

融合 PCA 的支持向量机人脸检测研究

李宜清, 程武山

(上海工程技术大学 机械与汽车工程学院, 上海 201820)

摘要: 支持向量机 (Support Vector Machine, SVM) 作为一种经典的非线性分类器, 用于模式识别, 可以将训练样本从不可线性分类的低维空间映射到可线性分类的高维空间, 再做分类, 文章主要训练支持向量机使它学会区分人脸和非人脸; 支持向量机的数学推导完备, 算法逻辑严密, 整体上比 Adaboost 算法复杂, 但在样本量较少的情况下效果良好, 因此有样本优势; 支撑它的理论包含泛化性理论、最优化理论和核函数等, 这些理论也被学术界广泛用于其他机器学习算法如神经网络, 几十年来被证明具有很高的可靠性; 同时本文论述主成分分析技术 (PCA) 用于压缩数据, 实现数据降维, 在数据预处理方面算法提供了很大帮助, 使 SVM 支持向量机的输入数据维数大幅下降, 大大提高了运算和检测时间。

关键词: 支持向量机; PCA; 人脸检测; 数据降维; 模式识别

Research on Face Detection Based on Improved Support Vector Machine Combined with PCA

Li Yiqing, Cheng Wushan

(Shanghai University of Engineering Science, Shanghai 201820, China)

Abstract: Support vector machine (SVM), as a classical nonlinear classifier, is used for pattern recognition. It can map the training samples from the low dimensional space of non linear classification to the high dimensional space of the linear classification, and then do the classification. This paper mainly trains the classifier to make it learn to distinguish the face and the non face. The support vector machine has complete mathematical derivation, rigorous algorithm logic, and more complex than Adaboost on the whole, but it has a good effect in the case of less sample size, so there is a sample advantage. The theory that supports it includes generalization theory, optimization theory and kernel function, which are also widely used in other machine learning algorithms, such as neural networks, which have been proved to have high reliability for several decades. At the same time, this paper discusses the principal component analysis (PCA) technology to compress data, realize data reduction, and provide great help to the algorithm of data preprocessing, which greatly reduces the dimension of input data of SVM support vector machine, and greatly improves the operation and detection time.

Keywords: support vector machine; PCA; face recognition; data dimensionality reduction; pattern recognition

0 引言

人工智能理论在过去的几十年一直在不断发展, 但是由于计算机硬件的局限, 特别是内存和运算速度的局限, 使得很多理论成熟的理论缺少应用。随着计算机软硬件迅速革新换代, 人工智能也发展出了很多的应用技术, 尤其是模式识别领域的应用, 具体包括行人检测、人脸识别、表情识别和语音识别等^[1-3]。这些应用的目的是希望设计出像人一样从经验中学习, 并做出决策的机器, 从而代替人的智慧完成一些特定的工作。而在诸多经验中, 人脸表情经验对判断人的心理活动, 体察人的喜怒哀乐具有重要意义, 如何让机器学习识别人脸表情, 是人工智能研究领域的一个热门话题^[4]。表情识别研究的对象是包含人脸的图片和视频 (视频也是由时间上连续的图片组成), 所以如何确定人脸在图片中的位置, 成为表情识别的第一步, 也即

如何实现人脸检测是表情识别的第一步 (同时也是关键的一步)。本文就这一问题给出了一种解决方案。

查阅大量文献后, 发现目前比较可靠的人脸检测算法主要包括如下四类:

- 1) 基于特征提取和决策树的级联分类器 (Adaboost) 算法。
- 2) 基于优化理论、泛化理论和核函数理论的支持向量机 (Support Vector Machine, SVM) 算法。
- 3) 基于贝叶斯先验模型的朴素贝叶斯模型。
- 4) 基于特征提取和权值更新的神经网络算法。

其中神经网络 (如 BP 神经网络、CNN 卷积神经网络、RNN 循环神经网络等) 作为人工智能领域划时代的产物, 参考人和动物的细胞感知外物的原理建立起神经网络细胞模型, 实现了数据并行运算和网络结构的自适应、自学习, 具有训练快速, 泛化性良好的优点, 但是也有容易陷入局部最优的缺点^[5]; Adaboost 算法采用级联的决策树结构, 具有泛化性好, 速度快, 命中率高的优点, 但是需要大量样本提高泛化性, 提取的特征值也数量惊人, 所以需要消

