

基于 Logistic 回归和 BPNN 的二值人脸图像识别

王海燕

(四川文理学院智能制造学院 四川 达州 635000)

摘要 针对人脸检测识别中受外在条件影响及低识别率的问题,提出一种基于二值图像的 Logistic 回归和反向传播神经网络 BPNN(back-propagation neural network)的人脸识别方法。该算法将彩色图像被转换成灰度图像。使用低通滤波器去噪,将局部窗口标准偏差和自适应阈值应用于灰度图像,得到高质量的二值去噪图像,从中检测可能的人脸区域。使用最近邻居内插方法将其缩小,与每个缩小大小的图像相对应地创建人脸数据库。使用 Logistic 回归和 BPNN 来分类属于每个人的所有图像,并为每一类图像获得一个决策边界。图像尺寸的缩小最大限度地减少了逻辑回归和神经网络训练的计算空间和时间。实验结果表明,在 FEI 图像数据库上 Logistic 回归和反向传播神经网络的识别精度高达 97.5%,优于其他识别算法的精度。

关键词 人脸识别 自适应阈值 最近邻插值 Logistic 回归 反向传播神经网络

中图分类号 TP391 **文献标识码** A **DOI**:10.3969/j.issn.1000-386x.2019.02.043

BINARY FACE IMAGE RECOGNITION BASED ON LOGISTIC REGRESSION AND BPNN

Wang Haiyan

(College of Intelligent Manufacturing, Sichuan University of Arts and Science, Dazhou 635000, Sichuan, China)

Abstract Face detection and recognition is affected by external conditions has low recognition rate. To solve this problem, we proposed a face recognition method based on binary image Logistic regression and back-propagation neural network (BPNN). The algorithm converted the color images to grayscale images. A low-pass filter was used to remove the noise. The local window standard deviation and adaptive threshold were applied to grayscale images so as to obtain high-quality binary denoised images from which possible face regions were detected. We adopted the nearest neighbor interpolation method to reduce them. A face database was created corresponding to each reduced-size image. We used Logistic regression and BPNN to classify all images belonging to each person, and obtained a decision boundary for each type of image. The reduction in image size minimized the computational space and time of logistic regression and neural network training. Experimental results show that the accuracy of Logistic regression and BPNN is as high as 97.5% in the FEI image database, which is better than the accuracy of other recognition algorithms.

Keywords Face recognition Adaptive threshold Nearest neighbor interpolation Logistic regression Back-propagation neural network(BPNN)

0 引言

人脸识别领域的研究人员一直在基于子空间判别分析或统计学习来表示和识别人脸^[1],人脸识别由于其在安全和监控方面的广泛应用,在过去的二十年中引起了广泛的研究兴趣^[2-3]。人脸识别可以不受干扰

地执行,而不需要用户的知识或明确的合作,然而,在不受控制的环境中拍摄的面部图像可以具有不同的姿态、面部表情、照明和伪装。由于对于给定图像的变化类型是未知的,因此设计一个能够处理不同影响因素的人脸识别算法变得至关重要^[4-6]。

目前,人脸识别方法主要分为几类:几何特征、基于模型、神经网络、深度学习和多分类器等。文献[7]

中提出了使用自组织映射从几何面部特征中识别情感的方法,使用扩展 Kohonen 自组织映射(KSOM)的综合数据驱动模型,其输入是包括眼睛、嘴唇和眉毛等特征点的26维面部几何特征向量,提高了识别精度。文献[8]将几何特征与SVM结合,提出基于显着几何特征和支持向量机的面部表情识别。文献[9]在隐马尔科夫模型基础上,在待识别头像预处理过程中增加了光照补偿操作,提出一种改进的隐马尔科夫模型的人脸识别方法。

LBP也是常用的人脸识别方法,文献[10-11]对LBP进行改进,分别提出自适应LBP人脸识别算法和增强局部量化模式(ELQP)的人脸识别算法。

随着深度学习的发展,其在计算机视觉领域取得很多成果,更是有研究将深度学习应用到人脸识别。文献[12]中提出了一个深度残差学习框架来减轻网络训练,该算法明确地将层重新定义为参照层输入学习残差函数,而不是学习未引用的函数。文献[13]提出了一种中心丢失的深度人脸识别方法,该方法在中心丢失同时学习每个类深层特征的中心,并惩罚深层特征与其相应类中心之间的距离,提出的中心损失函数是可训练的并且易于在CNN中优化。文献[14]提出一个综合的深度学习框架,用多模态信息联合学习人脸表征。所提出的深度学习结构由一组精心设计的卷积神经网络和三层堆叠自动编码器组成。该组CNN从多模式数据中提取补充面部特征。然后,将提取的特征串联起来形成高维特征向量,其维数由堆叠自动编码器压缩。

