

# 基于人工智能与机器学习技术在智慧城市的应用

郑永亮, 李晓坤, 王琳琳, 陈虹旭, 杨磊  
(黑龙江恒讯科技有限公司, 哈尔滨 150090)

**摘要:** 在城镇化进程不断加速的今天,智慧城市越来越被人们所重视。智慧城市的发展离不开人工智能,而机器学习是人工智能领域的一个重要分支,将人工智能与机器学习技术应用于智慧城市,可以解决城市发展所面临的诸多难题,让居住在城市的人们生活更加美好。本文以图像识别中的人脸识别和步态识别为例,阐述人工智能与机器学习技术在智慧城市中的应用,以期通过本文为智慧城市的继续建设提供思路和借鉴。

**关键词:** 人工智能; 机器学习; 人脸识别; 步态识别; 智慧城市

## Application of artificial intelligence and machine learning technology in smart city

ZHENG Yongliang, LI Xiaokun, WANG Linlin, CHEN Hongxu, YANG Lei  
(Heilongjiang Hengxun Technology Co. Ltd., Harbin 150090, China)

**[Abstract]** Today, as the urbanization process continues to accelerate, smart cities are increasingly being valued by people. The development of smart cities is inseparable from artificial intelligence, and machine learning is an important branch of artificial intelligence. Applying artificial intelligence and machine learning technology to smart cities can solve many problems faced by urban development and enable people live better in cities. This paper takes face recognition and gait recognition in image recognition as an example to illustrate the application of artificial intelligence and machine learning technology in smart cities, in order to provide ideas and reference for the continued construction of smart cities.

**[Key words]** artificial intelligence; machine learning; face recognition; gait recognition; smart city

## 0 引言

智慧城市是基于物联网、云计算、人工智能等技术而形成的一种新型智能化、信息化的城市形态。在智慧城市建设中利用人工智能与机器学习建设智慧化、智能化、信息化的现代城市,不仅是一种技术手段,更是一种颠覆性思维。要想将中国建设成为网络强国、数字中国和智慧社会,智慧城市便是重要抓手和综合载体,而人工智能与机器学习技术在智能城市中的应用则起着重要的支撑作用。

## 1 人工智能与机器学习概述

### 1.1 人工智能

随着互联网的普及,传感器的普遍存在,大数据的出现,电子商务的发展,信息社区的兴起,数据与知识在社会、物理空间和网络空间的互联与融合,围绕人工智能发展的信息环境发生了深刻的变化,导致了一个新的进化阶段——人工智能 2.0<sup>[1-2]</sup>。现

阶段的人工智能更加侧重于与人类生活紧密结合,并成为人类生活中的一部分。

新技术的出现将人工智能提升到了一个新的阶段。人工智能的目标也发生了巨大的变化,从追求使用计算机模拟人类智能转变为:

- (1) 结合机器和人类增强的混合智能系统;
- (2) 由机器、人类和网络组织的新的人群智能系统;
- (3) 更复杂的智能系统,如融合人类、社会、物理和网络系统的智能城市。

本文中所提及的人工智能是指人工智能中的图像识别技术。

### 1.2 机器学习

通常,机器学习定义为计算机利用经验自动改善系统自身性能的行为。<sup>[3]</sup>机器学习其主要的工作就是提取出主要的特征后根据已有的经验、数据或实例构造从特征到标签的映射。机器学习是人工智能领域最能体现智能的一个分支,也许不是人工智

**基金项目:** 中小企业创新基金(2017FF1GJ023); 专利优势示范企业基金(2017YBQCZ029); 国家自然科学基金(81273649)。

**作者简介:** 郑永亮(1985-),男,学士,工程师,主要研究方向:虚拟化、人工智能、生物特征识别等; 李晓坤(1979-),男,研究员级高级工程师,教授,硕士生导师,系统集成高级项目经理,CCF 高级会员,主要研究方向:虚拟化、人工智能、生物特征识别等。

**通讯作者:** 李晓坤 Email: li.xiaokun@163.com

**收稿日期:** 2018-10-09

能中最为高端的技术,但却是人工智能领域最不可或缺的技术。机器学习拥有高度发达的感知能力和强大的并行信息处理能力,在智慧城市建设的应用中取得了很大的进展,运用于图像识别、语音识别等领域并取得了令人瞩目的成就。

