

深度学习原理及应用综述

付文博¹ 孙涛² 梁藉¹ 闫宝伟¹ 范福新¹

(华中科技大学 武汉 430074)¹ (中国水利水电科学研究院 北京 100044)²

摘要 深度学习作为机器学习领域中重要的技术手段,有着广阔的应用前景。文中简述了深度学习的发展历程,介绍了卷积神经网络、受限玻尔兹曼机、自动编码器及其衍生的系列方法模型,以及 Caffe, TensorFlow, Torch 等 6 种主流深度框架;论述了深度学习在图像、语音、视频、文本、数据分析方面的应用情况,分析了深度学习现阶段存在的问题以及未来的发展趋势,为初学者提供了较全面的方法指导与文献索引支持。

关键词 深度学习,神经网络,卷积神经网络,受限玻尔兹曼机,自动编码器,框架,应用

中图分类号 TP18 **文献标识码** A

Review of Principle and Application of Deep Learning

FU Wen-bo¹ SUN Tao² LIANG Ji¹ YAN Bao-wei¹ FAN Fu-xin¹

(Huazhong University of Science and Technology, Wuhan 430074, China)¹

(China Institute of Water Resources and Hydropower Research, Beijing 100044, China)²

Abstract As an important technical means of machine learning, deep learning has a broad application prospect. This article briefly described the development of deep learning, introduced convolutional neural network, restricted boltzmann machine, auto encoder and its derived series method model, and six kinds of mainstream depth frame such as Caffe, TensorFlow, Torch. This paper also discussed the application of deep learning in image, speech, video, text and data analysis, analyzed the existing problems and future trends of deep learning, providing a more comprehensive method guidance and literature index support for beginners.

Keywords Deep learning, Neural networks, Convolutional neural networks, Restricted Boltzmann machine, Auto encoder, Framework, Application

1 引言

深度学习(deep learning)作为机器学习领域的重大分支,不仅深刻影响着机器学习领域的走向,更是实现人工智能的一条有力的途径。深度学习本质上是层次特征提取学习的过程,它通过构建多层隐含神经网络模型,利用海量数据训练出模型特征来提取最有利的参数,将简单的特征组合抽象成高层次的特征,以实现和数据或实际对象的抽象表达。

鉴于近几年深度学习的火热程度,本文将从发展历程、常用方法、主流框架、应用情况、应用问题及前景分析这 5 个方面对深度学习展开系统的介绍。

2 深度学习的发展历程

深度学习是神经网络发展到一定时期的产物。最早的神经网络模型可以追溯到 1943 年 McCulloch 等^[1]提出的 McCulloch-Pitts 计算结构,它大致模拟了人类神经元的工作原理,但需要手动设置权重,十分不便。1958 年, Rosenblatt^[2]教授提出了感知机模型(perceptron),尽管相比前者,该模型

能更自动合理地设置权重,但同样存在较大的局限,难以展开更多的研究。特别地, Minsky 教授于和 Paper 教授于 1969 年证明了感知机模型只能解决线性可分问题,并且否定了多层神经网络训练的可能性,甚至提出了“基于感知机的研究终会失败”的观点,此后十多年的时间内,神经网络领域的研究基本处于停滞状态^[3]。

20 世纪 80 年代,计算机飞速发展,计算能力相较以前也有了质的飞跃。1986 年, Rumelhart^[4]教授团队在 *Nature* 上发表文章,提出了反向传播算法(Back Propagation, BP)。BP 算法的提出不仅有力地回击了 Minsky 教授等人的观点,更引领了神经网络研究的第二次高潮。随后,玻尔兹曼机、卷积神经网络、循环神经网络等神经网络结构模型均在这一时期得到了较好的发展。

2006 年,机器学习领域泰斗 Hinton^[5]及其团队在 *Science* 上发表了关于神经网络理念突破性的文章,首次提出了深度学习的概念,并指明可以通过逐层初始化来解决深度神经网络在训练上的难题。该理论的提出再次激起了神经网络领域研究的浪潮。此后,随着大数据时代的到来、互联网+模式的

本文受北京市科技计划课题:北京市水土保持遥感技术应用研究与示范(Z161100001116102),北京市多水源综合调控理论及模型技术研究(2017KFYXJJ202),南水北调中线干线工程应急运行集散控制技术与示范(2015BAB07B03)资助。

付文博(1994—),男,硕士生,主要研究方向为水利信息化、深度学习, E-mail: wenbo. fu@qq. com; 孙涛(1973—),男,高级工程师,主要研究方向为遥感水文、GIS 开发和深度学习, E-mail: 407571306@qq. com; 梁藉(1977—),男,副研究员,主要研究方向为水利信息化、大数据; 闫宝伟(1981—),男,副教授,主要研究方向为水文水资源; 范福新(1993—),男,硕士生,主要研究方向为水利信息化、大数据。

