i^{(j)}$ 表示当前层对上一层的偏置和权重的映射,上标 j 显示为层数, $h_{w,b}(x)$ 为 Logistic 回归。因此,前向传播可以总结为:

$$z^{(l+1)} = W^{(l+1)} a^{(l)} + b^{(l+1)} \quad (4)$$

$$a^{(l+1)} = f(z^{(l+1)}) \quad (5)$$

激活函数为 relu 函数,即 $f = \max(0, x)$,本文中使用的激活函数并非传统的 sigmoid 函数,因为 sigmoid 函数两端饱和,在传输过程中易丢失信息,相比较 relu 函数则更容易学习优化。此非线性映射函数使深度神经网络具备了分层的非线性映射学习能力,使隐含层具有意义^[17-20]。按极小化误差的方法反向传播调整权重矩阵,就进入了反向传输过程。 $J(W, b)$ 函数作为反向传播中的代价函数,实际上是对样本真实值与其测量值之间的误差的一个计算公式,单个代价函数为:

$$J(W, b; x, y) = \frac{1}{2} \| h_{w,b}(x) - y \|^2 \quad (6)$$

整体代价函数为:

$$J(W, b) = \left[\frac{1}{m} \sum_{i=1}^m J(W, b; x^{(i)}, y^{(i)}) \right] + \frac{\lambda}{2} \sum_{l=1}^{nL-1} \sum_{i=1}^{sl} \sum_{j=1}^{sl+1} (W_{ij}^{(l)})^2 \quad (7)$$

通过梯度下降算法来更新权值,每一次迭代对参量 W 和 b 进行反向更新:

$$W_{ij}^{(l)} = W_{ij}^{(l)} - a' \frac{\partial}{\partial W_{ij}^{(l)}} J(W, b) \quad (8)$$

$$b_i^{(l)} = b_i^{(l)} - a' \frac{\partial}{\partial b_i^{(l)}} J(W, b) \quad (9)$$

式中, a' 为学习速率,直至找到最佳的权值 W ,偏置值 b 使得代价函数的值达到最小,这就是权值更新的意义。其中最小代价函数的偏导数为:

$$\frac{\partial}{\partial W_{ij}^{(l)}} J(W, b) =$$

$$\left[\frac{1}{m} \sum_{i=1}^m \frac{\partial}{\partial W_{ij}^{(l)}} J(W, b; x^{(i)}, y^{(i)}) \right] + \lambda W_{ij}^{(l)} \quad (10)$$

$$\frac{\partial}{\partial b_i^{(l)}} J(W, b) = \frac{1}{m} \sum_{i=1}^m \frac{\partial}{\partial b_i^{(l)}} J(W, b; x^{(i)}, y^{(i)}) \quad (11)$$

式中, (x, y) 为单个案例样本, W 为网络连接节点权重, b 为偏置值, W_{ij} 为权重值, λ 为权重系数。

2 加权融合的联合特征提取

PCA 提取最主要的信息来表达原始数据, 去除冗余与噪声, 简化复杂度并能最大程度地保留原始数据特征, 其中特征值与能量的含义至关重要。具体步骤见下:

(1) 计算数据矩阵列向量的均值 \bar{X} , 并将原训练数据矩阵 X 减去均值。

$$\bar{X} = \frac{1}{m} \sum_{i=1}^m X_i \quad (12)$$

$$X_i' = X_i - \bar{X} \quad (13)$$

(2) 计算协方差矩阵 C_X 。

$$C_X = \frac{1}{m-1} \sum_{i=1}^m (X_i', X_i'^T) \quad (14)$$

(3) 计算协方差矩阵的特征值和特征向量。

(4) 从大到小的排列特征值, 选择其中前 k 个特征值对应的特征向量作为投影特征矩阵 (保证能量在 97% 以上), 即为 b' 。

(5) 将训练样本 X 投影到上述特征向量上, 得到最终的 PCA 降维矩阵, 即为 Y 。

$$Y = b' \times X \quad (15)$$

随机投影, 将原始的高维度数据使用一个列长相

等的随机矩阵投影到一个低维度子空间中来达到简化原始数据的作用, 是一种计算高效、高保真、高精度的降维方法, 其实验结果是稀疏的^[16]。首先, 生成投影矩阵 R , 其过程如下:

(1) 构造一个独立同分布的、均值为零、正态的随机矩阵。

(2) 将步骤 (1) 产生的随机矩阵的行向量做标准正交化处理, 得到投影矩阵 R 。

(3) 对投影矩阵 R 的行向量进行归一化处理。

接下来, 将训练样本数据进行投影, 得到随机投影降维矩阵, 步骤为:

(1) 计算训练样本图像矩阵列向量的均值 \bar{d} , 行向量即为 y_i 。

$$\bar{d} = \frac{1}{m} \sum_{i=1}^m y_i \quad (16)$$

(2) 步骤 (1) 中训练样本图像矩阵减去均值。

$$y_i' = y_i - \bar{d} \quad (17)$$

(3) 步骤 (2) 矩阵与投影矩阵 R 相乘, 得到随机投影降维矩阵 S , 如下式所示:

$$S = R \cdot y_i' \quad (18)$$

本文中采用 PCA 与 RP 来对图像进行加权联合降维, 就是将两者的降维矩阵串行的组合在一起, 当然也需要进行权值的选取。最后测试特征融合方法的检测效果。图 2 为融合特征提取算法的流程。




Fig. 2 Design flow of module algorithm

图 2 中 x 表示输入数据, y 表示输出数据, 图像联合降维的融合特征如式:

$$\begin{cases} X_j = [X_{RP}, X_{PCA}] = [m \cdot P(x), n \cdot R(x)] \\ m + n = 1 \end{cases} \quad (19)$$

式中, $R(x)$ 和 $P(x)$ 分别为 RP 和 PCA 所对应的降维空间, m 为 PCA 降维矩阵的加权系数, n 为 RP 的加权系数, X_{RP} 和 X_{PCA} 分别为 RP 和 PCA 降维矩阵加权后的样本, X_j 为加权联合降维的图像特征向量。

3 算法实现

本文中提出的基于加权融合特征的深度识别算法的实现步骤如下: (1) 将图像按照 (12) 式 ~ (15) 式计算, 得到按 PCA 计算得到的降维矩阵 $P(X)$; (2) 将取均值图像向投影向量 R 投影, 见 (18) 式, 计算得到随机投影降维矩阵 $R(X)$; (3) 按照 (19) 式把步骤 (1)、步骤 (2) 结果串行加权融合, 形成新的降维特征 X, m ,

n 分别为 PCA 降维矩阵的加权系数和 RP 降维矩阵的加权系数,将图像预处理结果应用卷积神经网络 CNN 中进行处理,获取图像分类识别;(4)应用距离分类法分类,实现图像分类。算法实现流程图如图 3 所示。

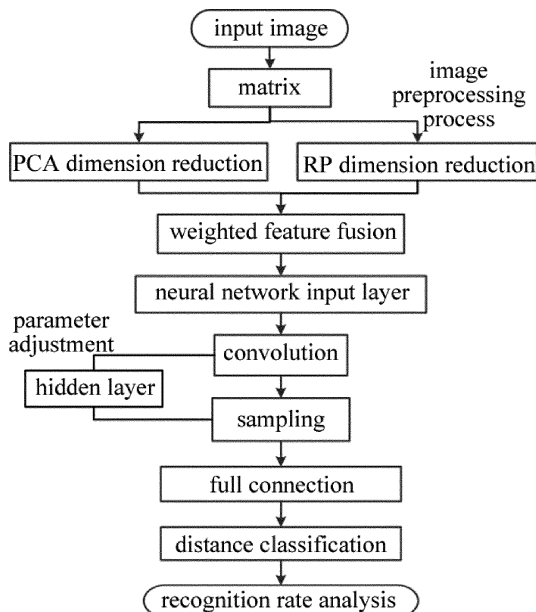


Fig. 3 Flow chart of classification recognition algorithm based on weighting and dimension reduction

4 实验与结果分析

实验条件为:计算机配置为 64 位操作系统, CPUi5-4200U 处理器,内存为 4GB, MATLAB 版本为 R2014a。数据库为 MIT 标准人脸图像库(图像总数为 2000 幅)、BioID 数据库、自建库。其中 MIT 人脸库包