### 1.3 深度学习

深度学习,也就是英文中常说的 Deep Learning,直观地说,深度学习就是不需要人参与特征的选取过程。深度学习作为近年来研究的热门领域,在图像识别、目标检测、自然语言处理等领域取得了较大的成功<sup>[5]</sup>。深度学习较机器学习来说具有更广泛的应用领域,极大地拓展了人工智能的应用范围<sup>[6]</sup>。

深度学习的框架主要有3种:深度卷积神经网络(CNN)、深度置信网络(DBN)、堆栈自编码器(SAE)<sup>[7]</sup>。深度学习的实质,是通过构建包含多个隐层的机器学习模型<sup>[8]</sup>与大量的数据<sup>[9]</sup>进行训练,从而来获取更加有用的特征,使得预测和分类的准确性得以提高。

## 2 人工智能与机器学习技术在智慧城市中的应用

在建设智慧城市的进程中,伴随着人工智能领域中图像识别技术运用领域的不断扩展,图像识别发挥着越来越重要的作用,人脸识别<sup>[11]</sup>、步态识别<sup>[12]</sup>、车牌识别<sup>[13]</sup>、指纹识别<sup>[14]</sup>等都属于这一范围。本文以图像识别中较具代表性的人脸识别与步态识别为例,来阐述人工智能与机器学习技术在智慧城市中的应用。

### 2.1 步态识别

#### 2.1.1 步态识别概述

步态识别是通过对人走路的姿势和形态可在远距离非受控状态实现对个人身份的识别和认证。早期的医学研究表明:人的步态中有24种不同的成分,如果把这24种不同成分都考虑到,则步态是为个体所独有的<sup>[15]</sup>,相互比于虹膜识别、指纹识别等传统的识别方式来说,步态识别具有相对唯一、不易伪装、不需客体配合、真实自然等优点<sup>[16]</sup>。由于以上优点,步态识别在智慧城市的诸多领域具有更加广泛的应用前景。

步态识别通常通过步态检测、步态特征提取等过程来进行个体识别,可以认为步态识别就是对包含人体运动的图像序列进行分析与处理,从而来提取步态特征<sup>[17-18]</sup>。步态识别流程如图1所示。

#### 2.1.2 步态识别的应用

首先,步态识别应用于安防领域。作为新兴的

生物特征识别技术,应用于视频监控领域,将会在社会治安、案件侦查、反恐等领域发挥重大作用,可以更加快速地对嫌疑人进行判断。其次,步态识别应用于财产安全领域。对于贵重物品的保管,在加入步态识别技术后,物品内的传感器将根据来者的步态判断此人是否会对物品构成威胁从而是否发出警报。最后,步态识别应用于医学领域。由于健康的人走路的姿态和不健康的人走路会有差别,通过步态识别,可以判断出人的身体是否健康,若不健康,可以判断出是身体哪个部位出现了问题。