收稿日期: 2018-09-17; 修回日期: 2018-10-22。

作者简介: 李宜清 (1994-), 男, 上海市青浦区人, 硕士研究生, 主要从事嵌入式和模式识别方向的研究。

耗大量内存, 不适合移植到小型设备^[6]; 而贝叶斯理论需要建立数据的先验概率分布模型, 模型建立简单, 但是对非典型样本适应性不够好^[7]; SVM 支持向量机算法用到了优化理论、泛化理论和核函数知识, 其模型是一个分隔所有数据点的超平面, 所有一定有全局最优解, 并且因为只需依靠占样本数量少数的支持向量维持超平面位置的特点, 不需要大量样本, 且泛化性好, 缺点是算法设计较复杂, 这一点可由序贯最小优化 (Sequential Minimal Optimization, SMO) 算法来解决^[8-11]。

基于对上述各算法优缺点的考虑和本身作者知识的掌握情况, 选择 SVM 支持向量机作为本文所论述的人脸检测算法。

而除了对人脸检测算法本身的选择会影响算法消耗的时间和空间大小, 对于数据的保存和使用如果设计的好也可以大大节省算法时间和空间, 因此本文还设计了结合奇异值分解 (Singular value decomposition, SVD) 的主成分分析 (Principal Component Analysis, PCA) 作为第一环节来实现数据的降维^[12]。

在第二环节, 降维后的数据经 SVM 支持向量机训练后保存为分类器数据结构。

到了第三环节, 为了减少分类器的负担, 提高效率, 考虑到肤色在 YCbCr 颜色空间的分布具有统计学特性, 设计了一种肤色高斯概率模型, 用以在图片上提取肤色感兴趣域, 这样就大大缩小了分类器的筛选范围^[13]。

第四环节使用分类器对肤色感兴趣域进行分类, 提取出人脸域, 这一环节可能提取出多个人脸域, 所以设计并查集算法合并同类域, 最后得到唯一的人脸域^[14]。

1 使用 PCA 进行样本降维处理

主成分分析 (Principal Component Analysis, PCA) 是一种分析数据在某空间分布的特征方向, 并提取主要方向, 用数据在主要方向上的投影来代替它们本身, 实现数据降维的技术, 可以减少数据所需存储空间。

1.1 使用奇异值分解对样本矩阵进行特征分解

用于训练的样本图片是彩色图片, 包括红、绿、蓝 (R、G、B) 三个通道的数据。灰度图反映的是图片的亮度信息, 仅包含灰度 (Y) 单通道的数据。

本文设定样本矩阵包括个灰度化后的图片样本, 每张图片大小都是 $N=24 \times 24$, 那么样本矩阵可以表示为:

$$\mathbf{X} = [x_1, x_2, \dots, x_m]^T, M = 100 \quad (2)$$

由于样本矩阵的行和列一般不相等, 所以对样本矩阵进行分解需要使用奇异值分解。奇异值分解 (singular value decomposition, SVD) 作为特征分解在任意矩阵上的推广, 可以对任意矩阵进行分解, 定义如下:

$$\mathbf{X} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^T \quad (3)$$

其中: \mathbf{U} 和 \mathbf{V} 是酉矩阵, 即 $\mathbf{U}\mathbf{U}^T = \mathbf{I}, \mathbf{V}\mathbf{V}^T = \mathbf{I}$ 。矩阵 \mathbf{U} 是 \mathbf{U} 空间的 $M \times M$ 阶标准正交基向量矩阵, 矩阵 \mathbf{V} 是 \mathbf{V} 空间的 $N \times N$ 阶标准正交基向量矩阵, $\mathbf{\Sigma}$ 是 $M \times N$ 阶半正定对角

矩阵, 除主对角元素外其余为 0, 主对角元素叫做奇异值 $r = \min(M, N)$, 数量为。

由于:

$$\mathbf{X}\mathbf{X}^T = (\mathbf{U} \sum \mathbf{V}^T)(\mathbf{U} \sum \mathbf{V}^T)^T \quad (4)$$