在研究了现有人脸识别方法的基础上,提出了一种基于Logistic回归和神经网络的二值人脸图像识别算法。该算法是将彩色图像转换为二进制图像,应用局部窗口标准差来增强局部变化在面部区域和自适应阈值捕捉局部变化,可获得高质量的二值图像。以这种方式生成的二值图像具有突出的面部边界并可以方便地用于定位面部区域的特征。然后,采用基于规则的人脸检测方法,基于形态学得到二值图像的垂直和水平轮廓,通过去除原始图像中的非面部区域来提取检测到的面部区域。通过应用最近邻插值方法,将二值人脸图像的尺寸减小,用分类器来分类属于每个人的所有图像,并为每一类图像获得一个决策边界。实验结果表明,本文方法能够高度准确地实现人脸识别。

1 图像二值化与特征提取

1.1 二值化与图像检测

二进制图像的分析比灰色或彩色图像更易操作和

费时更少,大多数人脸识别方法都是基于颜色和灰度图像,因为获得高质量的二值图像是一项具有挑战性的任务。本文提出的是处理从FEI数据库中提取的二值图像,对尺寸为 640×480 的快照图像进行实验,其人脸区域检测算法流程如图1所示。



图1 图像二值化和人脸区域检测的流程

图像二值化和人脸区域检测过程中,首先将颜色转换为灰度图像,之后通过应用局部窗口标准差LWSD(Local Window Standard Deviation)和自适应阈值处理来获得二值去噪图像。使用尺寸为 $M \times N$ 的滑动窗口的图像 X 的局部窗口标准偏差可以计算为:

$$\Delta = \sqrt{\frac{1}{MN-1} \left(q - \frac{s^2}{MN} \right)} \quad (1)$$

式中: $q = \sum_{i=1}^M \sum_{j=1}^N X_{ij}^2$, $s = \sum_{i=1}^M \sum_{j=1}^N X_{ij}$ 。LWSD 助于增强局部变化并使小的特征更加突出。

为了获得像素值为0和1的二值图像,使用了采用低通滤波器的自适应阈值方法。将接近1的某个值用作阈值,并且将滤波图像与其相乘以获得阈值图像,将阈值图像与原始图像进行像素比较,并且将大于阈值图像中的对应像素的原始图像中的像素值设置为1,否则将其设置为0。通过应用 $Y = (X * F) > \tau$ 从 Y 灰度图像生成二值图像 X ,其中 $*$ 代表滤波操作, F 代表平滑滤波器, τ 为阈值,本文由经验取值为0.9785。

图2(a)显示了一个灰度图像,其相应的二值图像使用局部窗口标准差和自适应阈值获得如图2(b)所示,由此获得的二值图像由不同维度的面部区域和非面部区域组成。



(a) 灰度图像 (b) 二值图像

图2 灰度图像和二值图像

然而,非面部区域对于学习目的来说并不重要,必须移除它以便仅提取面部区域。首先通过去除像素的

水平黑线去除可能的头发区域来找到头部的顶部,从左侧和右侧删除黑色像素的垂直线,完成连接组件分析以检测眉毛。选择 $M \times N$ 的均匀尺寸以使得整个提取的图像具有相同的像素尺寸。如果行数小于 M 或列数小于 N ,则只需在二进制图像的底部和侧面填充 0 或 1 即可。同样,如果行数大于 M 或列数大于 N ,则从图像的顶部和侧面移除一行像素。在这里,选择了 $M = 190$ 和 $N = 170$ 维,提取的二元人脸具有 190×170 的像素大小,如图 3 所示。



图3 连通分量分析前后的人脸区域检测

1.2 图像的特征提取

特征提取是人脸识别系统的重要组成部分,因为成功率的高低取决于提取的特征如何表现不同类别的图像独特性及其对同一类别图像的喜好程度。本文使用局部二值模式 LBP (Local Binary Pattern) 的特征提取方法进行人脸识别。

