

基于监督学习深度自编码器的图像重构

张 赛¹ 芮 挺^{1,2} 任桐炜² 杨成松¹ 邹军华¹

(陆军工程大学野战工程学院 南京 210007)¹

(南京大学计算机软件新技术国家重点实验室 南京 210023)²

摘 要 针对数字图像受损信息的重构问题,提出一种将经典无监督学习自编码器(Auto-Encoder, AE)用于监督学习的新方法,并对深度模型结构与训练策略进行了研究。通过设计多组监督学习单层 AE 模型,提出了逐组“递进学习”和“关联编码”的学习策略,构建了一个新的基于监督学习的深度 AE 模型结构;对于新模型结构,采用多对一(一个输入样本的多种形式对应一个输出)的训练方法代替经典 AE 中一对一(一个输入样本对应一个输出)的训练方法。将该模型的结构和训练策略用于部分数据受损或遮挡的图像中进行数据重构测试,提高了模型对受损数据特征编码的表达能力和重构能力。实验结果表明,提出的新方法对于受损及遮挡样本的图像具有良好的重构效果和适应性。

关键词 自编码器,监督学习,深度结构,训练策略,图像重构

中图分类号 TP391 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2018.11.042

Image Reconstruction Based on Supervised Learning Deep Auto-encoder

ZHANG Sai¹ RUI Ting^{1,2} REN Tong-wei² YANG Cheng-song¹ ZOU Jun-hua¹

(Department of Filed Engineering, PLA Army Engineering University, Nanjing 210007, China)¹

(State Key Laboratory for Novel Software Technology, Nanjing University, Nanjing 210023, China)²

Abstract Aiming at the reconstruction of the damaged information of digital image, this paper proposed a new approach in which the classical unsupervised auto-encoder(AE) is used for supervised learning, and researched the deep model structure and training strategy. Specifically, this paper presented a novel supervised learning based deep auto-encoder model which possesses a set of progressive and interrelated learning strategies through designing multiple groups of supervised single-layer AE. In the novel model, the one-to-one training strategy in classical AE model (one output corresponding to one input) is substituted by the many-to-one training strategy (one output corresponding to many inputs). Then, the structure and training strategy mentioned above were utilized for the damaged or occluded images to test the process of data reconstruction, thus improving the model's ability to express and reconstruct the feature of those data. Experimental results show that the new method has good reconstruction effect and adaptability to the damaged or occluded samples.

Keywords Auto-encoder, Supervised learning, Deep structure, Training strategy, Image reconstruction

1 引言

数字图像在采集、传输、使用的各个环节都可能产生数据的损坏和信息的丢失,为了保证图像信息的完整性,需要对受损部分进行有效修复。所谓图像修复,就是对图像上的数据缺损区域进行信息填充的过程,其目的是对有信息缺损的图像进行恢复^[1]。SCSB 模型(该模型由 Bertalmio, Sapiro, Caselles 和 Ballester^[2]4 人提出)最先用基于偏微分方程(Partial Differential Equation, PDE)的模型来解决图像修复问题。随后,Chan 等^[3]于 2001 年提出了另一种基于变分原理的图像

修复模型,该模型被称为全变分(Total Variation, TV)模型。Komodakis 等^[4]于 2006 年提出的基于优先权的反向传播算法(Backpropagation Algorithm, BP),将图像修复问题描述成离散全局最优问题。2010 年, Hsin 等^[5]在 BP 传播算法的基础上提出了更全面的修复算法,新方法通过增加边缘信息保证了图像修复的结构性。Mansfield 等^[6]提出利用不同的优化方法进行最优补丁的搜索,最后通过最优补丁进行综合的修补。Kang 等^[7]基于堆叠的去噪自编码对不同角度或姿态的人脸图像进行正面的重构修正。Xie 等^[8]使用深度网络预先训练去噪自动编码器(Denoising Auto-Encoder, DAE)进行