化简为:

$$\mathbf{X}\mathbf{X}^T = \mathbf{U} \sum^2 \mathbf{U}^T \quad (5)$$

所以 \mathbf{U} 矩阵可通过求特征向量得到, 同理:

$$\mathbf{X}^T \mathbf{X} = \mathbf{V} \sum^2 \mathbf{V}^T \quad (6)$$

所以 \mathbf{V} 矩阵可通过对 $\mathbf{X}^T \mathbf{X}$ 求特征向量得到, 而 $\mathbf{\Sigma}$ 矩阵可通过对 $\mathbf{X}\mathbf{X}^T$ 或 $\mathbf{X}^T \mathbf{X}$ 的特征值开平方根得到。

1.2 PCA 主成分分析实现数据降维

PCA 主成分分析通过对 SVD 分解得到的奇异值在主对角线上按大到小排序, 舍弃较小的值, 剩下的奇异值对应的特征向量也按顺序组成矩阵。设 $\mathbf{X}\mathbf{X}^T$ 或 $\mathbf{X}^T \mathbf{X}$ 的特征值为 λ_i , 奇异值 σ_i 计算公式为:

$$\sigma_i = \sqrt{\lambda_i} \quad (7)$$

且 $\sigma_1 > \sigma_2 > \dots > \sigma_r$, 定义数据压缩率

$$\eta = \frac{\sum_{j=1}^l \sigma_j}{\sum_{i=1}^r \sigma_i} \quad (8)$$

$\sigma_1, \sigma_2, \dots, \sigma_l$ 和对应的特征向量 v_1, v_2, \dots, v_l 即样本数据的主成分。 η 一般取 0.6~0.9, η 越低表示数据压缩率越低, 降维效果越好, 同时数据信息丢失的就越多。

变化公式 (3), 得到:

$$\mathbf{X}\mathbf{V} = \mathbf{U} \sum \quad (9)$$

\mathbf{V} 和 $\mathbf{\Sigma}$ 只保留主成分, 于是有:

$$\mathbf{X}[v_1, v_2, \dots, v_l] = \mathbf{U} \sum_l \quad (10)$$

令 $\mathbf{X} = \mathbf{X}v_i$ ($i=1, 2, \dots, l$) 为 \mathbf{X} 在特征向量 v_i 上的映射矩阵, 代替原始数据作为训练数据, 维度为 $M \times l$ ($l < r$), 即实现了数据降维。

2 支持向量机原理

支持向量机 (Support Vector Machine, SVM) 由 Broser, Guyon 和 Vapnik 发明。支持向量机的特点是产生分类超平面使数据间隔最大化, 使用了核函数, 有全局最优解, 解具有稀疏性, 以及通过泛化误差界来控制样本容量。本文使用一种软间隔 SVM 向量机, 并使用序贯最小算法 (Sequential Minimal Optimization, SMO) 优化^[11]。

2.1 核函数实现数据线性可分

对于数据维度为 N 的样本, 可能存在线性不可分的问题, 因此也就无法找到可以正确分离两类数据的超平面。于是利用核函数将数据的点积从低维空间映射到高维空间, 从而实现高维空间的线性可分, 再利用线性可分的原理进行计算。

这里使用高斯径向基核函数:

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right), \sigma > 0 \quad (11)$$

高斯径向基核函数可以看成是一个以 x_j 为中心的的概率域, 代表 x_i 与 x_j 的相似度, x_j 即所谓的支持向量, 需要通过对目标函数进行优化求解得到。后文的 x_i, x_j 统一用 $K(x_i, x_j)$ 或 K_{ij} 代替。

2.2 优化目标的得到

超平面 (The hyperplane) 用于分隔两类数据, 维度总比数据空间低一维。假如数据线性可分, 那么可由许多个超平面按图 1 分开。




图1 超平面将数据分开

数据点到超平面的位置关系如图 2 所示。




图2 点到超平面的向量表示

其中:

$$\vec{x} = x_0 + \gamma \frac{w}{\|w\|} \quad (12)$$

$$\gamma = \frac{w^T x + b}{\|w\|} = \frac{f(x)}{\|w\|} \quad (13)$$

得到几何间隔和函数间隔的关系:

$$\tilde{\gamma} = \gamma \|w\| = \frac{\tilde{\gamma}}{\|w\|} \quad (14)$$

支持向量机的目的就是最大程度地分开两类数据, 所以目标就是最大化数据集中所有点到超平面的几何间隔中的最小间隔, 即:

$$\max \tilde{\gamma} \quad (15)$$

并且有约束条件:

$$y_i(w^T x_i + b) = \hat{\gamma}_i \geq \tilde{\gamma}, i = 1, 2, \dots, M \quad (16)$$