要使用全脸图像代替局部特征,则必须输入所有的图像像素作为学习的特征向量。这里提取的二值人脸图像具有 $190 \times 170 = 32\ 300$ 的像素大小,这对于训练来说太大而不可行,为了减小复杂性并减少学习时间,本文使用最近邻插值方法。通过最近邻插值得到的缩小图像具有 $m \times n$ 的大小,其中 m 和 n 是缩小图像矩阵的行数和列数。通过将每一行逐个级联,将缩小的图像矩阵转换成行向量,特征数据集 X 是通过堆叠图像的每个行向量来形成的。

$m \times 1$ 维的列向量 y 与在 X 中的每个对应的图像向量给出的标签(目标值)一起形成,其中样本数是样本量。对同一个人的图像给出相同的标签号,以便将一个人作为一个类的图像和另一个人的图像作为另一个类,等等。在机器学习中,矩阵 X 将是输入特征,向量是每个行的输出标签。

2 Logistic 回归和 BPNN 的二值人脸图像识别

2.1 Logistic 回归人脸图像识别

Logistic 回归允许两类分类的非线性边界模型不

同于仅当两个类可以通过线性分隔时才起作用的线性回归。线性回归分析用于人脸识别系统,如果这两类样本可以线性分离,也被应用于用于面部表情识别的平稳主成分分析。然而,即使当两类样本不能线性分离时,Logistic 回归也能起作用,从而产生更高的正确分类率的机会。Logistic 回归使用一个逻辑函数(也称为 sigmoid 函数),它在 0 和 1 之间的范围内产生一个“S”形曲线。sigmoid 函数 $g(z)$ 可以表示为:

$$g(z) = \frac{1}{1 + e^{-z}} \quad (2)$$

在输入图像特征矩阵 X 的每一行中加入 $x_0^i = 1$ 的偏差,其中 $i = 1, 2, \dots, m$, 添加偏置节点以增加模型的灵活性以适应数据,特征矩阵 X 现在变为:

$$X = \begin{bmatrix} x_0^1 & \text{image} & 1 \\ x_0^2 & \text{image} & 2 \\ \vdots & \vdots & \vdots \\ x_0^m & \text{image} & m \end{bmatrix} = \begin{bmatrix} 1 & x_j^1 \\ 1 & x_j^2 \\ \vdots & \vdots \\ 1 & x_j^m \end{bmatrix} \quad (3)$$

式中: $j = 1, 2, \dots, n$ 。在 Logistic 回归中,假设函数 $h_{\theta(x)}$ 作为一个阈值分类器,当 $h_{\theta(x)} \geq 0.5$, 预测 $y = 1$, 当 $h_{\theta(x)} < 0.5$, 预测 $y = 0$ 。假设函数将输入特征分类为两个类 $[0\ 1]$ 。矩阵 X 经过转置,使特征矩阵为列向量。

学习参数 θ 是一个 $(n + 1) \times 1$ 的列向量,初始化为 0 向量。学习参数 θ 将在每次迭代中改变其值以适应模型,假设函数可以计算为:

$$h_{\theta(x)} = g(\theta^T x) \quad \text{s. t. } 0 \leq h_{\theta(x)} \leq 1 \quad (4)$$

式中: x 是矩阵 X 的向量元素, θ 是与特征矩阵中的每个像素值相关联的学习参数值。在机器学习中,成本函数测量特定解决方案远离最佳解决方案的程度,梯度下降是与梯度负值成最佳解决方案(或局部最小值)成比例的步骤。成本函数和梯度下降可迭代多次以从给定数据中学习并计算假设函数。

当有太多参数作为输入特征时,可能会发生过度拟合,过度拟合会导致较差的预测性能,因为这会试图适应外部噪声参数和训练数据的微小波动。为了防止模型过度拟合,使用正则化函数,其目标是使成本函数最小化 θ , 正则化成本函数计算如下:

$$J(\theta) = \frac{1}{m} \sum_{i=1}^m \left(-y^{(i)} \log(h_{\theta}(x^{(i)})) - (1 - y^{(i)}) \times \log(1 - h_{\theta}(x^{(i)})) + \frac{\lambda}{2m} \sum_{j=1}^n \theta_j^2 \right) \quad (5)$$