到稿日期:2017-10-11 返修日期:2017-12-27 本文受国家自然科学基金:数据驱动的社会媒体信息传播演化关键技术研究(61473444)资助。

张 赛(1991—),男,硕士生,主要研究方向为机器学习、计算机视觉, E-mail:466908114@qq.com;芮 挺(1972—),男,博士,副教授,CCF 高级会员,主要研究方向为机器学习、计算机视觉, E-mail:rtinguu@sohu.com(通信作者);任桐炜(1981—),男,博士,副教授,主要研究方向为视觉媒体计算;杨成松(1982—),男,博士,讲师,主要研究方向为信息检索、数字图像处理;邹军华(1991—),男,博士生,主要研究方向为机器学习、计算机视觉。

图像修补,但不适合修补大尺度的受损区域。近年来,Pathak等^[9]通过图像语义信息对图像进行修复。Yang等^[10]则是基于卷积神经网络,通过内容和纹理信息推断缺失的信息。Huang等^[11]基于特殊的去噪自编码器和图像重构,构建了一个基于深度的面部识别框架。

目前,深度学习^[12]已成为图像处理领域的研究热点和有效方法^[13-16]。自编码器是深度学习的经典模型之一,它采用无监督学习完成训练,不仅可以通过自学习的方式抽取自身低维的数据结构和表达,还可以通过精简的表达重构出数据信息。然而这种对数据的表达仅限于对所学数据本身固有信息的压缩,如果训练数据的信息有缺损,则会导致提取到的特征不完整,必然会对后续的重构工作产生影响。

综上所述,为了更好地利用自编码器高效的特征编码能力,并结合监督学习的训练优势,本文提出在经典无监督学习AE模型结构的基础上,构建一个基于监督学习的AE模型,实现对受损信息估计的新方法;设计了一种新的训练策略,该策略有效利用样本先验获得更抽象、更丰富的特征表达,提高了对受损数据的重构能力。通过在MINIST字符库中引入冲击椒盐噪声的方式生成模拟受损样本,并将其作为测试对象用于对受损样本恢复后的分类测试,证明了方法的有效性;将该方法应用于人脸部分区域缺失或遮挡的重构,并定量地分析了重构效果,从而验证了新方法的有效性和适用性。

2 监督学习自编码器

2.1 监督学习单层自编码器模型

自编码器的概念是由Rumelhart^[17]于1986年提出的,并被用来处理高维复杂数据。AE是一个可以通过多个单层AE模型堆叠的深层网络,单层AE模型的目标是最小化输入数据 X 与重构数据 Z 之间的平均重构误差,其目标损失函数为:

$$J(W, b) = \frac{1}{m} \sum_{i=1}^m \left(\frac{1}{2} \| Z^i - X^i \|^2 \right) \quad (1)$$

其中, m 为训练样本的个数; Z^i 表示第 i 个重构样本; X^i 表示第 i 个输入样本。其模型结构如图1所示。




图1 自编码器模型结构

Fig.1 Structure of AE model

自编码器对特征的表达结果与训练样本的形式密切相关,若无监督学习AE模型的训练样本受损,则对特征表达的学习一定是不完整的。

为了弥补无监督学习对特征表达能力的局限性,合理利用监督学习的优势,文中提出了对经典无监督学习AE模型加以监督学习的新方法。新模型将目标函数改为最小化监督

标签 X_{label} 与重构样本 Z 之间的平均重构误差,目标损失函数变为:

$$J(W, b) = \frac{1}{m} \sum_{i=1}^m \left(\frac{1}{2} \| Z^i - X_{\text{label}}^i \|^2 \right) \quad (2)$$

其中, m 为训练样本的个数; X_{label}^i 表示第 i 个输入所对应的理想监督样本。其模型结构如图2所示。





图2 监督学习单层自编码器模型结构

Fig.2 Sstructure of supervised single-layer AE model


2.2 监督学习单层自编码器的特征学习

经典AE模型在网络学习的过程中采用一对一的无监督学习方式,即一个输入对应一个输出(且输出为输入本身),使得经典AE模型获取的特征表达具有单一性和局限性,通过学习提取的特征仅仅是输入样本自身固有的特征,如图3(a)和图3(b)所示。



