

基于深度网络的多形态人脸识别

王莹 樊鑫 李豪杰 林妙真
(大连理工大学软件学院 大连 116620)

摘要 在实际的自动人脸识别系统中,输入的识别图像往往在表情、分辨率大小以及姿态方面呈现出多种变化。现在在很多方法尝试通过线性或局部线性的映射来寻找由这些变化共享的统一的特征空间。利用由受限玻尔兹曼机(RBM)堆叠成的深度神经网络来发掘这些变化内在的非线性表达。深度网络能够学习高维数据到低维数据的映射关系,并且有助于提高图像分类和识别的性能。同时,为了实现在一个统一的深度框架下同时进行特征提取和识别,在网络的顶层增加了一个监督的回归层。在预训练阶段,通过训练集中不同姿态、不同表情以及不同分辨率的图像对网络进行初始化。在微调阶段,通过网络的输出与标签之间的差并利用标准反向传播的方法对模型的参数空间进行调整。在测试阶段,从测试库中随机选择一幅图像,获得统一空间下的特征向量。通过与参考图像库中的所有特征向量进行对比,利用最近邻域的方法识别人脸身份。在具有丰富表情以及大姿态变化的CMU-PIE人脸数据库上进行了全面的实验,结果表明,提出的方法取得了比最新的局域线性映射(或局部线性)的人脸识别方法更高的识别率。

关键词 人脸识别,深度网络,低分辨率,姿态,表情

中图法分类号 TP391.41 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2015.9.013

Face Recognition with Multiple Variations Using Deep Networks

WANG Ying FAN Xin LI Hao-jie LIN Miao-zhen

(School of Software Technology, Dalian University of Technology, Dalian 116620, China)

Abstract In automatic face recognition (AFR) applications, input images typically present multiple types of variations on expression, resolution and pose. Existing approaches attempt to seek a common feature space shared by these variations through linear or local linear mappings. We used deep networks stacked by restricted Boltzmann machines to discover intrinsic non-linear representations of these variations. Deep learning can provide insight into how high-dimensional data are organized in a lower dimensional feature space and it also improves the performance of classification and recognition. In the meantime, we realized a supervised regression layer on the top of the network so that both feature extraction and recognition can be achieved in a unified deep framework. For the pre-training phase, the whole network is initialized by training set including different poses with various expressions under high resolution (HR) and low resolution (LR). For the fine-tuning phase, the parameter space is adjusted by the errors between the output of network and the labels via standard back propagation. For the test phase, a profile face image from Probe is chosen randomly, then the feature vector in the subspace is gained. Compared with all of the vectors in the Gallery set, we determined the identity of images by the nearest neighborhood. We performed the extensive experiments on CMU-PIE facial database that presents rich expressions and wide range pose variations. The experiments show the superior recognition rate of our approach over the state-of-the-art linear (or locally linear) methods.

Keywords Face recognition, Deep networks, Low resolution, Pose, Expression

1 介绍

在过去的十年里,自动人脸识别(AFR)领域取得了显著进展。经典算法往往适用于可控条件下的人脸识别,被称为标准模式^[1]。在这种条件下的人脸图像是正面的而且其分辨率较高。但是,最近的研究表明在实际的AFR系统中存在两

大难题:1)低端摄像机带来的图像是低分辨率的^[2];2)目标人物的表情变化和姿态变化带来的图像差异^[3]。

现在流行的方法尝试寻找到一个由不同分辨率、不同姿态和表情变化的人脸图像共享的特征空间来解决人脸识别问题。标准模式(正面人脸)和其他形态图像(非正面图像、不同表情的图像、或者低分辨率图像)之间的相关关系或映射关系

到稿日期:2014-07-29 返修日期:2014-08-12 本文受国家自然科学基金项目(61033012,61003177,61272371),教育部新世纪优秀人才计划(11-0048)资助。