式中: $y^{(i)}$ 是 y 中第 i 行的输出标签,而 λ 是正则化参数,本文中使用 $\lambda = 1$ 来避免过度拟合。因为 θ_0 对应于偏置输入 $x_0 = 1$, 所以参数 θ_0 不被考虑用于正则化,则损失函数的梯度定义为:

$$\begin{cases} \frac{\partial J(\theta)}{\partial \theta_0} = \frac{1}{m} \sum_{i=1}^m ((h_{\theta}(x^{(i)}) - y^{(i)})x_j^i) & j = 0 \\ \frac{\partial J(\theta)}{\partial \theta_j} = \frac{1}{m} \sum_{i=1}^m ((h_{\theta}(x^{(i)}) - y^{(i)})x_j^i) + \frac{\lambda}{m}\theta_j & j \geq 1 \end{cases} \quad (6)$$

为了得到一个非线性边界的最优解,直到梯度下降到局部极小值,正则化的代价函数被迭代停止,为两类分类生成的决策边界如图 4 所示。




图 4 Logistic 回归的二分类

应用给定的公式,可以训练机器将其中一个类别分为多个类别,因此,对于给定数量的类,必须训练分类数。使用迭代法计算代价函数和梯度下降,在一定的次数或收敛到最优解,数据的训练产生一个预测输出。

2.2 BPNN 学习的人脸识别

本文采用三层 BPNN 的人脸识别技术,该技术适用于在通过二值化和矢量化获得的缩小二值人脸图像,采用 BPNN 训练 80% 的人脸数据库和一个前馈神经网络来测试剩余的 20%。

三层的神经网络包括输入层、两个隐藏层和输出层,如图 5 所示,其中 $\Theta^{(i)}$ 是要获得的网络参数, $g(z^{(i)})$ 是通过将 Sigmoid 函数应用于 θ 与前一层的乘积而获得的值。 $h_{\theta}(x^i)_k = \alpha_k^3$ 是第 k 个输出单元的激活, L 是层的总数, s_l 是层 l 中的单元数。




图 5 前馈神经网络模型

给出 m 个样本和 k 个输出标签的训练集,并给出正则化神经网络的整体成本函数。

$$J(\theta) = -\frac{1}{m} \left[\sum_{i=1}^m \sum_{k=1}^K y_k^{(i)} \log(h_{\theta}(x^{(i)}))_k - \Lambda \right] +$$

$$\frac{\lambda}{2m} \sum_{l=1}^{L-1} \sum_{i=1}^{s_l} \sum_{j=1}^{s_{l+1}} (\Theta_{ij}^{(l)})^2 \quad (7)$$

式中: $\Lambda = (1 - y_k^{(i)}) \log(1 - h_{\theta}(x^{(i)}))_k$, 给定一个训练样本 (x^t, y^t) , 首先运行正向传递来计算整个网络中的所有激活, 然后对于层 l 中的每个节点 j , 计算误差项 $\delta_j^{(l)}$ 来衡量该节点对输出中的错误的贡献。三层网络的反向传播更新方法如图 6 所示。




图 6 反向传播神经网络模型


采用的反向传播算法如下所示:

- (1) 将输入层的值 (a^1) 设置为第 t 个训练样本 $x^{(t)}$, 执行前馈神经网络, 计算层 2、3、4 的激活 $(z^{(2)}, a^{(2)}, z^{(3)}, a^{(3)}, z^{(4)}, a^{(4)})$, 在输入和隐藏层添加 +1 的偏差;
- (2) 对输出层中的每个输入单位 k 进行设置 $\delta_k^{(4)} = a_k^{(4)} - y_k, y_k \in \{0, 1\}$ 指示当前训练样本是属于同一类别还是属于不同类别;
- (3) 对于隐藏层 $l = 2$, 设置 $\delta^{(3)} = (\Theta^{(2)})^T \delta^{(4)} \times (g'z^{(3)})$;
- (4) 对于隐藏层 $l = 1$, 设置 $\delta^{(2)} = (\Theta^{(2)})^T \delta^{(3)} \times (g'z^{(2)})$;
- (5) 跳过 $\delta_0^{(3)}$ 和 $\delta_0^{(2)}$ 因为其对应于偏置单位, 通过 $\Delta^{(l)} = \Delta^{(l)} \delta^{(l+1)} \times (a^{(l)})^T$ 积累梯度;
- (6) 通过将累积梯度除以图像总数 m , 获得神经网络损失函数的梯度: $\frac{\partial}{\partial \Theta_{ij}^{(l)}} J(\Theta) = D_{ij}^{(l)} = \frac{1}{m} \Delta_{ij}^{(l)}$ 。