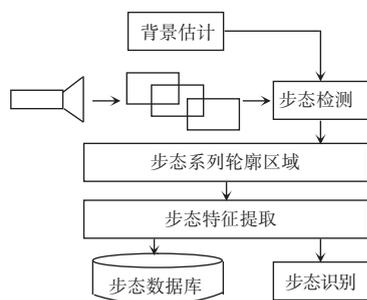


图1 步态识别流程

Fig. 1 Overall process of gait recognition

### 2.2 人脸识别

#### 2.2.1 人脸识别的应用

人脸识别作为一种重要的身份鉴别方法,在许多领域都有着广泛的应用。首先,人脸识别应用于安防领域。目前,社会中大量监控的高清普及,为人脸识别应用提供基础。在案发之后利用视频录像对嫌疑人面部特征进行提取,通过酒店、网吧、出租屋、汽车站、火车站、广场、交通要道等场所进行在逃犯实时布控需求,利用人脸卡口轨迹线索分析能有效定位嫌疑人员。其次,人脸识别应用于金融领域<sup>[19]</sup>。随着支付方式日新月异,二维码等收付款方式有可能存在不安全,或者不能满足人们需求等的缺点。相比之下,刷脸支付<sup>[20]</sup>的支付方式具有的安全性、唯一性的优点被人们逐渐重视起来,在将来,刷脸支付可能会成为新的支付方式。再次,人脸识别应用于门禁管理<sup>[21]</sup>。门禁系统对于安全的居住环境至关重要,由于人脸识别具备的唯一性和不易被复制的特性为身份鉴别提供了良好的前提,通过对人脸的识别作为开门的前提,小区住户可通过门禁系统对人脸的识别作为开门的钥匙,保证了住户的安全,同时也免去了忘记带钥匙的不便。最后,人脸识别应用于考勤管理。人脸识别可以提高考勤管理的效率,通过事先的信息采集,在员工上下班的过程中,考勤机会自动对其进行记录,节省了员工排队打卡的时间,同时也可以避免弄虚作假情况的发生。

### 2.2.2 人脸识别的应用模式

当前人脸识别有 3 种应用模式: 1 : 1 人脸识别、1 : N 人脸识别、M : N 动态布控。1 : 1 识别就是对目前所出现的人脸与数据库中的人像进行快速对比, 进而得出匹配的过程, “刷脸” 登机、验票、支付都属此类; 1 : N 是在海量的人像数据库中找出当前用户的人脸数据并进行匹配, 即从 N 个人脸中找出 1 个目标; M : N 是通过计算机对目标区域内的所有个体进行人脸对比, 并与人像数据库中的样本进行动态人脸对比, 可以应用于黑名单监控、VIP 客户管理系统、校园人脸识别系统等多种场景。

## 3 人脸识别与步态识别融合相关技术介绍

### 3.1 DBN 深度置信网

DBN 是由多个限制波尔兹曼机 (RBM) 堆叠而成<sup>[22]</sup>。RBM 作为深度信念网络的组成元素, 由 2 层结构组合而成, 分别称之为显层和隐层, 层与层之间网络单元是互相连接的, 但是层内单元并无连接, 其结构如图 2 所示。通常假设其所有节点的取值都是 0 或 1, 同时假设全概率分布满足 Boltzmann 分布, 则该模型为限制波尔兹曼机模型<sup>[23-25]</sup>。

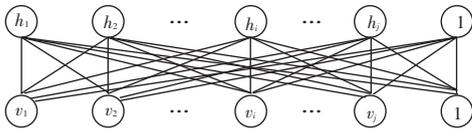


图 2 RBM 结构示意图

Fig. 2 Schematic diagram of RBM structure

RBM 模型显层和隐层都服从伯努利分布, 因此, 其能量表达式为:

$$E(v, h; \theta) = - \sum_{ij} w_{ij} v_i h_j - \sum_i b_i v_i - \sum_j a_j h_j$$

其中,  $\theta = \{W, a, b\}$  为该模型的参数。

RBM 的联合分布可以表示为:

$$P_{\theta}(v, h) = \frac{1}{Z(\theta)} \exp(- E(v, h; \theta)) =$$

$$\frac{1}{Z(\theta)} \prod_{ij} e^{w_{ij} v_i h_j} \prod_i e^{b_i v_i} \prod_j e^{a_j h_j}$$

$$Z(\theta) = \sum_{h, v} \exp(- E(v, h; \theta))$$

RBM 的显层和隐层对应的条件概率可表示为:

$$P(h_j = 1 | v) = \frac{1}{1 + \exp(- \sum_i w_{ij} v_i - a_j)}$$

$$P(v_i = 1 | h) = \frac{1}{1 + \exp(- \sum_j w_{ij} h_j - b_j)}$$

深度置信网是由多个 RBM 和一个 BP 网络堆叠

而成, 输入数据在 DBN 模型中逐层进行数据转换的同时, 不断地对数据的特征进行提取和抽象, 并且剔除冗余的信息, 最后将经过多层数据转换后的特征信息输入顶层 BP 层, 通过 BP 网络利用反向传播算法进行有监督的训练学习, 对整个 DBN 模型进行微调, 从而优化整个模型, 提高 DBN 模型数据抽象的能力, 学习到更精确的特征。深度信念网络示意如图 3 所示。