王莹(1989-),女,硕士,主要研究领域为计算机视觉,E-mail:593013732@qq.com;樊鑫(1977-),男,博士后,博士生导师,主要研究领域为计算机视觉、医学影像处理、计算几何,E-mail:xin.fan@ieee.org;李豪杰(1973-),男,博士后,副教授,主要研究领域为计算机视觉与图像处理、多媒体搜索,E-mail:hjli@dlut.edu.cn;林妙真(1986-),女,硕士,主要研究领域为计算机视觉。

建立在此共同空间下。对于输入的任何不同形态的图像,可以找到与标准模式对应的特征,而后运用简单的分类器进行识别,如最近邻方法^[4]。Li 等人提出的 CLPM 算法建立了一种局部的线性映射方法,保持了姿态和分辨率差异性之间的局部邻域关系^[5]。Huang 和 Zeng^[1]利用径向基函数(RBF)构建不同姿态和分辨率图像间的内在关系。他们将两种线性方法即典型相关分析(CCA)和主成分分析(PCA)串联起来,提取变化之间的相关特性。为了提高低分辨率人脸图像的识别效果,文献^[14]利用 CCA 确定基于 HR 和 LR 样本的特征空间,再对标记的样本集进行半监督的局部保持投影(semiLPP)。这些代表性工作应用线性策略来估计姿态变化、表情变化以及分辨率变化带来的非线性差异。这种估计算法在图像具有显著变化时降低了识别效果。

近几年研究者们利用一种深度结构来建立数据与特征之间的非线性映射关系,并且将基于深度架构的学习算法应用于计算机视觉的不同应用方面。Salakhutdinov 和 Hinton 利用深度学习作为非线性内嵌来保持邻域关系^[7],其目标函数与文献^[5]中的相似,最大的不同在于文献^[7]中的非线性特征。对于图像分类方面的应用,Zhou 等人将标记数据与未标记数据一同供给深度网络、找到特征并最大化类别的区分性^[8]。相似的方法也出现在语音识别方面^[9]。He 等人提出一种基于神经网络、利用故障相关性分析来解决软件多故障定位的模型^[13]。Hu 等人^[19]将网络应用于无线传感器网络的异常监测中。文献^[20]将动态调整网络参数的遗传算法应用于软件可靠性增长模型的研究中。最近,Huang 等人将卷积深度信念网络(CDBN)引入特征学习领域,将描述子与经典的局部二值模式(LBP)进行互补^[12],并验证了描述子在一对一识别方面的有效性;Andrew 等人^[15]利用两个不同的网络训练不同姿态的图像,使得训练后的特征向量在低维空间中最大相关(CCA);CNN^[16]将每一层的特征提取分成卷积和池化两部分,对局部特征进行训练和学习;为了解决姿态变化给人脸识别带来的非线性变化,Zhu 等人^[17]利用深度神经网络将侧面图像映射成正面图像,增加人脸图像的识别信息,提高识别效果;与经典 DBN 不同,文献^[18]提出对每一层的节点单元进行监督,将大角度的人脸图像分成不同的小角度进行训练和识别,减小了网络对训练图像的学习难度。

但是,DBN 如何学习全局特征来进行多变化的情况下的人脸识别并没有得到全面的研究。

本文利用深度网络(DN)寻找从多种变化情况下的人脸图像到低维特征空间的非线性映射。同时,在 DN 上设置一个逻辑回归层,用于识别基于深度信念网络的特征向量。与以往的工作^[1,5]不同,我们是在统一的 DN 框架下进行特征提取、映射和分类,而不是将这 3 种独立模块分开进行识别。利用各种变化(分辨率、表情和姿态)下的人脸图像训练神经网络,产生初始的网络权重,然后利用交叉熵对目标标签的梯度下降微调网络权重。人工将图像分组成同一类变化下的不同图像,目的是训练成对图像之间的映射关系^[1,5]。这样,可以简单地将测试库中不同形态的人脸图像输入训练后的网络,得到的输出即为其身份特性(ID)。图 1 示出整个算法框架。我们在具有显著人脸变化的 CMU-PIE 数据库^[10]上验证了提出算法的有效性。