(a)无监督学习无损样本

(b)无监督学习受损样本



(c)监督学习受损样本(一对一)

(d)监督学习受损样本(多对一)

图3 无监督AE学习和监督AE学习的特征表达

Fig.3 Feature representation of unsupervised AE learning and supervised AE learning

通过对经典AE模型添加监督层的学习方式,改善了经典AE模型对受损样本在特征表达学习时的单一性和局限性。图3(c)给出了AE一对一监督学习的特征表达结果,可以直观看图3(c)比图3(b)具有更稳定和更丰富的“内容”表达。进一步,本文采用多对一的学习策略,即一个输入样本具有多种形式,而输出仅对应一个训练标签,这使得受新策略训练的监督学习AE模型在进行特征表达时,能够学习到除样本自身固有特征以外更加多元化的特征表达,如图3(d)所示,从而弥补了经典AE模型对受损样本训练中特征表达的缺失,使获取的特征更具鲁棒性。

2.3 监督学习深度自编码器模型及训练方法

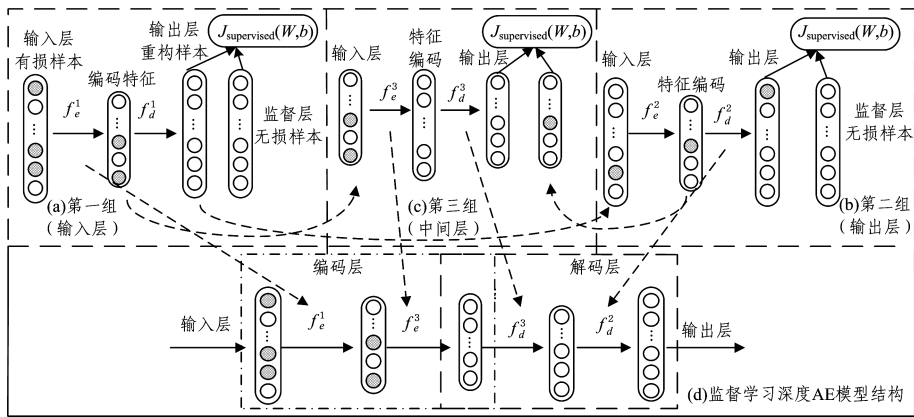
经典AE的深度结构是通过无监督贪婪算法逐层训练,并以堆叠的方式实现的,在每一层训练过程中都产生一种特征表达,其堆叠层越深,特征越抽象,从而实现了对原始样本

的特征表示。2.2 节中实现了监督学习单层自编码器的构建与训练,在深度学习的框架下,希望获得监督自编码器的深度结构与训练方法。由于在监督学习深度 AE 模型中每一层用于监督的训练标签并非该层的输入,无法采用经典 AE 的堆叠方式与训练方法,因此文中提出一种针对监督学习 AE 模型的新的深度网络结构与训练方法。

基于监督学习的深度 AE 模型的训练分为 3 组,如图 4 所示。每组的训练都基于一个监督学习单层 AE 模型,且每一个训练模型都是独立的,但整个训练过程是相互关联的。

第一组训练为监督学习深度 AE 模型中输入层的训练(即第一层的训练),如图 4(a)所示,对于一个监督学习单层 AE 模型,将受损数据作为输入,无损数据作为监督,进行监

督学习。在训练过程中,本文把隐含层的结果称为特征编码,把输入层到隐含层的连接权值(即 W_e)称为编码的特征表达。把从隐含层到输出层的连接权值(即 W_d)称为解码的特征表达。第二组的训练被称为监督学习深度 AE 模型中输出层的训练(即第三层的训练)。首先提取第一组通过监督学习输出的重构数据,并将其作为第二个监督学习单层 AE 模型训练的输入,再一次与无损数据之间进行监督学习。文中把这种逐组学习的过程称为“递进式学习”,目的是进一步减小重构数据结果与无损数据的误差。同时,在首次重构数据的基础上通过监督获取输出层中解码的特征表达,如图 4(b)所示。最后一组的训练,被称为监督学习深度 AE 模型中中间层的训练(即第二层的训练),如图 4(c)所示。