含 10 个人不同表情与头部姿势,每人 200 幅。库图片如图 4 所示。




Fig. 4 Partial image of MIT face database

4.1 参量确定

在深度学习的神经网络研究中,参量的选择与确定很重要,如网络层数等。预处理过程中,即使是很小的差异也会产生不可忽略的影响。

参量确定实验在 MIT 标准人脸库、BioID 人脸库、自建库(以自然场景图像为主)3 种库上进行,图片像素尺寸归一化为 115×115 ,网络结构为 224-54-27-13-13-13-6。

4.1.1 特征值维数的确定 为了使数据得到更好的降维投影矩阵基,在 PCA 运算过程中将高维矩阵投影到低维空间,使复杂问题简单化,则协方差矩阵的计算是关键,可以从中分析特征值与特征向量,以能量集中的特征值对应的特征向量构成图像降维特征,选取能量超过全部能量的 97% 的特征值来确定识别特征。

Table 1 Determination of the dimension of eigenvalues

dimension	15	19	20	21	22	23	24	25	28	30
euclidean	89.9	88.9	89.9	94.4	94.4	94.4	92.9	94.4	94.3	93.9
cosine	90.4	90.4	90.4	94.4	94.9	94.4	93.9	93.9	94.5	96.4
correlation	86.9	90.4	88.9	92.4	94.6	92.4	92.9	92.9	94.3	94.9
mean	89.1	89.9	89.7	93.8	94.7	93.8	93.3	93.3	94.2	94.9

本文中选取能量超过全部能量的 97% 的特征值

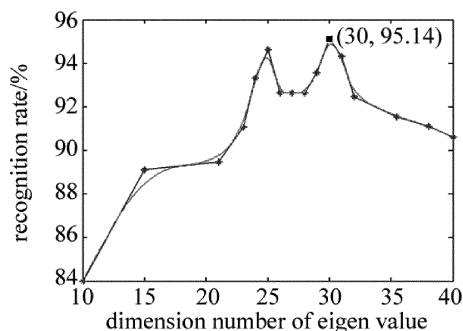


Fig. 5 Relationship between the dimension of eigen value and recognition rate

的特征向量来表征图像,对应的的特征值个数为 30, PCA 与 RP 的联合降维后的数据维度为 30×115 。表 1 所示准确率最高能达到 96.4%。在 PCA 与 RP 的联合降维的特征串行融合权值为 0.6:0.4 及深度网络为 17 层时,特征值个数对算法识别准确率的关系,如表 1 所示。特征值维数与识别准确率的关系曲线中有明显的两个拐点,分别为维数为 24、30 时图像识别率比较高,特别在特征值维数为 30 时,识别率能达到最高,如图 5 所示。

4.1.2 深度学习结构确定 深度学习卷积神经网络结构层次决定学习特征的深度,在固定联合特征权值

比 0.6:0.4 及特征值个数为 30 个的前提下研究深度学习网络结构对准确率的影响。实验结果如表 2 所示。表中数据取 100 次试验的均值作为最终实验结

果。从表 2 中看出,网络为 17 层结构时,识别率最高,3 种距离算法下识别率平均值为 95.14%。

从图 6 中可以看出,在网络结构层数为 17 时,图

Table 2 Structure determination of deep learning

network structure(res)	14	15	16	17	18	19	20	21	22
euclidean	87.94	88.44	87.94	93.97	92.46	89.45	88.94	85.43	74.87
cosine	87.44	88.94	88.94	96.48	92.96	89.45	89.95	85.93	75.88
correlation	88.44	88.44	88.94	94.97	93.47	90.45	89.95	85.93	75.88
mean	87.94	88.61	88.61	95.14	92.80	89.95	89.61	85.76	75.54




Fig. 6 Relationship between number of network structure and recognition rate

像的检测率达到最高,高于或低于 17 时准确率呈下降趋势。说明网络层数为 17 时获取的特征具有很好的表达能力。

4.1.3 特征融合系数的确定 利用联合降维的思想,将 PCA 处理后的矩阵与经过 RP 投影的矩阵进行加权串联的方法实现融合。两者降维矩阵直接串联的特征识别效果不理想,如图 7 所示。按 0.6:0.4 加权串联