通过以上算法, 将获得每个层的 Θ^1, Θ^2 和 Θ^3 , 这些层将在前馈技术中用输入测试特征来计算, 以预测测试数据属于哪个类。

3 实验结果与分析

在本文中, 使用 FEI 图像数据库进行研究, 本文只考虑正面图像和稍微倾斜的图像以用于训练和测试目的。来自 FEI 数据库中选择 40 个人, 每个人 5 张图像, 训练和测试比例为 4:1。图 7 给出了一些训练的例子和相应的测试数据集。



(a) 训练图像 (b) 测试图像

图7 训练图像和测试图像

在表1中给出了 Logistic 回归和 BPNN 的训练和测试准确度结果。

表1 使用 Logistic 回归和 BPNN 在人脸图像上的准确率

图像大小	缩小尺寸	Logistic 回归		BPNN	
		训练准确性	测试精度	训练准确性	测试精度
95 × 85	50%	100%	100%	100%	95%
57 × 51	30%	100%	100%	100%	95%
38 × 34	20%	100%	100%	100%	97.5%
19 × 17	10%	100%	97.5%	2.5%	2.5%

从表1可以看出,逻辑回归和 BPNN 都为训练和测试提供了很高的准确率,数据在所有尺寸缩小的情况下。在所有情况下,Logistic 回归都优于 BPNN,Logistic 回归给出了 100% 的准确性,而当图像大小减小到 38 × 34 时,BPNN 将测试图像错误归类为 97.5% 的精度。Logistic 回归分别为培训和测试分别提供 100% 和 97.5% 的准确性,当图像尺寸进一步减小到 19 × 17 时,BPNN 无法训练网络。可以得出,当使用二值图像进行人脸识别时,Logistic 回归优于 BPNN。

将本文算法与其他算法进行比较识别准确度,图像大小减小到 38 × 34,结果见表2。

表2 不同算法人脸识别准确度

Logistic 回归	BPNN	YCrCb	HSV	YCrCb + HSV
100.00%	97.50%	94.60%	95.3%	96.6%

可以看出本文算法识别准确率达到 100% 和 97.5%,而其他三种识别准确率分别为 94.6%、95.3% 和 96.6%,说明本文算法优于其他三种二值人脸识别算法的性能。

为检验算法的普适性,在 CAS-PEAL 大规模中国人脸图像数据库上对本文算法进行验证,该人脸库包

含 1 040 人的 99 450 幅人脸图像,将本文算法与其他算法进行比较,人脸识别结果见图8。




图8 不同算法的人脸识别率

可以看出本文算法识别准确率达到 97% 和 95% 以上,而其他三种识别率低于本文算法,说明在 CAS-PEAL 大规模人脸数据库上,本文算法优于其他三种二值人脸识别算法的性能。

4 结 语

本文提出了基于 Logistic 回归和 BPNN 的二值人脸识别算法,该算法使用 LWSD 和自适应阈值将彩色图像转化为去噪二值图像,生成的二值图像具有突出的面部边界并可以方便地用于定位面部区域的特征,减少人脸识别时间。然后采用基于规则的人脸检测方法、形态学,得到二值图像的垂直和水平轮廓,去除原始图像中的非面部区域来提取检测到的面部区域。将与检测到的脸部区域对应的二值图像用作训练数据集。之后通过应用最近邻插值方法,将二值人脸图像的尺寸减小,然后使用 Logistic 回归和 BPNN 来分类属于每个人的所有图像,并为每一类图像获得一个决策边界。实验结果表明,本文方法能实现二值人脸图像识别,且在不同的缩小比例下,Logistic 回归和 BPNN 识别精度优于其他二值人脸识别算法,说明本文算法的可行性与有效性。

参 考 文 献

- [1] Schroff F, Kalenichenko D, Philbin J. FaceNet: A unified embedding for face recognition and clustering [C]//IEEE Conference on Computer Vision and Pattern Recognition. IEEE Computer Society, 2015:815-823.
- [2] 蔡芬. 一种基于人工免疫的小波特征集合最近邻人脸识别算法[J]. 西南师范大学学报(自然科学版), 2016, 41(3):96-100.
- [3] Zhu X, Lei Z, Yan J, et al. High-fidelity pose and expression normalization for face recognition in the wild [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2015: 787-796.