注:(a)表示第一组输入层的监督训练过程;(b)表示第二组输出层的递进式学习;(c)表示第三组中间层的关联编码;(d)表示堆叠的监督学习深度 AE 模型结构

图 4 监督深度 AE 模型的逐组训练过程及深度模型的网络结构

Fig. 4 Training process by group of supervised deep AE model and deep model network structure

将提取的第一组中学习的特征编码作为该组模型训练的输入,将提取的第二组中学习的特征编码作为监督,从而进行监督学习,其目的是通过该层的学习建立起监督学习深度 AE 模型中输入层与输出层所学编码和解码特征表达的关联性,该部分的学习过程被称为“关联编码”。同时,对两组特征编码的监督学习进一步完善了深层特征表达的能力以及对特征的编码。

在每一组监督单层 AE 模型的训练过程中使用 sigmoid 函数 $f(\cdot)$ 作为激活函数来映射特征表示,其学习过程如下:

$$\begin{aligned} f_e^i(x) &= f(W_e^i * x + b_e^i) \\ f_d^i(f_e^i) &= f(W_d^i * f_e^i + b_d^i) \end{aligned} \quad (3)$$

其中, f_e^i 表示第 i 组监督 AE 模型的编码结果, f_d^i 表示第 i 组监督 AE 模型的解码结果。

综上所述,文中提出的监督学习深度 AE 与经典 AE 在模型结构与训练方法上都存在着显著的差别。本文通过分组的递进式学习以及组间的关联编码实现了对监督深度 AE 的训练,使新模型可以采用多对一的训练策略进行深层抽象特征编码,从而克服了经典 AE 对特征表达的单一性。

3 基于监督学习的深度自编码器的数据重构

采用 2.3 节中监督学习深度 AE 模型的训练方法完成对模型的训练,并按照 2.3 节中的方法提取模型中的特征表达,即特征权值 W 。根据先编码再解码的网络结构,构建一个具

有两层编码和两层解码的堆叠 AE 模型,网络结构如图 4(d)所示。先通过监督学习的编码特征表达对受损样本进行深层的特征编码,再根据获取的解码特征表达反向解码,重构出特征编码所描述的趋近于无损的样本信息。对于训练好的模型,以前馈方式完成对受损输入样本的重构。该前馈重构过程如下:

$$\begin{aligned} f_e^i(x) &= f(W_e^i * x + b_e^i) \\ f_e^3(f_e^1) &= f(W_e^3 * f_e^1 + b_e^3) \\ f_d^3(f_e^3) &= f(W_d^3 * f_e^3 + b_d^3) \\ f_d^2(f_d^3) &= f(W_d^2 * f_d^3 + b_d^2) \end{aligned} \quad (4)$$

4 实验与分析

4.1 实验数据

手写字符识别和人脸识别是图像分类中最具代表性的经典问题,将这两个问题作为测试对象来验证本文提出的监督学习深度 AE 模型对受损样本重构的性能。实验采用的数据来源于 MNIST 手写字符样本库和美国普渡大学的 AR 人脸库。

MNIST 数据集分为训练集和测试集,其中训练集包含 60000 个样本数据,测试集包含 10000 个样本数据。每个样本都进行了尺度标准化及图像灰度化的预处理(每个样本尺度为 28×28),同时对数据集分别添加了 0~50% 不等的椒盐冲击噪声以模拟一个样本的多种受损状态。训练的监督样本为原始无损样本,图 5(a)为选取的部分无损样本(原始数