固定 $\tilde{\gamma} = 1$, 并根据式 (1) 和 (2) 做等效替代, 于是优化目标变成:

$$\min \frac{1}{2} \|w\|^2 \quad (17)$$

$$\text{Subject to } y_i(w^T x_i + b) \geq 1, i = 1, 2, \dots, M$$

为了提高泛化性, 允许数据点在一定程度上违反间隔

约束, 给出松弛变量 ξ_i ($\xi_i \geq 0$), 并设不等式约束函数:

$$g_i(w) = 1 - y_i(w^T x_i + b) - \xi_i \leq 0, i = 1, 2, \dots, M \quad (18)$$

为了将等式约束和不等式约束加入优化目标, 设定原问题的拉格朗日函数:

$$L(w, \alpha, \xi, b, r) = \frac{1}{2} \|w\|^2 + \sum_{i=1}^M \alpha_i g_i(w) + C \sum_{i=1}^M \xi_i - \sum_{i=1}^M r_i \xi_i \quad (19)$$

对各个变量求偏导, 然后加上约束条件, 就是优化问题有最优解的 Karush-Kuhn-Tucker (KKT) 条件:

$$\frac{\partial}{\partial w_i} L(w^*, \alpha^*, \xi^*, b^*, r^*) = w - \sum_{i=1}^M \alpha_i y_i x_i = 0 \quad (20)$$

$$\frac{\partial}{\partial \xi_i} L(w^*, \alpha^*, \xi^*, b^*, r^*) = C - \alpha_i - r_i = 0 \quad (21)$$

$$\frac{\partial}{\partial b} L(w^*, \alpha^*, \xi^*, b^*, r^*) = \sum_{i=1}^M y_i \alpha_i = 0 \quad (22)$$

$$\alpha_i^* g_i(w^*) = 0 \quad (23)$$

$$(\alpha_i^* - C) \xi_i^* = r_i^* \xi_i^* = 0 \quad (24)$$

$$g_i(w^*) \leq 0 \quad (25)$$

$$C \geq \alpha_i^* \geq 0 \quad (26)$$

$$r_i^* \geq 0 \quad (27)$$

$$\xi_i^* = \text{maximise}[0, 1 - y_i(w^{*T} x_i + b^*)] \quad (28)$$

$$i = 1, 2, \dots, M \quad (29)$$

其中带 * 的量表示问题的最优解对应的参数值。

式 (19) 中 α_i 和 r_i 作为拉格朗日乘子同时也表示最优值对约束的灵敏度。C 代表安全系数, 作用是防止松弛变量对目标函数的影响过大, 同时也限制了离群点的 α_i , 即式 (26) (称为盒约束, 离群点的 α_i 通常很大, 需要加以约束, 同时也保证了可行域的界, 即原问题总有非空可行域)。式 (26) 由式 (21) 和式 (27) 得到。

式 (23) 和 (24) 称为 KKT 互补条件。从式 (23) 得知 $\alpha_i^* > 0$ 对应的 $g_i(w) = 0$ (称为积极约束), 对应的点也被称为支持向量 (Support vector)。而对应的 (称为非积极约束), 对应的点的扰动对最优问题的解没有影响。

从式 (21) 和式 (24) 得知 $r_i^* > 0$ 对应的 $\xi_i^* = 0$ 且 $\alpha_i^* < C$, 对应的点称为非离群点, 即几何间隔大于等于 $\frac{1}{\|w\|}$ (遵守间隔约束的) 数据点。而 $r_i^* = 0$ 对应的 $\xi_i^* > 0$ 且 $\alpha_i^* = C$, 对应的点称为离群点, 即几何距离小于 $\frac{1}{\|w\|}$ (允许在一定程度上违反间隔约束) 的数据点。

得到原目标问题和对偶问题的关系:

$$\min_{\omega, \xi, b} \max_{\alpha} L(\omega, \alpha, \xi, b, r) \geq \max_{\alpha} \min_{\omega, \xi, b} L(\omega, \alpha, \xi, b, r) \quad (30)$$