图7 部分图像定位结果图

3 结 语

本文提出一种结合最稳定极值区域和边缘增强的船名定位方法。该方法首先采用 Retinex 算法增强待处理图像,然后检测 MSER 区域,之后采用 Canny 算子检测边缘,得到边缘增长后的文字候选区域,最后分析连通域属性,设定先验知识阈值,得到最终文字区域。该算法通过实验和分析,验证了该方法在昼间和夜间均能实现船名精准定位。实验结果表明,昼间数字定位准确率高达 90.9%,昼间船名定位准确率达 78.5%。

本文对于船名字符定位算法的研究在一定程度上弥补了船名定位在计算机视觉方面的空白,另一方面该研究也推进了基于计算机视觉的船舶身份自动识别进程。本文所提出的算法仍有需改进之处,如针对船名中的汉字字符的定位准确率相对较低,提高字符定位准确率尤其是中文字符准确率将是今后研究需要突破的难点。

参 考 文 献

- [1] 王永杰,裴明涛,贾云得. 多信息融合的快速车牌定位[J]. 中国图象图形学报, 2014, 19(3): 471-475.
- [2] 钟伟钊,杜志发,徐小红,等. 基于字符边缘点提取的车牌定位方法[J]. 计算机工程与设计, 2017, 38(3): 795-800.
- [3] Kim K I, Jung K, Kim J H. Texture-based approach for text detection in images using support vector machines and continuously adaptive mean shift algorithm[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2003, 25(12):1631-1639.
- [4] 魏娜,王振臣,张聪,等. 一种新型车牌定位算法的研究[J]. 激光与红外, 2012, 42(8): 936-939.
- [5] 魏金光,侯杰,张帆. 基于均值差分边缘检测和单链聚类的实时车牌定位算法[J]. 电视技术, 2017, 41(9): 176-181.

- [6] Pan Y F, Hou X, Liu C L. A hybrid approach to detect and localize texts in natural scene images[J]. IEEE Transactions on Image Processing, 2011, 20(3): 800-813.
- [7] 邓泓,李水泉,彭莹琼. 像素连接车牌定位技术的研究[J]. 江西师范大学学报(自然科学版), 2017(6): 651-655.
- [8] 王晓群,刘宏志. 基于自适应数学形态学的车牌定位研究[J]. 图学学报, 2017, 38(6): 843-850.

(上接第 244 页)

- [4] Sariyanidi E, Gunes H, Cavallaro A. Automatic analysis of facial affect: A survey of registration, representation, and recognition[J]. IEEE transactions on pattern analysis and machine intelligence, 2015, 37(6): 1113-1133.
- [5] Ding C, Choi J, Tao D, et al. Multi-directional multi-level dual-cross patterns for robust face recognition[J]. IEEE transactions on pattern analysis and machine intelligence, 2016, 38(3): 518-531.
- [6] Lu J, Liong V E, Zhou X, et al. Learning compact binary face descriptor for face recognition[J]. IEEE transactions on pattern analysis and machine intelligence, 2015, 37(10): 2041-2056.
- [7] Majumder A, Behera L, Subramanian V K. Emotion recognition from geometric facial features using self-organizing map[J]. Pattern Recognition, 2014, 47(3): 1282-1293.
- [8] Ghimire D, Lee J, Li Z N, et al. Recognition of facial expressions based on salient geometric features and support vector machines[J]. Multimedia Tools and Applications, 2017, 76(6): 7921-7946.
- [9] 李忠健,杨宜民,梅平. 基于改进的隐马尔科夫模型的人脸识别方法[J]. 工业控制计算机, 2014, 27(11):29-31.
- [10] 朱黎,胡涛,罗锋. 基于自适应 LBP 人脸识别的身份验证[J]. 计算机工程与科学, 2014, 36(11):2217-2222.
- [11] 张辉,刘新. 基于改进 LBP 的单样本人脸识别算法[J]. 计算机应用与软件, 2017,34(12): 220-223, 282.
- [12] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Las Vegas, NV, United States: IEEE, 2016: 770-778.
- [13] Wen Y, Zhang K, Li Z, et al. A discriminative feature learning approach for deep face recognition[C]//European Conference on Computer Vision. Springer, Cham, 2016: 499-515.
- [14] Ding C, Tao D. Robust face recognition via multimodal deep face representation[J]. IEEE Transactions on Multimedia, 2015, 17(11): 2049-2058.