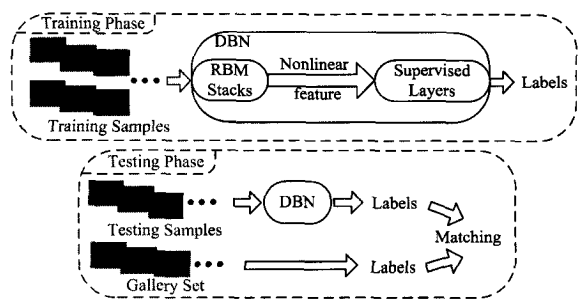
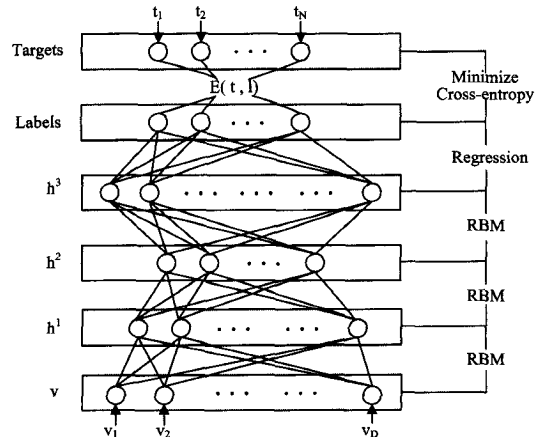


图 1 基于深度网络的人脸识别框架图

2 网络架构

深度网络利用多层互连节点来学习高维数据与低维特征之间的双向非线性的映射关系。我们在深度网络的基础上架构了一种学习流程,如图 2 所示,在统一的深度网络的框架下实现了图像的特征提取、非线性映射以及分类的目的。网络结构是用一个输入层 $v \in \mathbb{R}^D$ 将不同分辨率的图像通过简单的差值方法处理成统一大小的图像进行训练或测试;在 3 个隐含层 h^1, h^2, h^3 逐层提取图像特征;在模型的最顶层加入了一个线性的逻辑回归层 Label,用来将图像特征映射到相应的类别信息上。通过最小化输出图像的类别和标记数据之间的交叉熵,采用 Back-Propagation 算法对整个模型的参数进行全局的调整。



深度信念网络是由可视节点、隐含节点以及标签这 3 个主要的模块组成。标签单元是线性的,而其他两个是逻辑模型的。交叉熵用来估计预测值和标签的相关性。

图 2

网络的主要架构模块是一个二分的无向图,称为受限玻尔兹曼机(RBM)。一个 RBM 的两层节点之间是全连的,然而同一层之间没有连接关系。如果一个神经网络有 5 个甚至更多的隐含层,则其与只有一个隐含层的网络相比在性能方面是没有更多优势的^[6]。因此,构建了具有 3 个 RBM 的神经网络。每层的节点个数依据数据集的不同进行了预定义。Hinton^[11]在 2006 年提出了一种快速的、非监督的贪婪逐层算法来学习 RBM 中成百上千的权重系数。该算法的时间复杂度与每个隐含层的节点个数线性相关,这是 RBM 压倒性的优势。深度架构与贪婪学习算法共同使得提出的模型能够有效地找到不同形态的人脸图像共享的特征空间。这些共享的线性、非线性特征表达也是近代算法^[1,4,5]在 AFR 应用方面取得成功的关键。

生成模型 RBM 通过非监督的误差重建方法进行参数初始化,我们在模型的顶层放置一个线性的逻辑回归层,目的是将原本的生成模型改造成一个判别模型来进行人脸图像的识别。我们利用网络的预测和标签之间的交叉熵,来验证不同变化下图像的相关性;然后,通过最小化交叉熵值,即最大化不同 ID 下图像之间的相关性,采用 BP 算法微调了回归层以及所有 RBM 的权重。

3 深度学习

首先应用逐层的贪婪算法^[11]来学习 RBM 的初始权重,预训练图像与特征之间的映射关系。这些网络系数通过预测 ID 与标签之间的误差,利用标准 BP 来进行微调。