之所以不用求 $r_i^* > 0$ 是因为根据式 (21) $r_i^* > 0$ 可由 $C - \alpha_i^*$ 替换。当且仅当参数满足 KKT 条件 (ω, ξ, b 取到最优值 ω^*, ξ^*, b^*) 时式 (30) 的等号成立, 将式 (20)、(21) 和 (22) 带入式 (19) 将原目标问题转化为单优化值的对偶问题:

$$\max_{\alpha} L(\omega^*, \alpha, \xi^*, b^*, r^*) = (\max_{\alpha} L) W(\alpha) = (\max_{\alpha} L) \sum_{i=1}^M$$

$$\alpha_i - \frac{1}{2} \sum_{(i=1)}^M \sum_{(j=1)}^M \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (31)$$

$$\begin{aligned} \text{Subject to } & \sum_{i=1}^m \alpha_i y_i = 0, \quad i = 1, 2, \dots, MC \geq \alpha_i \geq 0, \\ & i = 1, 2, \dots, M \\ & 1 - y_i (\sum_{j=1}^M y_j \alpha_j K(x_j, x_i) + b) - \xi_i \leq 0, \\ & i = 1, 2, \dots, M \\ & \alpha_i (1 - y_i (\sum_{j=1}^M y_j \alpha_j K(x_j, x_i) + b) - \xi_i) = 0, \\ & i = 1, 2, \dots, M \end{aligned}$$

求出了最优的 α^* ，接着就可以求出最优的 ω^* 、 b^* 、 ξ^* 和 r^* 。

2.3 SMO 优化算法

在求解式 (31) 的优化问题的时候，会发现每次更新要更新一组变量 $\alpha_1, \alpha_2, \dots, \alpha_m$ ，也就是说目标函数要对这 M 个变量依次求最优值。而由于有约束 $\sum_{i=1}^M \alpha_i y_i = 0$ ，所以可以每次只作用于 α 的一个小的子集（两个变量），且子集有如下约束：

$$\alpha_1^{new} y_1 + \alpha_2^{new} y_2 = \alpha_1^{old} y_1 + \alpha_2^{old} y_2 = \sum_{i=3}^m \alpha_i y_i = \text{常数} \quad (33)$$

利用解析式求每对变量的最优值，直到所有 α_i^* 都满足 KKT 条件，再根据约束去求对应的 ω^* 、 b^* 、 ξ^* 和 r^* 。这就是序贯最小优化（Sequential Minimal Optimization, SMO）算法的核心思想。

将式 (33) 带入式 (31) 得到：

$$\alpha_2^{new, smc} = \alpha_2^{old} + \frac{y_2(E_1 - E_2)}{\eta} \quad (34)$$

$$\eta = K_{11} + K_{22} - 2K_{12} \quad (35)$$

$$E_i = f(x_i) - y_i = (\sum_{j=1}^M y_j \alpha_j K(x_j, x_i) + b) - y_i, \quad i = 1, 2 \quad (36)$$




图 3 对变量 α_2 的约束

当 $y_1 \neq y_2$ 时：

$$L = \max(0, \alpha_2^{old} - \alpha_1^{old}) \quad (37)$$

$$H = \min(C, C + \alpha_2^{old} - \alpha_1^{old}) \quad (38)$$

当 $y_1 = y_2$ 时：

$$L = \max(0, \alpha_2 + \alpha_1^{old} - C) \quad (39)$$

$$H = \min(C, \alpha_2^{old} + \alpha_1^{old}) \quad (40)$$

由：

$$\frac{\partial}{\partial \alpha} W(\alpha_2) = K_{11} + K_{22} - 2K_{12}$$

可知当 $K_{11} + K_{22} - 2K_{12} > 0$ ， $W(\alpha_2)$ 是下凹函数，更新 α_2 ：

$$\alpha_2^{new, clipped} = \begin{cases} H & \text{if } \alpha_2^{new, clipped} \geq H \\ \alpha_2^{new} & \text{if } \alpha_2^{new, clipped} < L \\ L & \text{if } \alpha_2^{new, clipped} < L \end{cases} \quad (41)$$