据);从上至下每行样本的受损程度依次增加 10% 的冲击噪声,如图 5(b)所示;图 5(c)给出多种不同受损程度的样本。

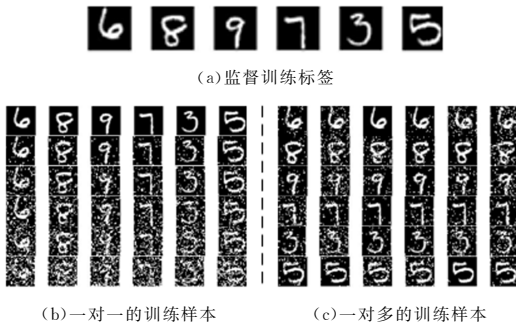


图 5 不同受损程度的样本

Fig. 5 Samples with different damaged levels

美国普渡大学的 AR 人脸库包含 126 个人(56 位女士和 70 位男士),包含 4000 多张人脸。本文利用此数据库中 50 位男士的人脸进行实验,共 1300 张人脸。其中,每个人对应 26 张具有不同程度光照、表情变化以及受遮挡(戴墨镜和戴围巾)的脸。AR 人脸库的部分数据如图 6 所示。

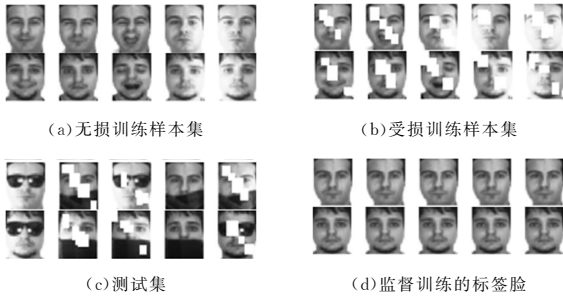



图 6 AR 人脸库的部分数据

Fig. 6 Partial data of AR dataset



注:(a)表示经典 AE 模型依次对 5 种受损样本进行重构的结果(第一行为无损样本,从第二行开始,依次是对含有 10%、20%、30%、40%、50% 样本受损情况的重构结果);(b)表示一对一训练的监督学习 AE 模型对受损样本重构的结果;(c)表示多对一监督学习 AE 对受损样本重构的结果;(d)表示多对一监督学习深度 AE 对受损样本重构的结果

图 8 受损样本在不同结构 AE 模型下的重构结果对比

Fig. 8 Comparison of reconstruction results of damaged samples by AE models with different structures

表 1 基于 CNN 对不同程度受损样本重建后的分类结果

Table 1 Classification results of reconstructing samples with different damaged levels by CNN

模型	噪声强度	分类错误率/%				
		10	20	30	40	50
分类器直接分类		6.75	25.76	48.50	67.59	80.13
	无监督	4.71	17.73	34.36	50.19	60.46
单层	一对一监督	2.06	3.11	5.83	10.49	19.56
	多对一监督	1.88	2.76	4.55	8.72	16.84
深层 AE	多对一监督	2.06	2.68	4.39	7.53	14.74

通过监督学习 AE 模型重构的结果可以看出,根据受损程度的不同,分类的错误率在受损样本直接分类的基础上分别降低了 4.69%~60.57% 不等,其受损程度越严重,重构的

实验把从 AR 库中提取的数据分为 4 个部分:1)无损训练集,共 700 张人脸,每人对应 14 张脸,如图 6(a)所示;2)利用无损训练集构建的一个对应的受损数据集,受损数据集是人工对无损训练集中每张无损脸的面部部分区域像素值随机地进行归零操作获得的,如图 6(b)所示;3)测试集,取自然条件下受遮挡的人脸(如戴墨镜、戴围巾),同时,人工对提取的有遮挡的人脸进行随机的二次破坏,然后从自然条件下人为二次破坏的遮挡人脸中抽取 700 张,同时保证每人对应 14 张受遮挡脸,如图 6(c)所示;4)人工为每一位男士在各自对应的人脸中挑选出一张主观认为在光照、表情以及无遮挡情况下的最佳脸作为监督训练的标签脸,如图 6(d)所示。

4.2 实验方法与结果分析

4.2.1 对受损手写字符重构的测试结果分析

首先利用无损样本预训练一个卷积神经网络(Convolutional Neural Networks, CNN),并将之作为分类器,将有损样本采用新模型重构后输入到预训练好的 CNN 分类器中进行分类,通过分类结果比较重构模型的优劣,其结构如图 7 所示。