3.1 受限玻尔兹曼机

RBM 是一种马尔科夫随机场(MRF),拥有两层架构。其中一层是可视的随机二值节点 $v \in \{0, 1\}^D$,与之相连的是另一层隐含节点 $h \in \{0, 1\}^F$ 。 $\{v, h\}$ 的能量函数定义为:

$$E(v, h; \theta) = -v^T W h - b^T v - a^T h \quad (1)$$

其中 $\theta = (W, a, b)$ 是网络的参数空间。 W 表示可视节点与隐含节点之间的对称互连项, a 和 b 是偏差项。可视节点的边缘分布为:

$$P(v; \theta) = \frac{1}{Z(\theta)} \sum_h \exp(-E(v, h; \theta)) \quad (2)$$

其中 $Z(\theta)$ 为归一化常数。由于每一层的节点之间没有直接相连,因此样本的概率分布由相互独立的节点概率的乘积组成。通过最大化似然函数得到 RBM 的参数更新:

$$L(\theta) = \sum_{i=1}^n \log P(v^{(i)}; \theta) \quad (3)$$

采用文献[9]中的变分方法,计算对数似然函数对模型参数集 θ 的导数。参数则按照如下公式进行更新:

$$\frac{\partial P(v; \theta)}{\partial W} = E_{data} [v h^T] - E_{model} [v h^T] \quad (4)$$

$$\frac{\partial P(v; \theta)}{\partial a} = E_{data} [h] - E_{model} [h] \quad (5)$$

$$\frac{\partial P(v; \theta)}{\partial b} = E_{data} [v] - E_{model} [v] \quad (6)$$

其中 $E[\cdot]$ 表示期望。利用训练数据作为模型的初始状态,然后运行有限步的吉布斯采样来产生文献[11]中的期望估计。

3.2 参数微调

我们在 3 个 RBM 上面增加一层逻辑回归层,在这一层上将所有图像的特征映射成对应的类别信息熵,尽可能地使回归层的预计标签与目标标签最大相关。交叉熵方法最早由 Rubinstein 引入,用来估计复杂随机网络中稀有事件发生的概率。该方法用来解决稀有事件发生概率的估计问题,是一种使估计的方差达到最小的算法。与交叉熵相比,基于误差平方和最小化准则(MSSE)的 BP 神经网络并不适合解决小概率事件的分类、识别问题,这是最小化交叉熵的优势。BP 神经网络作为一种非线性建模方法,网络的输出是目标类别事件的后验概率;而传统的以误差平方和最小化为准则的 BP 神经网络是在目标输出满足正态分布条件下导出的,在识别问题中不符合正态分布,故该方法不是最合理的。因此,我们将交叉熵作为相关性的度量方法,目标函数如下:

$$E = - \sum_i F(v_i; W) \log t_i - \sum_i (1 - F(v_i; W)) \log (1 - t_i) \quad (7)$$


其中, $F(v_i; W)$ 记作由深度网络在参数 W 下产生的预判结

果,而 t_i 是 i^{th} 的目标标签。激活函数本身是模拟生物特征,从数学上讲是将一个空间映射到另一个空间。训练人脸识别这样的系统需要大量的标记数据,相应的神经网络也需要多层的非线性的处理。本文模型的最顶层增加一层逻辑回归层的目的是将所有图像的特征映射到其对应的类别信息上。那么,一个原本的生成模型在加入逻辑回归以后,可以被当成一个判别模型使用。与回归层的作用不同,前面的 RBM 是用来训练模型以产生一个好的初值,因此采用了不同的激活函数。接下来,通过最小化交叉熵对最顶层的参数进行如下更新:

$$\Delta W = h_3^T \times (l - t) \quad (8)$$

其中, l 代表通过 RBM 堆栈获得的输出特征, $h_3 \in \mathbb{R}^{N \times 2000}$ 表示第三层网络, $(l - t) \in \mathbb{R}^{N \times 68}$ 表示网络的输出结果和真实标签之间的误差, N 表示训练图像的个数。图 3 是一个 RBM 模型。相似地,第 j 个 RBM 的参数调整为:

$$\Delta W_j = h_{j-1}^T \times ((h_{j+1} \times W_{j+1}^T) \times h_j \times (1 - h_j)) \quad (9)$$