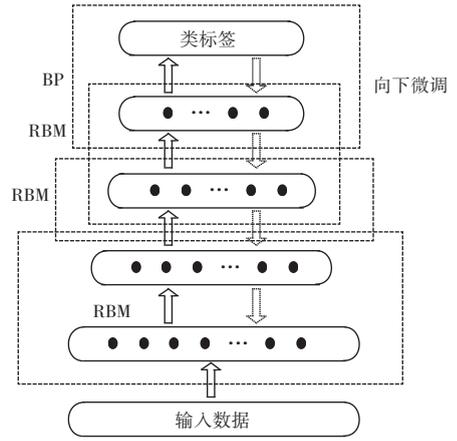


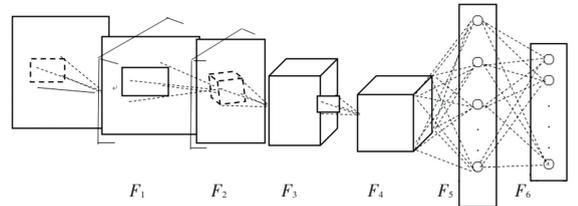
图 3 深度信念网络示意图

Fig. 3 Diagram of deep belief network

### 3.2 基于深度卷积神经网络的图像识别

神经网络是将多个神经元连接起来后, 将某个神经元的输出作为下一层神经元的输入, 图 4 是一个具有一层隐藏层的神经网络。其中  $x, L, x_j, L, x_d$  表示输入向量  $X$  的每一维,  $W_{i,j}^{(1)}$  表示输入层的第  $j$  个元素与第一隐藏层的第  $i$  个神经元连接的权值,  $o(g)$  表示输出层的激发函数, 对于隐层的每个神经元有:

$$a(x)_i = b_i^{(1)} + \sum_j W_{i,j}^{(1)} x_j$$



输入层	卷积层 $C_1$	池化层 $S_1$	卷积层 $C_2$	池化层 $S_2$	全连接层 $FCL_5$	神经网络输出层
一张训练图像	$F_1$ 个提取的 map 特征	$F_2$ 个提取的 map 特征	$F_3$ 个提取的 map 特征	$F_4$ 个提取的 map 特征	$F_5$ 个神经元	$F_6$ 个神经元

图 4 深度卷积神经网络框架图

Fig. 4 Deep convolutional neural network framework

写成矩阵式即:

$$a(x) = b^{(1)} + W^{(1)} X$$

隐层的激发函数:

$$h(X) = g(a(X))$$

因此, 可以计算出输出层的结果:

$$f(X) = o(b^{(2)} + W^{(2)r} h^{(1)}(X))$$

由此可以推广到具有多层隐层的神经网络。

卷积神经网络包括卷积层、池化层和全连接层,并具有稀疏连接和权值共享的特征。

在图像采集的过程中,步态图像或人脸图像的某些部分的特征也许会出现于其它位置,为了得到新的特征映图,通常使用一个卷积核对输入的一张图片进行卷积操作。相对应的利用图像局部相关性原理,实现下采样操作。

卷积的计算公式为:

$$y_i = f\left(\sum_{ieM} x_i * k_i + b_p\right)$$

其中,  $x_i$  代表在  $x$  位置  $i$  上的输入特征图的数值;  $k_i$  为卷积核在位置  $i$  上的参数值;  $b_p$  为偏置项,  $M_j$  为用来计算卷积操作的输入特征图对应位置的集合;  $y_i$  表示输出特征图在  $p$  上的数值;  $f(\cdot)$  表示激活函数。因为 *sigmoid* 函数和修正线性单元具有较高的诊断精度,所以通常采用 *sigmoid* 函数或修正线性单元激活函数。数学表达式分别为:

$$S(X) = \frac{1}{1 + e^{-X}}$$

$$f(x) = \max(x, 0)$$

池化的计算公式为:

$$Y_i = \text{down}_{ieM}(X_i)$$

其中, *down* 是下采样操作。

全连接的计算公式为:

$$Y = f(P * x + b)$$

其中,  $P$  是一个矩阵,  $x$  是输入二维特征图的一维向量形式。而且通过全连接能够将特征图映射到任意维度的向量中。

在网络训练过程中, *Softmax Loss* 函数通过损失值的反馈不断对网络参数进行优化,迭代次数不断增加的同时,其损失值也在不断的降低,而训练数据中的类别在实验中也会被慢慢地分离开。由于人脸具有复杂多变的特性,对人脸识别来说, *Softmax Loss* 存在的一个明显的缺点就是对于人脸识别性能来说,虽然能够提高人脸识别的精度,但却不能减少同类别人脸间的距离,这就易使在某些非限定条件下的人脸识别产生误差。对于此问题,中心损失函数 (*Center Loss*)<sup>[26]</sup> 可以实现减少类内距离,使类内距离小于肋间距离。计算公式如下:

$$\text{CenterLoss} = \frac{1}{2N} \sum_{i=1}^N \|x^i - c^j\|^2$$

其中,  $N$  代表训练批次;  $x^i$  表示第  $j$  类中第  $i$  个样本的特征向量;  $c^j$  是第  $j$  类的中心特征向量。每次迭代,  $c^j$  都会进行更新,通过不断进行训练,可以

有效减少类间距离,从而实现减少类内距离的目标。

在进行网络训练时, *Center Loss* 对类别无法区分,只能缩小类内距离。由于这点原因本文将 *Softmax Loss* 和 *Center Loss* 共同使用,从而联合监督网络训练,以期实现减小类内距离的目标。本文中的实验方法是将 *Softmax Loss* 和 *Center Loss* 进行加权,运算公式如下:

$$L = \text{Softmax} + \lambda \text{CenterLoss} =$$

$$\frac{1}{N} \sum_{i=1}^N \left[ \log \sum_{j=1}^F (e^{w_j^T + b^j}) - (w_k^T + a_k) \right] + \frac{\lambda}{2N} \sum_{i=1}^N \|x_i - c_k\|^2$$

其中,前半部分为 *Softmax Loss* 函数;  $F$  代表训练数据的类别总数;  $w$  是最后一个全连接层的权重集合;  $a$  为偏置值;  $\lambda$  为用来平衡这 2 个损失的 *Center Loss* 的权重值。在本文所提出的网络中, *Softmax Loss* 层和 *Center Loss* 层的具体使用方式如图 5 所示<sup>[27]</sup>。

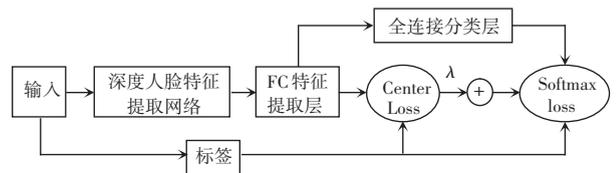


图5 *Center Loss* 与 *Softmax Loss* 在网络中的具体使用方法示意图  
Fig. 5 Sketch diagram of specific use method of *Center Loss* and *Softmax Loss* in the network

基于卷积神经网络,通过使用 *Center Loss* 与 *Softmax Loss*,来平衡人脸识别与步态识别中的偏差,提取出更具区分能力的人脸特征与步态特征,使得人脸识别与步态识别能够更为精准。

## 4 实验结果与分析

本文的实验平台配置为 Intel2.67 GHz CPU、8 GB 内存、操作系统为 Ubuntu 14.04。

### 4.1 步态识别实验结果及分析

#### 4.1.1 实验样本

实验选取中科院的步态数据库 CASIA-B 和 CASIA-C<sup>[28]</sup> 等公开数据集对本文中所提出的方法进行验证。CASIA-B 数据集中包含 124 个个体的行走数据,包括正常的行走、背包行走和穿外套行走。CASIA-C 数据集是夜间拍摄的红外步态图像,包含 153 个个体正常行走、快走、慢走和背包的行走状态。本文从中随机选取了 16 个人正常情况下的水平向左步行数据和 10 个人的背包情况下水平向左步行的行走数据,前者用“*Gait - nm*”表示,后者用“*Gait - bg*”表示。