图 7 受损字符重构的实验框架

Fig. 7 Experimental framework of reconstructing damaged samples


通过训练经典 AE 模型、一对一监督 AE 模型、多对一监督 AE 模型以及多对一的监督学习深度 AE 模型,依次对受损样本进行重构,重构结果如图 8 所示。通过 CNN 分类的错误率比较模型的优劣,由表 1 可见,随着受损程度的增加,无损数据通过经典 AE 模型重构的结果变差,重构结果如图 8(a)所示。

效果越显著,重构效果如图 8(b)所示,验证了文中提出的监督学习 AE 模型对受损样本重构的有效性。而在监督学习 AE 模型的训练中,利用多对一的训练策略进行测试的结果如表 1 所列,分类错误率根据样本受损程度的不同再一次降低了 0.18%~2.72%,重构结果如图 8(c)所示,证明了新的训练策略对监督学习 AE 模型训练的有效性。

实验最后利用本文提出的基于监督学习的深度 AE 模型在多对一的训练方式下对受损样本进行重构,其结果如图 8(d)所示。结果显示,该方法有效地改善了重构图像中局部边缘的平滑性,具有最好的重构效果,从而证明了监督学习深度 AE 模型的有效性。

4.2.2 对人脸遮挡区域重构的测试结果分析

实验对 AR 人脸库进行重构测试,利用皮尔逊相关性^[18](Pearson Correlation Coefficient, PCC)定量地描述了不同模



注:(a)中第一、二行为无损样本和受损样本,其余依次是经典 AE 重构的结果、一对一监督学习 AE 重构结果;(b)中第一行为标签脸,第二行为测试样本,然后依次是经典 AE 重构的结果、一对一监督 AE 重构的结果;(c)中第一行为标签脸,第二行为测试样本,然后依次为多对一训练的监督学习 AE 重构的结果、多对一训练的监督学习深度 AE 重构的结果

图 9 在不同结构的 AE 模型下对人脸重构的结果对比

Fig. 9 Comparison of face reconstruction results by AE models with different structures

通过分析重构效果可知,利用监督学习 AE 模型对有损人脸样本的重构效果优于经典 AE 模型的重构效果,如图 9(a)所示。对于人脸遮挡区域的重构,图 9(b)中的结果显示,监督学习 AE 模型的重构效果依然优于经典 AE 模型的重构效果,但是该模型一对一的训练策略不能满足对遮挡区域的特征表达。如图 9(c)所示,通过多对一训练的监督学习 AE 模型对此问题的解决优于采用一对一训练策略的监督学习 AE 模型,从而证明了针对监督学习 AE 模型提出的新训练策略的有效性。对于文中提出的基于监督学习的深度 AE 模型,利用多对一的训练策略进一步提高了对人脸部分遮挡区域细节的重构效果,与多对一监督学习单层 AE 模型相比,图像重构更加自然,证明了文中所提新模型和新训练策略的有效性和适用性。

为了定量地描述上述模型对数据重构的性能差异,采用皮尔逊相关性对上述模型的重构结果进行相关性分析。皮尔逊相关系数的定义如下:

$$r = \frac{\sum_{i=1}^n (X_{label} - \bar{Z})(X_{recon}^2 - \bar{Z}^2)}{\sqrt{\sum_{i=1}^n (X_{label} - \bar{Z})^2} \sqrt{\sum_{i=1}^n (X_{recon}^2 - \bar{Z}^2)^2}} \quad (5)$$

其中, n 表示样本数量, X_{label} 表示标签脸, Z 表示重构脸。其网络模型测试结构如图 10 所示。




图 10 人脸重构的实验框架

Fig. 10 Experimental framework of face reconstruction

计算结果取决于重构的测试集中某个人所对应的 14 张遮挡脸与对应标签脸的平均相似度值,如表 2 所列。

表 2 对人脸重构后的相关性分析结果

Table 2 Correlation analysis results of reconstructed face dataset

模型	无监督 AE	监督单层 AE	监督单层 AE	监督深度 AE
训练集	0.59	0.79	—	—
测试集	0.46	0.51	0.93	0.95

基于受损人脸的重构结果显示,相比于无监督学习 AE 模型,文中提出的监督学习单层 AE 模型的重构人脸的相似

型的重建方法的效果。

利用上述 4 种 AE 模型分别对人脸遮挡区域进行重构,重构结果如图 9 所示。

度提高了 0.2,从而再一次验证了在无监督学习模型中加入监督学习的有效性。在对人脸遮挡区域的重构测试中,通过监督学习 AE 模型重构的人脸的相似度同样比无监督模型重构的人脸的相似度高出 0.05,这证明了监督学习 AE 模型对人脸遮挡区域重构的适用性。