$h \times W^T$ 得到的是下一层节点的值, \times 运算代表矩阵的元素的平方

图 3 简单的 RBM

4 实验结果

在 CMU-PIE 数据库^[10]上,针对 3 种不同人脸图像的变化(即表情变化、分辨率变化以及姿态变化)进行了丰富而详细的实验。其中表 1 列出了 CMU-PIE 数据库中的 68 个目标,13 种不同姿态以及 3~4 种表情变化。FERET 库上的表情变化比较有限,而 ORL 和 UMIST 库上的目标规模较小。相比之下,CMU-PIE 是一个包含因素丰富、采集条件真实、在人脸识别方面应用较广泛的数据库。因此,我们提供了在拥有更大角度的姿态变化、更丰富的表情变化以及更大目标规模的 CMU-PIE 库上综合全面的实验。Huang^[1] 和 Li^[5] 的方法将姿态变化引起的非线性引入到不同的几何结构中,并且取得了较好的性能。

搭建了一个深度网络,输入为 36×36 大小的节点单元数,输出为 68 个目标单元。回归层和输出层的节点个数相同,即为 CMU-PIE 中的目标 ID 总数。隐含层的单元个数分别是 1000、500 和 2000。这些实验参数是经过多次实验后进行配置的,而且性能相对稳定。对于下面的几组实验,均使用相同的深度结构(36×36 -1000-500-2000-68)。

表 1 CMU-PIE 数据库的概况

Database	Subjects	Poses	Images per Person per Pose	Total
CMU-PIE	68	13	3~4	2987

4.1 表情实验

这组实验用来验证当测试集中的表情变化没有出现在训练集中时本算法的识别效果。CMU-PIE 数据集中,每个人每个姿态有 3~4 张不同表情的图像。先从中随机选取 2~3 张作为训练集,其余作为测试集。测试图像集(Probe)中的测试图像被统一降采样到 8×8 大小的分辨率,并同时在参考图像集(Gallery)中去相应的高分辨率图像,保证了测试集与训

练集之间没有交集。不同分辨率的图像统一差值成 36×36 , 用于模型训练。表情实验分为两组, 分别是 2110 张训练图像 (记作“test-1”) 和 1233 张训练图像 (记作“test-2”)。“test-”后面的数字表示将每个人每个姿态下, 选取不同表情个数的图像作为测试图像。首先, 通过预训练一个结构为 36×36 -1000-500-2000-68 的深度网络来获得一组原始的标签概率信息, 然后通过 BP 算法最小化模型得到的输出标签概率和真实图像的标签之间的交叉熵, 微调整个模型的参数空间。将测试图像在 Huang^[1] 的算法、Li^[5] 的 CLPM 算法以及本模型中进行实验对比。

图 4 示出了 3 种不同方法对于两个测试子集的表情变化所带来的非线性差异的处理能力, 通过计算累积识别正确率, 其中排名 k 意味着一张测试图像是从 k 个最相似的图像中被正确识别的可能性, 可以得出下面的结论。




图 4 左: 测试当输入图像有不同表情变化时的累积分辨率结果
右: 一个人在固定姿态下的不同表情图像

本文方法在姿态变化的处理能力上表现出明显的优势。在排名 10 的情况下基于深度网络的方法达到了 90% 的识别率, 在相同情况下高于 CLPM 73%, 高于 Huang 20%。CLPM 在排名 1 时与 DBN 的方法结果相近, 但是两种方法之间的差距随着排名的增加逐渐拉大。这种现象可以解释为, 深度网络发现非线性结构的能力优于局部线性的 CLPM^[5], 也优于线性组合 Huang^[1] 的方法。尽管 Huang 的方法在 FERET 和 UMIST 中取得了不错的成绩, 但其在该实验中的表现较弱, 在排名 10 的情况下两组实验结果只有 26.5% 和 14.3%。CMU-PIE 中的显著姿态变化打破了 Huang 方法中对 PCA 和 CCA 的全局线性假设。