### 4.1.2 实验细节

在实验中,首先对  $320 \times 240$  像素的原始图像生成归一化的步态轮廓图像,并且将尺寸放缩至  $64 \times 64$  像素来计算步态周期。

本文中提及的实验训练过程包括全连阶层网络与受限玻尔兹曼机。每一 DBN 网络含有输入层、顶层输出与 3 个隐藏层,时序模型包含 3 层网络。在实验中,输入层的数据维度为 15 000,顶层的数据维度为 100,3 个隐藏层结点数分别是 5 000、1 000 与 500,输入层、隐层、输出层均是 100 个节点。所有深网中,RBM 在预测阶段的迭代次数是 300 次,BP 神经网络微调次数为 200,训练时序模型时,对其中 GRBM 和 CRBM 的训练迭代次数均为 2 000 次。

### 4.1.3 实验结论

本文中的实验数据与其它几种方法对比结果见表 1。可以看到,SVM 和 DBN+RBF 的步态序列识别情况较为紊乱,识别率偏低;DBN+SVM 的步态识别率则相对较高;而集成深网相比于其它效果则具有更加明显的优势。

表 1 几种方法的步态序列类别识别对比

Tab. 1 Gait sequence class identification comparison of several methods

方法	Gnit-nm(16 类)		Gnit-bg(10 类)	
	识别类/个	识别率/%	识别类/个	识别率/%
SVM	11	67.75	7	70
DBN+RBF	5	32.25	3	30
DBN+SVM	15	92.75	10	100
集成深网	16	100	10	100

## 4.2 人脸识别实验结果及分析

### 4.2.1 实验样本

选取 CASIA-WebFace<sup>[29]</sup> 作为训练样本,其中包含 10 575 人的约 500 000 张图片。使用此训练库来训练网络,本文在实验中使用公开人脸库 LFW 数据库进行测试,实验测试结果是基于 LFW 数据库中人脸验证任务的 1 000 对正样本和 1 000 对负样本。

### 4.2.2 实验细节

在实验中,对训练样本和测试样本作同样的预处理。首先,采用 MTCNN 算法进行人脸检测和关键点定位;其次,根据关键点的位置进行相似性变换。在进行完以上操作后,对实验中所有的人脸图像裁剪为  $112 \times 96$  的 RGB 图片。

实验的训练参数设定为:初始学习率设置为 0.02,训练批次为 50,权重衰减设置为 0.005,总的迭代次数为 10 万次,最大迭代次数为 5 万次。在实验

过程中,对测试原图进行提取,与水平翻转图的特征进行比对,并提取出最终的比对特征,同时,采用 Cosine 距离计算出相似度。在此过程中与其它方法进行对比和实验。结果数据见表 2。

表 2 其它方法在 LFW 库上的结果对比

Tab. 2 Comparison of results of other methods on the LFW library

方法	训练监督信号	网络个数	人脸关键点	准确率/%
High-dim LBP	N/A	N/A	27	94.38
Fisher vector face	N/A	N/A	9	92.73
DeepFace	Softmax Loss	1	6+67	97.45
本文网络	SoftmaxLoss+ centerLoss	1	5	98.25

### 4.2.3 实验结论

与传统的人脸识别算法相比,本文中所提及的人脸识别算法具有更高、更精准的识别度;同时,将度量学习算法融合其中,提取到了更为精准的人脸特征。本文方法使用了更少的人脸关键点,且有更高的验证识别准确率。

## 5 步态识别与人脸识别共同运用的优势

人脸识别只有当个体与摄像机距离足够近时才能提取到有效的面部特征。而由于人的步态具有唯一性的特征,即使摄像机只能捕捉到分辨率较低的图像,也可以获取足够的步态信息。将人脸识别与步态识别共同运用,可以有效地应对个体与摄像机距离的问题。而且,由于步态与人脸通过摄像机来收集身份信息对传感设备的要求相对较低,同时,步态识别受穿着、负荷的影响较大,但这些因素对人脸识别的影响较小;而人脸识别受化妆、表情、发型的影响较大,但这些因素对步态识别却无甚影响。可以说,步态识别与人脸识别是可以互补的。所以,将步态识别与人脸识别共同运用,可以提高识别的精准度,对建设智慧城市是一项极其有利的举措<sup>[30]</sup>。