当 $K_{11} + K_{22} - 2K_{12} \leq 0$ 时（当 $K_{11} + K_{22} - 2K_{12} < 0$ 时 $W(\alpha_2)$ 是上凸函数，当 $K_{11} + K_{22} - 2K_{12} = 0$ 时 $W(\alpha_2)$ 是线性函数），更新 α_2 ：

$$\alpha_2^{new, clipped} = \min(\psi_L, \psi_H) \quad (42)$$

其中：

$$\psi_L = L_1 f_1 + L f + \frac{1}{2} L_1^2 K_{11} + \frac{1}{2} L^2 K K_{22} + s L L_1 K_{12} \quad (43)$$

$$\psi_H = H_1 f_1 + H f_2 + \frac{1}{2} H_1^2 K_{11} + \frac{1}{2} H^2 K_{22} + s H H_1 K_{12} \quad (44)$$

$$f_1 = y_1(E_1 + b) - \alpha_1^{old} K_{11} - \alpha_2^{old} K_{12} \quad (45)$$

$$f_2 = y_2(E_2 + b) - \alpha_1^{old} K_{12} - \alpha_2^{old} K_{22} \quad (46)$$

$$L_1 = \alpha_1^{old} + s(\alpha_2^{old} - L) \quad (47)$$

$$H_1 = \alpha_1^{old} + s(\alpha_2^{old} - H) \quad (48)$$

根据支持向量（即 α_1 在 0 到 C 之间的向量 x_i ）的性质 $1 = y_i(\omega^T x_i + b)$ ，得到第一个 b 的计算公式：

$$b = y_i - \omega^T x_i = y_i - \sum_{j=1}^m \alpha_j y_j K(x_j, x_i) \quad (49)$$

之后的 b^{new} 按下式计算：

$$\begin{aligned} b^{new} = & b^{old} + (\alpha_1^{old} - \alpha_1^{new}) y_1 K(x_1, x_1) + \\ & (\alpha_1^{old} - \alpha_2^{new}) y_2 K(x_1, x_2) - E_1 \end{aligned} \quad (50)$$

$$\alpha_1^{new} = \alpha_1^{old} + y_1 y_2 (\alpha_2^{old} - \alpha_2^{new}) \quad (51)$$

关于 α_1 和 α_2 的选取采用启发式原则， α_1 的选择作为外循环， α_2 的选择作为内循环，一旦外循环选到符合条件的 α_1 ，即进入内循环选择符合条件的 α_2 ，然后进行优化。

外循环流程：

1) 搜索所有样本，选取不满足 KKT 条件的样本参数 α_i 作为 α_1 。

2) 搜索所有参数 α_i ，满足 $0 < \alpha_i < C$ 的样本，选择不满足 KKT 条件的样本参数 α_i 作为 α_1 。

不断重复 1) 和 2) 直到所有 α_i 满足 KKT 条件内循环流程：

1) 搜索所有样本，启发式地寻找使 $|E_1 - E_2|$ 最大的 α_2 。

2) 随机选择参数 α_i ，满足 $0 < \alpha_i < C$ 并且不满足 KKT 条件的样本参数 α_i 作为 α_2 。

3) 搜索所有样本，选择不满足 KKT 条件的样本参数 α_i 作为 α_2 。

4) 如果找不到合适的 α_2 ，就跳出内循环，寻找新的 α_1 。

不断更新一对对 α_1 和 α_2 ，并更新 ω 和 b 。直到所有样本都满足 KKT 条件，支持向量机训练完毕。

3 人脸检测的实现

3.1 训练支持向量机分类器

将 M 个训练样本经 PCA 主成分分析压缩后输入支持向量机训练, 这里程序代码使用 C# 语言编写。输出分类器数据结构并保存成文本格式, 如图 4 所示。

```

FACE_SVM_File - 记事本
文件(F) 编辑(E) 格式(O) 查看(V) 帮助(H)
SVM_File
&&&&
Data_Size>>37
SVM_b>>0.7650144
Two_Sigma_Squared>>1000000
N_Support_Vector>>267
SVM_C>>100
SVM_kernelstyle>>1
SVM_eps>>0.001
SVM_tolerance>>0.001
****alpha****
3.386821 2.85937 2.82564 0.3864306 3.112492 (
1 0.09722394 0.158274 0.06211544 0.04250482
02850661 0.01722409 0.09634486 11.94193 0.2(
&&&&
    
```