4.2 分辨率实验

设计这组实验的目的是为了观察输入图像的分辨率对网络识别能力的影响。使用与上面“test-1”实验相同的网络配置, 但是输入的测试图像有多种不同的分辨率。测试了 3 组图像, 分辨率大小通过降采样分别变为 8×8 、 16×16 、 28×28 。

图 5 显示了 3 种方法针对不同分辨率得到的累积识别正确率。从折线图中可以看出, 当分辨率改变时, 除了从 8×8 增加到 16×16 、在排名 1 的情况下识别率有 3% 的提高以外, 其他情况下的识别率基本保持不变, 也就是说 DBN 方法对分辨率的变化不敏感。CLPM 的结果显示出在分辨率为 16×16 时, 累积识别率平均比 8×8 高出 3 个百分点, 比 28×28 高出 6 个百分点。这个结果说明对于过低的分辨率图像, 容易缺失有效的识别信息; 对于过高的分辨率图像, 较多的识别细节影响了算法的性能。在排名不大于 4 的情况下, Huang 的方法的识别率对分辨率变化不敏感, 但是低至 10%。除了识别率以外, 本文方法的训练过程与 CLPM 和 Huang 的方法也不同。他们的方法中低分辨率-高分辨率成对地出现在训练

集中, 目的是为了找到由训练对共享有的特征空间。因此, 在这组实验中, 他们不得不针对不同的分辨率运行多次实验。相反, 本文将不同的分辨率图像一起混入网络, 即可使网络学习不同分辨率之间的特征关系。




图 5 左: 测试当输入图像分辨率大小不同时的累积分辨率结果
右: 不同分辨率下的图像

4.3 姿态实验

在这组实验中, 验证了当测试集中的姿态不存在于训练集中时, DBN 的处理能力。模型结构和训练策略与表情实验组、分辨率实验组设置一致。我们对每个人从 13 种姿态中选择具有代表性的姿态标号分别为“02”、“07”、“14”作为测试姿态, 如图 6 所示。利用其余姿态的图像训练深度网络, 并将测试的图像降采样到 8×8 大小。




图 6 左: 选择姿态标号为“02”、“07”以及“14”作为测试集, 同时在训练集中去除相应的图像得到的累积分辨率结果。
右: 一个人在相同表情下的不同姿态图像

图 6 示出了 3 种方法对姿态引起的非线性变化的人脸识别问题的处理能力。当排名为 1 时, “pose07”和“pose14”的实验结果说明 CLPM 的识别率与本文方法接近。本文方法获得了较高的识别率尤其是在排名大于 3 的情况下。Huang 的方法在这组实验中的性能落后于 CLPM 和 DBN。当训练集中的姿态和测试集中的姿态之间差异性较大时, 对姿态变化的表现能力会受到显著的影响^[1]。从整体来看, 图 6 中的姿态实验组的结果低于图 4 中的表情实验和图 5 中的分辨率实验, 因为姿态这种非线性变化会显著降低 AFR 的识别性能。但是, 我们的方法与 CLPM 和 Huang 的相比, 在姿态实验中的结果与表情实验、分辨率实验中存在了明显的优势。例如, 图 6 显示在排名 10 的情况下, 针对 3 种不同的姿态, 本文方法都比 CLPM 高出多于 20% 的识别率, 而图 4 和图 5 中只有 10% 的优势。这组实验证明了对于非线性的显著的姿态变化情况, DBN 具有稳定的特征描述能力。

4.4 时间复杂度

在本实验中, 本方法与 Huang、CLPM 两种方法进行了训练代价的比较。表 2 列出了每种方法在表情实验、分辨率实验、姿态实验中的运行时间。表情实验中的“test-1”的训练配置与分辨率实验是一致的, 不同的是测试图像的分辨率大

小。因此二者的训练代价差别不大,而姿态实验的训练代价比较大。Huang 和 CLPM 方法是本文方法的 1~13 倍,而 CLPM 方法的训练代价的增长相对稳定。基于以上实验结果,本文方法达到了最好的识别效果和最小的训练代价。