通过利用多对一的训练策略,监督学习 AE 模型对人脸遮挡区域的重构效果提升了 0.42 的相似度。采用本文提出的监督学习深度 AE 模型对人脸的重构与监督学习单层 AE 模型重构相比,再一次提高了 0.02 的相似度,有效抑制了重构结果中的噪点;与经典无监督 AE 重构相比,提高了 0.49 的相似度。上述结论证明了针对监督学习 AE 模型的训练提出的新策略的有效性和适用性。

结束语 当今社会每时每刻都会产生海量的数字媒体数据,提供一种有效的数据维护修复方式十分必要。通过对经典 AE 模型的分析研究,提出了一种基于经典 AE 模型的结构,采用监督学习实现对缺损图像进行重构的方法。首先,提出了针对单层监督自编码器的网络结构与训练策略;然后,基于深度思想,利用逐组递进学习和关联编码的学习策略构建了一个监督学习深度 AE 模型;设计了对有损字符样本恢复后的识别实验以及对缺失和遮挡人脸重构性能的定量分析实验,从而较为系统、全面地验证了所提方法的有效性。

参 考 文 献

[1] ZHANG H Y, PENG Q C. A survey on digital image inpainting [J]. Journal of Image & Graphics, 2007, 12(1): 1-10. (in Chinese)

张红英, 彭启琮. 数字图像修复技术综述[J]. 中国图象图形学报, 2007, 12(1): 1-10.

[2] BERTALMIÓ M, SAPIRO G, CASELLES V, et al. Image inpainting[C]//Conference on Computer Graphics and Interactive Techniques. DBLP, 2000: 417-424.

[3] CHAN T, SHEN J. Mathematical models for local non-texture inpaintings[J]. SIAM Journal on Applied Mathematics, 2001, 62(3): 1019-1043.

[4] KOMODAKIS N. Image Completion Using Global Optimization [C]// 2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. IEEE, 2006: 442-452.

- [4] NVIDIA Corporation. CUDA Technology[OL]. <http://www.nvidia.com/CUDA>.
- [5] ZECHNER M, GRANITZER M. Accelerating K-Means on the Graphics Processor via CU-DA[C] // First International Conference on Intensive Applications and Services. IEEE Computer Society, 2009: 7-15.
- [6] LI Y, ZHAO K, CHU X, et al. Speeding up K-Means Algorithm by GPUs[C] // International Conference on Computer and Information Technology. IEEE, 2010: 115-122.
- [7] ZHONG S, LIN S, XU G, et al. The expansibility research of K-Means algorithm under the GPU[C] // IEEE International Conference on Software Engineering and Service Science. IEEE, 2017: 734-737.
- [8] HUANG P, LI X, YUAN B. A Parallel GPU-Based Approach to Clustering Very Fast Data Streams[C] // ACM International on Conference on Information and Knowledge Management. ACM, 2015: 23-32.
- [9] WU J, HONG B. An Efficient k-Means Algorithm on CUDA [C] // IEEE International Symposium on Parallel and Distributed Processing Workshops and Phd Forum. IEEE Computer Society, 2011: 1740-1749.
- [10] HUI Z N. Multidimensional data clustering algorithm research and GPU acceleration based Global K-means[D]. Xi'an: Xidian University, 2012. (in Chinese)
- 惠转妮. 基于 Global K-means 的多维数据聚类算法研究及其 GPU 加速[D]. 西安: 西安电子科技大学, 2012.
- [11] KAKOUEI M, SHAHHOSEINI H S. A parallel k-means clustering initial center selection and dynamic center correction on GPU[C] // Electrical Engineering. IEEE, 2015: 20-25.
- [12] BHIMANI J, LEESER M, MI N. Accelerating K-Means clustering with parallel implementations and GPU computing[C] // High Performance Extreme Computing Conference. IEEE, 2015: 1-6.
- [13] BAYDOUN M, DAWI M, GHAZIRI H. Enhanced parallel implementation of the K-Means clustering algorithm[C] // International Conference on Advances in Computational TOOLS for Engineering Applications. IEEE, 2016: 7-11.
- [14] ABBASITABAR H, SAMAVATIAN M H, SA-RBAZI-AZAD H, ASHA. An Adaptive Shared-Memory Sharing Architecture for Multi-Programmed GPUs[J]. Microprocessors & Microsystems, 2016, 46: 264-273.
- [15] HETTICH S, BAY S D. KDD cup 1999 data[EB/OL]. <http://kdd.ics.uci.edu/databases/kddcup99/kddcup99.html>.
- [16] WANG Q, MEGALOOIKONOMOU V. A clustering algorithm for intrusion detection[J]. Proc Spie, 2008, 5812(5812): 31-38.
- [17] FANG W, LAU K K, LUM, et al. Parallel datamining on graphics processors [OL]. <http://11130.126.143.33/sites/default/files/papers/358/gpuminer.pdf>.