图 4 SVM 数据结构

3.2 高斯肤色模型粗取人脸感兴趣域

摄像头采集测试图片的大小统一压缩到 $300 * 168$ 。彩色图转化灰度图的公式如下:

$$Y = 0.299 * R + 0.578 * G + 0.114 * B \quad (52)$$

$$R = G = B = Y \quad (53)$$

原图经灰度化后由于拍摄时光线不好, 图片较暗, 灰度值集中在比较小的范围, 造成数据稀疏性不够, 所以使用光补偿算法扩展灰度值的尺度:

$$R = 255 * \left(\frac{R}{255}\right)^{\dagger} \quad (54)$$

$$G = 255 * \left(\frac{G}{255}\right)^{\dagger} \quad (55)$$

$$B = 255 * \left(\frac{B}{255}\right)^{\dagger} \quad (56)$$

得到光补偿后的灰度图如图 5 所示。



图 5 光补偿灰度图

为了缩小分类器筛选的范围, 使用肤色高斯模型进行人脸感兴趣域的粗取。由于肤色在 YCbCr 空间对光照不敏感, 所以将 RGB 空间转化到 YCbCr 空间, 转换公式如下:

$$Y = 0.299 * R + 0.587 * G + 0.114 * B \quad (57)$$

$$C_b = -0.1678 * R - 0.3313 * G + 0.5 * B + 128 \quad (58)$$

$$C_r = 0.5 * R - 0.4187 * G - 0.0813 * B + 128 \quad (59)$$

定义 C_b 和 C_r 的协方差矩阵为:

$$C = \begin{pmatrix} Cov(C_b, C_b) & Cov(C_b, C_r) \\ Cov(C_r, C_b) & Cov(C_r, C_r) \end{pmatrix} \quad (60)$$

其中:

$$Cov(C_b, C_b) = E[(C_b - \bar{C}_b)(C_b - \bar{C}_b)^T] \quad (61)$$

$$Cov(C_b, C_r) = E[(C_b - \bar{C}_b)(C_r - \bar{C}_r)^T] \quad (62)$$

$$Cov(C_r, C_b) = E[(C_r - \bar{C}_r)(C_b - \bar{C}_b)^T] \quad (63)$$

$$Cov(C_r, C_r) = E[(C_r - \bar{C}_r)(C_r - \bar{C}_r)^T] \quad (64)$$

得到肤色高斯模型的计算式:

$$P_{(C_b, C_r)} = exp[-0.5(x - Mean)^T C^{-1}(x - Mean)] \quad (65)$$

$$C = E((x - Mean)(x - Mean)^T) \quad (66)$$

$$x = [C_r, C_b]^T \quad (67)$$

$$Mean = E(x) \quad (68)$$

采集 100 个肤色图片样本经过训练后得到肤色高斯模型数据结构并保存为文本, 如图 6 所示。

```

skin - 记事本
文件(F) 编辑(E) 格式(O) 查看(V) 帮助(H)
<Skin>
<Mean>111.25 147.13</Mean>
<C>160 12 12 299</C>
</Skin>
    
```

图 6 肤色高斯模型数据结构

对 $P_{(C_b, C_r)} \geq 0.6$ 的点灰度值置 255, $P_{(C_b, C_r)} < 0.6$ 对的点灰度值置 0 得到由肤色概率分割的二值化图片如图 7 所示。




图 7 肤色概率分割二值化图

使用搜索框扫描图片, 搜索框具有 cell 和 size 属性, cell 代表最小单位边长 (像素点数), size 代表搜索框边长 (cell 数)。搜索策略是给 size 设置初始 start 值和终止 end 值。在 size 从 start 到 end 的增长过程中, 每当 size 加 1 之前, 用搜索框扫描一遍图片, 搜索策略如下: 在移动搜索框之前, 将当前框内所有点的 $P_{(C_b, C_r)}$ 值累加求均值:

$$\overline{P_{(C_b, C_r)}} = \frac{\sum_{j=1}^{size * cell} \sum_{i=1}^{size * cell} P_{(C_b, C_r)}}{size * size * cell * cell} \quad (69)$$

如果:

$$\overline{P_{(C_b, C_r)}} \geq \delta \quad (70)$$

则将该搜索框保存为脸候选框, 保存的内容包括搜索框的长、宽和位置坐标。这里代表肤色概率阈值 δ (一般取 $\delta=0.6$)。




图 8 扫描框扫描过程

总结如下:

1) 使用 PCA 主成分分析法对样本进行压缩, 提高了支持向量机训练速度。

2) 支持向量机引入 SMO 优化算法, 实现对非线性数据分隔面参数的快速训练, 并使得算法在程序上更容易实现。编译通过的程序根据样本训练得到的分类器数据结构使用文本保存到检测程序根目录, 方便检测时调用。

3) 使用肤色高斯概率模型粗取人脸感兴趣域, 大大缩小分类器筛选范围, 提高了检测速度。

参考文献:

[1] 钟义信. 人工智能的突破与科学方法的创新 [J]. 模式识别与人工智能, 2012, 25 (3): 456-461.