表 2 时间复杂度

方法	表情实验	分辨率实验	姿态实验
DBN	0.42	0.41	0.49
Huang	1.38	1.33	1.97
CLPM	5.61	5.52	5.68

结束语 本文提出了一种基于深度神经网络的方法来消除包括表情变化、分辨率变化以及姿态等多种变化形态对人脸识别的影响。在 RBM 堆栈的顶层增加了一个回归层,用来在一个统一的深度学习框架下完成特征提取以及分类两种任务。网络中大量参数通过无监督的误差重建方法进行初始化,随后最小化网络的输出特征与标签之间的交叉熵,通过 BP 算法来调整网络参数。在 CMU-PIE 数据库上的实验结果表明 DBN 方法相比其他人脸识别方法有更优秀的表现。在未来的工作中,我们将基于深度神经网络的方法对姿态变化的人脸识别进行更加深入的研究。

参 考 文 献

- [1] Huang H, Zeng X. Super-resolution method for multi-view face recognition from a single image per person using nonlinear mappings on coherent features [J]. IEEE Signal Processing Letters, 2012, 19(4): 195-198
- [2] Zou W, Yuen P. Very low resolution face recognition problem [C]//IEEE Transactions on Image Processing, 2012
- [3] Zhang X, Gao Y. Face recognition across pose. A review [J]. Pattern Recognition, 2009, 42(11): 2876-2896
- [4] Huang H, He H. Super-resolution method for face recognition using nonlinear mappings on coherent features [J]. IEEE Transactions on Neural Networks, 2011, 22(1): 121-130
- [5] Li B, Chang H, Shan S, et al. Low-resolution face recognition via coupled locality preserving mappings [J]. IEEE Signal Processing Letters, 2010, 17(1): 20-23
- [6] Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks [J]. Science, 2006, 313(5786): 504-507
- [7] Salakhutdinov R, Hinton G E. Learning a nonlinear embedding by preserving class neighbourhood structure [J]. International Conference on Artificial Intelligence and Statistics, 2007, 3: 412-419
- [8] Zhou S, Chen Q, Wang X. Discriminative deep belief networks for image classification [C]//ICIP. 2010: 1561-1564
- [9] Mohamed A R, Dahl G, Hinton G. Deep belief networks for phone recognition [C]//NIPS Workshop on Deep Learning for Speech Recognition and Related Applications. 2009
- [10] Sim T, Baker S, Bsat M. The CMU pose, illumination, and expression(pie) database [C]//Proceedings of International Conference on Automatic Face and Gesture Recognition, 2002: 46-51
- [11] Hinton G E, Osindero S, Teh Y-W. A fast learning algorithm for deep belief nets [J]. Neural Computation, 2006, 18(7): 1527-1554
- [12] Huang G B, Lee H, Learned-Miller E. Hierarchical representations for face verification with convolutional deep belief networks [C]//Proceedings of International Conference on Computer Vision and Pattern Recognition(CVPR). 2012: 2518-2525
- [13] 何加浪, 张宏. 神经网络在软件多故障定位中的应用研究[J]. 计算机研究与发展, 2013, 50(3): 619-625
He Jia-lang, Zhang Hong. Application of artificial neural network in software multi-faults location [J]. Journal of Computer Research and Development, 2013, 50(3): 619-625
- [14] 周旭东, 陈晓红, 陈松灿. 半配对半监督场景下的低分辨率人脸识别[J]. 计算机研究与发展, 2012, 49(11): 2328-2333
Zhou Xu-dong, Chen Xiao-hong, Chen Song-can. Low-Resolution face recognition in semi-paired and semi-supervised scenario [J]. Journal of Computer Research and Development, 2012, 49(11): 2328-2333
- [15] Andrew G, Arora R, Bilmes J, et al. Deep Canonical Correlation Analysis [J]. JMLR W&CP, 2013, 28(3): 1247-1255
- [16] Le Q V, Ngiam Ji-quan, Chen Zheng-hao, et al. Tiled convolutional neural networks [C]//NIPS. 2010
- [17] Zhu Zhen-yao, Luo Ping, Wang Xiao-gang, et al. Deep Learning Identity-Preserving Face Space [C]//ICCV 2013. 2013: 113-120
- [18] Kan Mei-na, Shan Shi-guang, Chang Hong, et al. Stacked Progressive Auto-Encoders for Face Recognition Across Poses [C]//CVPR 2014. 2014: 1883-1890
- [19] 胡石, 李光辉, 卢文伟, 等. 基于神经网络的无线传感器网络异常数据检测方法 [J]. 计算机科学, 2014, 41(11A): 208-211
Hu Shi, Li Guang-hui, Lu Wen-wei et al. Outlier Detection Methods based on Neural Network in Wireless Sensor Networks [J]. Computer Science, 2014, 41(11A): 208-211
- [20] 刘遵, 郭力, 红肖辉, 等. 基于参数动态调整的动态模糊神经网络的软件可靠性增长模型 [J]. 计算机科学, 2013, 40(2): 186-190
Liu Lu, Guo Li, Hong Xiao-hui, et al. Software reliability growth model based on dynamic fuzzy neural network with parameters dynamic adjustment [J]. Computer Science, 2013, 40(2): 186-190
- [1] Huang H, Zeng X. Super-resolution method for multi-view face recognition from a single image per person using nonlinear mappings on coherent features [J]. IEEE Signal Processing Letters, 2012, 19(4): 195-198
- [2] 蒋宗礼. 人工神经网络导论[M]. 北京: 高等教育出版社, 2001
Jiang Zong-li. Introduction to artificial neural networks [M]. Bei Jing: Higher Education Press, 2001
- [3] Hinton G, Salakhutdinov R. Reducing the dimensionality of data with neural networks [J]. Science, 2006, 313(5786): 504-507
- [4] Le Q V, Ranzato M A, Monga R. Building high-level scale unsupervised learning [C]//International Conference on Acoustics, Speech and Signal Processing. Vancouver, Canada, 2013: 8595-8598
- [5] Krizhevsky A, Sutskever I, Hinton G. Imagenet classification with deep convolutional neural networks [C]//Advances in Neural Information Processing Systems. California, America, 2012: 1106-1114
- [6] Zeiler M D, Fergus R. Visualizing and Understanding Convolutional Neural Networks [J]. arXiv: 1311. 2901, 2013
- [7] 朱明, 武妍. 基于深度网络的图像处理研究[J]. 电子技术与软件工程, 2014(5): 101-102
Zhu Ming, Wu Yan. Image processing research based on deep networks [J]. Electronic Technology and Software Engineering, 2014(5): 101-102
- [8] Bengio Y. Learning deep architectures for AI [J]. Foundations and Trends® in Machine Learning, 2009, 2(1): 1-12