(上接第 271 页)

- [5] HSIN H F, LEOU J J, LIN C S, et al. Image inpainting using structure-guided priority belief propagation and label transformations[C] // International Conference on Pattern Recognition. IEEE, 2010: 4492-4495.
- [6] MANSFIELD A, PRASAD M, ROTHER C, et al. Transforming Image Completion [C] // British Machine Vision Conference. 2011.
- [7] KANG Y, LEE K T, EUN J, et al. Stacked Denoising Autoencoders for Face Pose Normalization [C] // International Conference on Neural Information Processing. Springer Berlin Heidelberg, 2013: 241-248.
- [8] XIE J, XU L, CHEN E. Image denoising and inpainting with deep neural networks[C] // International Conference on Neural Information Processing Systems. 2012: 341-349.
- [9] PATHAK D, KRAHENBUHL P, DONAHUE J, et al. Context Encoders: Feature learning by inpainting[C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2016: 2536-2544.
- [10] YANG C, LU X, LIN Z, et al. High-Resolution Image Inpainting Using Multi-scale Neural Patch Synthesis [C] // IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2017: 4076-4084.
- [11] HUANG R, CHANG L, LIC G, et al. Adaptive Deep Supervised Autoencoder Based Image Reconstruction for Face Recognition [J]. Mathematical Problems in Engineering, 2016, 2016(5): 1-14.
- [12] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7): 1527.
- [13] BENGIO Y. Learning deep architectures for AI[J]. Foundations and Trends in Machine Learning, 2009, 2(1): 1-127.
- [14] ZHANG C, ZHANG Z Y. Improving multiview face detection with multi-task deep convolutional neural networks[C] // IEEE Winter Application and Computer Vision Conference. USA, 2014: 1036-1041.
- [15] LÄNGKVIST M, KARLSSON L, LOUTFI A. A review of unsupervised feature learning and deep learning for time-series modeling[J]. Pattern Recognition Letters, 2014, 42(1): 11-24.
- [16] ZHANG Y, CHEN Q Y, ZHANG Y J. Deep learning and its new progress in object and behavior recognition[J]. Journal of Image & Graphics, 2014, 19(2): 175-184. (in Chinese)
- 郑胤, 陈权崎, 章毓晋. 深度学习及其在目标和行为识别中的新进展[J]. 中国图象图形学报, 2014, 19(2): 175-184.
- [17] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back-propagating errors[J]. Nature, 1986, 323: 533-536.
- [18] PEARSON K. Mathematical contributions to the theory of evolution (III): Regression, heredity, and panmixia[J]. Proceedings of the Royal Society of London, 1998, 187(4): 253-318.