[2] 郑南宁. 人工智能面临的挑战 [J]. 自动化学报, 2016, 42 (5): 641-642.

[3] Mohamed A. Shatin. State-of-the-art review of some artificial intelligence applications in pile foundations [J]. Geoscience Frontiers, 2016, 7 (1): 33-44.

[4] 王大伟, 周 军, 梅红岩, 等. 人脸表情识别综述 [J]. 计算机工程与应用, 2014, 50 (20): 149-157.

[5] 王 亚, 朱 明. 基于卷积神经网络的人脸检测方法 [J]. 网络新媒体技术, 2016, 5 (6): 24-29.

[6] 江伟坚, 郭躬德, 赖智铭. 基于新 Haar-like 特征的 Ada-boost 人脸检测算法 [J]. 山东大学学报 (工学版), 2014, 44 (2): 43-48.

[7] 张明华. 基于贝叶斯理论的人脸识别算法的研究 [D]. 镇江: 江苏科技大学, 2012.

[8] 张永新. 基于 SVM 的人脸检测算法研究 [D]. 西安: 西北大学, 2009.

[9] Guang-Hui Xue. The Study of Coal and Gangue Recognition of Fully Mechanized Caving Mining Face Based on Support Vector Machine [Z]. 2015.

[10] Face Recognition Based on Support Vector Machine and Nearest Neighbor Classifier [J]. Journal of Systems Engineering and Electronics, 2003 (3): 73-76.

[11] (英) Nello Cristianini, John Shawe-Taylor 著. 支持向量机导论 [M]. 李国正等译. 北京: 电子工业出版社, 2004

[12] 张雪楠. 基于 PCA 降维的快速人脸检测算法研究 [D]. 秦皇岛: 燕山大学, 2016.

[13] 王航宇. 基于 YCbCr 肤色模型的人脸检测技术研究 [J]. 现代电子技术, 2008 (22): 102-105.

[14] 李 松, 刘力军, 翟 曼. 改进粒子群算法优化 BP 神经网络的短时交通流预测 [J]. 系统工程理论与实践, 2012, 32 (9): 2045-2049.

[13] 罗 钧, 李 研. 具有混沌搜索策略的蜂群优化算法 [J]. 控制与决策, 2010, 25 (12): 1913-1916.

[15] Ming-Wei Li, Wei-Chiang Hong, Hai-Gui Kang. Urban traffic flow forecasting using Gauss-SVR with cat mapping, cloud model and PSO hybrid algorithm [J]. Neurocomputing, 2013, 99.

[16] 苏 飞. 城市道路路网交通运行状态分析方法及应用研究 [D]. 北京: 北京交通大学, 2017.



图 9 候选人脸框

使用训练好的 SVM 分类器对候选人脸框进行筛选, 保留输出结果是“人脸”的候选框, 最后, 定义相似函数将相邻框归为一个集合, 取成员最多的集合求框长、宽和位置坐标的均值, 得到唯一人脸框:



图 10 合并同类框结果

4 结论

本文使用的人脸检测算法, 在 C# 平台中对文中所有理论进行程序验证和测试, 根据拍摄的 300 幅测试图片的结果 (上接第 48 页)

[10] Xu L, Peng J, Shao Y. Prediction of Expressway Traffic Flow on Holidays Based on Improved GA-BP Algorithm [J]. Journal of Computational & Theoretical Nanoscience, 2016, 13 (5): 3290-3294.

[11] 江铭炎, 袁东风. 人工蜂群算法及应用 [M]. 北京: 科学出版社, 2014.

[12] 匡芳君, 徐蔚鸿, 金 忠. 自适应 Tent 混沌搜索的人工蜂群算法 [J]. 控制理论与应用, 2014, 31 (11): 1502-1509.

[13] 江铭炎, 袁东风. 人工蜂群算法及应用 [M]. 北京: 科学出版社, 2014.