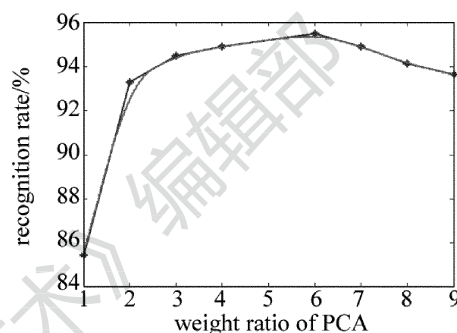


Fig. 7 Relationship between weight ratio of PCA and recognition rate
特征融合识别的结果明显好于直接串联的识别效果。

实验结果如表 3 所示。在特征值个数为 30、深度网络层数为 17 层的条件下得到的联合特征值对准确率的影响。由图 8 看出,随着 PCA 降维矩阵所占比重逐渐增加,识别率也呈现出逐渐上升的趋势,直至 PCA 矩阵与 RP 降维矩阵之比达到 6:4,识别率能达到最高,达到 96% 以上。

Table 3 Determination of feature fusion coefficient of PCA and RP

weight ratio	0.5:0.5	0.1:0.9	0.2:0.8	0.3:0.7	0.4:0.6	0.6:0.4	0.7:0.3	0.8:0.2	0.9:0.1
euclidean	85.43	87.44	93.79	94.47	94.47	93.97	94.47	92.96	92.46
cosine	86.43	86.93	92.96	94.47	94.47	96.48	95.48	94.97	94.47
correlation	84.42	86.43	92.96	94.47	94.47	94.97	94.97	94.47	93.97
mean	85.43	86.93	93.29	94.47	94.47	95.14	94.97	94.13	93.63

4.2 算法性能比较

4.2.1 算法的有效性 本文中设计了加权联合降维的特征融合深度识别算法来提取图像的深层特征。为了验证算法的有效性,设计 3 种特征提取算法与本文中方法的对比试验,分析识别率。方法 1 是采用 PCA 投影法提取特征和欧氏距离分类法;方法 2 是采用随机投影 RP 法提取特征和欧氏距离分类法;方法 3 是采用深度网络体特征和欧氏距离分类法;方法 4 是本文中设计的加权融合特征的深度识别法与欧氏距离分类法。为了保证实验的准确性,采用相同的实验条件和数据库。

实验结果如表 4 所示。表中数据取 50 次试验的

Table 4 Comparison results of feature extraction method

feature extraction method	method 1	method 2	method 3	method 4
recognition rate	86%	89%	93%	97%

均值作为最终实验结果。由表 4 可知,本文中所设计的特征提取算法的准确率明显高于前 3 种方法的准确率。总结得出:方法 1 与方法 2 仍停留在浅层特征的挖掘,属于传统的手动提取特征;方法 3 虽然采用了深度网络提取特征,但对于大尺寸的人脸图片,识别效果不佳;而本文中所设计的加权特征融合算法有效处理大尺寸图片,通过多层隐含层的设计挖掘了数据深层、抽象的特征,识别率最高。

4.2.2 分类器性能比较 加权特征融合算法提取特

征后,采用 3 种近邻方法的分类器设计对比实验来分析分类器对识别率的影响。3 种近邻方法为:欧氏距离法、夹角余弦距离法、相关距离法。

实验结果如表 5 所示。表中数据取 50 次试验的均值作为最终实验结果。表 5 所示夹角余弦距离分类法的分类结果更为稳定,识别率相对较高。

Table 5 Comparison results of distance method

classification method	euclidean distance	cosine distance	correlation distance
recognition rate	91.5%	93%	92%

4.2.3 算法鲁棒性 本文中通过 BioID 库、自建库两种图库来检验算法鲁棒性。BioID 库为 400 张图片 10 类,自建库选取了 650 张 23 类(以物品图像为主)。数据库如图 8、图 9 所示。




Fig. 8 Some images of BioID library



Fig. 9 Some images of self-built library

实验结果如表 6 所示。表中数据取 50 次试验的

均值作为最终实验结果。从表 6 可知,本文中算法在两种图库上验证的识别率均能达到 90% 以上,尤其自建库的识别率能达到 93%,表明本文中所设计算法在背景复杂与样品数目种类居多的情况下具有良好效果,说明了本文中算法具有良好适应性。

Table 6 Contrast results of three kinds of galleries

library name	MIT library	BioID library	self-built library
recognition rate	97%	90%	93%