## 6 结束语

智慧城市是未来城市发展的主要方向,人工智能和机器学习技术必将在智慧城市中发挥越来越重要的作用,人工智能与机器学习技术在智慧城市各领域的应用必将随着技术的进步和人们对智慧城市间认识的深入而更加广泛地应用,智慧城市、人工智能技术各自蓬勃发展,必将催生新的经济增长点,促进物质文明和精神文明的进步,使中国新型城镇化向着健康、有序的方向发展<sup>[31]</sup>。

## 参考文献

- [1] 郭平,王可,罗阿理,等. 大数据分析中的计算智能研究现状与展望[J]. 软件学报,2015,26(11):3010-3025.
- [2] 曾毅,刘成林,谭铁牛. 类脑智能研究的回顾与展望[J]. 计算机学报,2016,39(1):212-222.
- [3] 张蕾,崔勇,刘静,等. 机器学习在网络空间安全研究中的应用[J]. 计算机学报,2018,41(9):1943-1975.
- [4] 刘焯,汪亚珉,卞玉龙,等. 面向智能时代的人机合作心理模型[J]. 中国科学:信息科学,2018,48(4):376-389.
- [5] 刘全,翟建伟,章宗长,等. 深度强化学习综述[J]. 计算机学报,2018,41(1):1-27.
- [6] 赵星宇,丁世飞. 深度强化学习研究综述[J]. 计算机科学,2018,45(7):1-6.
- [7] 付文博,孙涛,梁藉,等. 深度学习原理及应用综述[J]. 计算机科学,2018,45(6):11-15,41.
- [8] 张蕾,章毅. 大数据分析的无限深度神经网络方法[J]. 计算机研究与发展,2016,53(1):68-79.
- [9] 余凯,贾磊,陈雨强,等. 深度学习的昨天、今天和明天[J]. 计算机研究与发展,2013,50(9):1799-1804.
- [10] 尹宝才,王文通,王立春. 深度学习研究综述[J]. 北京工业大学学报,2015,41(1):48-59.
- [11] 杨长盛,陶亮. 几种机器学习方法在人脸识别中的性能比较[J]. 计算机工程与应用,2009,45(4):169-172.
- [12] 王科俊,侯本博. 步态识别综述[J]. 中国图像图形学报,2007,12(7):1152-1160.
- [13] 郑顾平,闫勃勃,李刚. 基于机器学习的多车牌识别算法应用研究[J]. 计算机技术与发展,2018,28(6):129-132.
- [14] 林静,吴锡生. 基于虚拟样本的改进人脸识别算法研究及应用[J]. 计算机工程与应用,2017,53(23):123-128.
- [15] 薛召军,靳静娜,明东,等. 步态识别研究现状与进展[J]. 生物医学工程学杂志,2008,25(5):1217-1221.
- [16] 柴艳妹,夏天,韩文英,等. 步态识别研究进展[J]. 计算机科学,2012,39(6):10-15,46.
- [17] 王开杰,杨天奇. 基于列质量向量和SVM的步态识别[J]. 计算机工程与应用,2015,51(7):169-173.
- [18] 杨军,吴晓娟,彭彰,等. 基于多区域分割的步态表示与识别算法研究[J]. 计算机学报,2006,29(10):1876-1881.
- [19] 陈卫华,徐国祥. 基于深度学习和股票论坛数据的股市波动率预测精度研究[J]. 管理世界,2018(1):180-181.
- [20] 陈翔,白创,黄跃俊. 基于BP神经网络的人脸识别系统研究[J]. 智能计算机与应用,2018,8(3):57-60.
- [21] 万建武,杨明,吉根林,等. 一种面向人脸识别的加权代价敏感局部保持投影[J]. 软件学报,2013,24(5):1155-1164.
- [22] 张春霞,姬楠楠,王冠伟. 受限波尔兹曼机[J]. 工程数学学报,2015,32(2):159-173.
- [23] 柴瑞敏,倡称称. 一种改进的深度置信网络及其在自然图像分类中的应用[J]. 计算机应用与软件,2016,33(9):221-223,244.
- [24] 周兰,于重重,陈秀新,等. 基于深度卷积限制玻尔兹曼机的步态识别[J]. 计算机工程与设计,2018,39(1):244-248.
- [25] 吕璐,蔡晓东,曾燕,等. 一种基于融合深度卷积神经网络与度量学习的人脸识别方法[J]. 现代电子技术,2018,41(9):58-61,67.
- [26] WEN Yandong, ZHANG Kaipeng, LI Zhifeng, et al. A discriminative feature learning approach for deep face recognition [M]//LEIBE B, MATAS J, SEBE N, et al. Computer Vision-ECCV 2016. ECCV 2016. Lecture Notes in Computer Science. Cham: Springer, 2016:499-515.
- [27] 彭天强,粟芳. 基于深度卷积神经网络和二进制哈希学习的图像检索方法[J]. 电子与信息学报,2016,38(8):2068-2075.
- [28] 贾晔焯,徐森,王科俊. 行人步态的特征表达及识别综述[J]. 模式识别与人工智能,2012,25(1):71-81.
- [29] 李凯,王国超. 融合腿部局部特征的步态识别方法[J]. 计算机工程与设计,2016,37(5):1340-1345.