(上接第 60 页)

Tan Lu. The theory and application of the dimension reduction on the high-dimensional data set [D]. Changsha: National university of defense technology, 2005

- [2] 蒋宗礼. 人工神经网络导论[M]. 北京: 高等教育出版社, 2001
Jiang Zong-li. Introduction to artificial neural networks [M]. Bei Jing: Higher Education Press, 2001
- [3] Hinton G, Salakhutdinov R. Reducing the dimensionality of data with neural networks [J]. Science, 2006, 313(5786): 504-507
- [4] Le Q V, Ranzato M A, Monga R. Building high-level scale unsupervised learning [C]//International Conference on Acoustics, Speech and Signal Processing. Vancouver, Canada, 2013: 8595-8598

- [5] Krizhevsky A, Sutskever I, Hinton G. Imagenet classification with deep convolutional neural networks [C]//Advances in Neural Information Processing Systems. California, America, 2012: 1106-1114
- [6] Zeiler M D, Fergus R. Visualizing and Understanding Convolutional Neural Networks [J]. arXiv: 1311. 2901, 2013
- [7] 朱明, 武妍. 基于深度网络的图像处理研究[J]. 电子技术与软件工程, 2014(5): 101-102
Zhu Ming, Wu Yan. Image processing research based on deep networks [J]. Electronic Technology and Software Engineering, 2014(5): 101-102
- [8] Bengio Y. Learning deep architectures for AI [J]. Foundations and Trends® in Machine Learning, 2009, 2(1): 1-12