5 结 论

本文中提出了加权联合降维的特征融合与分类识别算法。将图片分别进行 PCA 降维处理和 RP 降维处理,根据两特征的识别贡献率对 PCA 降维处理和 RP 随机投影处理结果进行加权融合。加权融合结果经卷积神经网络处理得到图像分类的高层特征,使用欧氏距离分类器对识别对象进行分类。实验表明,这种方法检测率高、鲁棒性强、效果显著,避免了手动提取特征的片面与繁琐,有效改善了卷积神经网络对大尺寸图片识别效果不佳的情况,降低了网络计算的复杂度,避免了过拟合现象。

参 考 文 献

[1] SUN Y, CHEN Y H, WANG X G, *et al.* Deep learning face representation by joint identification-verification [J]. *Advance in Neural Information Processing Systems*, 2014, 27 (12) :30-60.

[2] LLORCA D F, ARROYO R, SOTELO M A. Vehicle logo recognition in traffic images HOG features and SVM [C]//2013 16th International IEEE Conference on Intelligent transportation Systems: Intelligent Transportation Systems for All M-odes (ITSC 2013). New York, USA: IEEE, 2014;2229-2234.

[3] QIAN F. Face recognition based on PCA [D]. Nanjing:Southeast University, 2003; 49-51 (in Chinese).

[4] XU P, FU H. Facial expression recognition based on convolutional neural network, [J]. *Artificial Intelligence*, 2015, 34 (12) :45-47 (in Chinese).

[5] XU F J, WU W, GONG Y, *et al.* Tracking using convolutional neural networks [J]. *IEEE Transcations on Neural Networks*, 2010, 21 (10) :1610-1623.

[6] BELHUMEUR P N, HESPANHA J P, KRIEGMAN D J. Recognition using class specific linear projection [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1997, 19 (7) :711-720.

[7] ZHANG C, ZHANG Z. Improving multiview face detection with multi-task deep convolutional neural networks [C]//2014 IEEE Winter Conference on Application of Computer Vision (WACV). New York, USA: IEEE, 2014;1036-1041.

[8] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [C]// International Conference on Neural Information Processing Systems. City of North Miami Beach, Florida, USA :Curran Associates Inc. , 2012;1097-1105.

- [9] BENGIO Y. Learning deep architectures for AI [J]. Foundations & Trends[®] in Machine Learning, 2009, 2(1):1-127.
- [10] LIN Y M. face recognition based on deep learning [D]. Dalian: Dalian University of Technology, 2013: 14-26 (in Chinese).
- [11] SUN Y, WANG X G, TANG X. Deep learning face representation form predicting 10,000 classes[C]//Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition. New York, USA: IEEE, 2014:1891-1898.
- [12] ZHENG Y, CHEN Q Q. Deep learning and its new progress in object and behavior recognition[J]. Journal of Image and Graphic, 2014, 19(2):175-184.
- [13] CHEN Ch. Research and implementation of face detection algorithm based on depth learning[D]. Chengdu: University of Electronic Science and Technology, 2017:49-80 (in Chinese).
- [14] LANGKVISE M, KARLSSON L, LOU T A. A review of unsupervised feature learning and deep learning for time series modeling[J]. Pattern Recognition Letter, 2014, 42(5):11-24.
- [15] XIONG Y, ZUO X Q, HUANG L, *et al.* Classification of color remote sensing images based on multi-feature combination [J]. Laser Technology, 2014, 38(2): 165-171 (in Chinese).
- [16] LIU B. Infrared face recognition method based on random projection and sparse representation [D]. Xi'an: Xi'an Electronic and Science University, 2009:2-9 (in Chinese).
- [17] SUN J G, MENG F Y. A weighted weighted fusion face recognition algorithm [J]. Journal of Intelligent Systems, 2015, 12(7):4-7 (in Chinese).
- [18] ZHANG B, LIU J F, TANG X L. Multi-scale video text detection based on corner and stroke width verification[C]//Visual Communications and Image Processing (VCIP), 2013. New York, USA: IEEE, 2014:1-6.
- [19] ZOU G F, FU G X. Multi pose face recognition based on weighted mean face[J]. Computer Application Research, 2017, 11(7):1-7 (in Chinese).
- [20] CHAN T H, MA Y. A simple deep learning baseline for image classification[J]. IEEE Transactions on Image Processing, 2015, 11(4):10-17.