- [30] YI Dong, LEI Zhen, LIAO Shengcai, et al. Learning face representation from scratch [J]. arXiv preprint arXiv:1411.7923, 2014.
- [31] 戚欣,姜春雷. 人工智能助力智慧城市建设[J]. 智能建筑与智慧城市,2017,9(11):33-37.
- (上接第152页)
- [20] CHEN Weihua, CHEN Xiaotang, ZHANG Jianguo, et al. Beyond triplet loss: A deep quadruplet network for person re-identification [C]// Proc. IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, Hawaii: IEEE, 2017:1320-1329.
- [21] WANG Jian, ZHOU Feng, WEN Shilei, et al. Deep metric learning with angular loss [C]// 2017 IEEE International Conference on Computer Vision. Venice, Italy: IEEE, 2017:2593-2601.
- [22] SONG H O, JEGELKA S, RATHOD V, et al. Deep metric learning via facility location [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, Hawaii, USA: IEEE, 2017: 2206-2214.
- [23] ZHU Pengfei, ZHANG Lei, ZUO Wangmeng, et al. From point to set: Extend the learning of distance metrics [C]// 2013 IEEE International Conference on Computer Vision. Washington, DC, USA: IEEE, 2013:2664-2671.
- [24] WANG Ruipeng, SHAN Shiguang, CHEN Xilin, et al. Manifold-manifold distance and its application to face recognition with image sets [J]. IEEE Transactions on Image Processing, 2012, 21(10):4466-4479.
- [25] LU Jiwen, WANG Gang, DENG Weihong, et al. Multi-manifold deep metric learning for image set classification [C]// 2015 IEEE Conference on Computer Vision and Pattern Recognition. Boston: IEEE, 2015: 1137-1145.
- [26] HUANG Zhiwu, WANG Ruipeng, SHAN Shiguang, et al. Learning Euclidean-to-Riemannian metric for point-to-set classification [C]// 2014 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Columbus, OH, USA: IEEE, 2014: 1677-1684.
- [27] ZHANG Liliang, LIN Liang, WU Xian, et al. End-to-end photo-sketch generation via fully convolutional representation learning [C]// Proc. the 5<sup>th</sup> ACM on International Conference on Multimedia Retrieval. Shanghai, China: ACM, 2015: 627-634.
- [28] LIONG V E, LU Jiwen, TAN Y P, et al. Deep coupled metric learning for cross-modal matching [J]. IEEE Transactions on Multimedia, 2017, 19(6):1234-1244.
- [29] BRONSTEIN M M, BRONSTEIN A M, MICHEL F, et al. Data fusion through cross-modality metric learning using similarity-sensitive hashing [C]// The Twenty-Third IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2010. San Francisco, CA, USA: IEEE, 2010: 3594-3601.