发展,以及计算机性能的飞速提高,深度学习开始渗透到各行各业,神经网络也迎来了发展的春天。2011年,吴恩达领导Google科学家们用16000台电脑成功模拟了一个人脑神经网络;2012年,Hinton团队将深度学习应用于ImageNet上,并取得了惊人的识别效果;2013年,欧洲委员会发起模仿人脑的超级计算机项目,同年1月,百度宣布成立深度学习研究院。2014年,深度学习模型Top-5在ImageNet 2014计算机识别竞赛上拔得头筹,同年,腾讯和京东也分别成立了自己的深度学习研究室。2016年,AlphaGo击败围棋世界冠军李在石,同年9月,中国科学院计算技术研究所发布“寒武纪1A”深度神经网络处理器。这一切都显著地表明了一个事实:深度学习正在有条不紊地发展着,其影响力不断扩大。

3 深度学习原理方法

3.1 常用的深度学习方法

3.1.1 卷积神经网络

卷积神经网络(Convolutional Neural Networks, CNN)^[6-9]是在模式识别、图像处理领域的一种高效且稳定的方法,它通过局部感知、共享权值、空间或时间上的池采样来充分利用数据本身包含的局部特性,以优化网络结构,保证一定程度上的位移和变形的不变性。所谓局部感知,是指在卷积神经网络结构中每个神经元只与部分图像产生特征映射关系,不用感知全局图像。这一特性启发于1962年Hubel和Wiesel通过对猫视觉皮层细胞的研究而提出的感受野理论^[10]。共享权值则是指:当用卷积神经网络提取1种特征时,神经元间共享一套权值,且用这一个相同的卷积核对图像做卷积;当提取 n 种特征时,神经元间共享 n 套权值,并用这 n 个相同的卷积核对图像做卷积。局部感知和共享权值这两大特性大大地减少了卷积神经网络结构中的参数数目,使网络结构变得更加简单清晰。

一个完整的卷积神经网络基本上由输入层、卷积层、池化层、全连接层和SoftMax层这5种结构组成,如图1所示。输入层是整个卷积神经网络的输入,一般代表一张图片的像素矩阵;卷积层是整个神经网络的核心,一般将前一层神经网络上的子节点矩阵卷积转化为下一层神经网络上的节点矩阵,并增加节点矩阵的深度,以达到更深层次抽象特征表达的目的;池化层的实质是数理统计矩阵块不重叠区域的聚合特征,一般有平均池采样和最大池采样两种方法,池采样层不会改变特征矩阵的深度,但可以缩小矩阵的大小,简化神经网络的结构;全连接层一般位于多次卷积池化处理后,用以给出最后的分类结果。SoftMax层类似图1中的分类器,主要用以分类,能得到结果的概率分布情况。

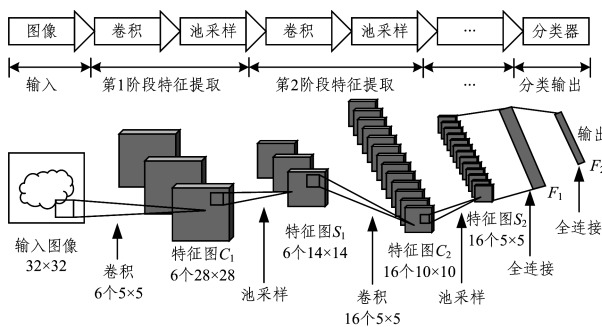


图1 一般卷积神经网络的结构示意图

卷积神经网络的训练实际上是监督学习的过程,主要包

括向前传播和反向传播两个阶段,在训练的过程中,参数能被不断地优化,从而达到最好的模拟效果。随着卷积神经网络探究的深入,以卷积神经网络为基础,出现了一系列的优化改进结构模型,如全卷积神经网络(Fully Convolutional Neural Network, FCN)^[11]、深度卷积神经网络(Deep Convolution Neural Network, DCNN)^[12]等。

3.1.2 受限玻尔兹曼机

受限玻尔兹曼机(Restricted Boltzmann Machine, RBM)^[13-14]是由Smolensky在波尔兹曼机基础上提出的,由显性单元(显性变量)和隐性单元(隐性变量)构成,如图2所示。在受限玻尔兹曼机模型中,显性单元和隐性单元之间才会存在映射关系,显性单元内部及隐性单元内部均不会存在连接。受限玻尔兹曼机的训练方式主要是基于对比散度的快速学习算法。随着对受限玻尔兹曼机研究的深入,也出现了一系列改进算法模型,如稀疏组受限玻尔兹曼机(Sparse Group Restricted Boltzmann Machine, SGRBM)^[15]、分类受限玻尔兹曼机(Classification Restricted Boltzmann Machine, ClassRBM)^[16]等。

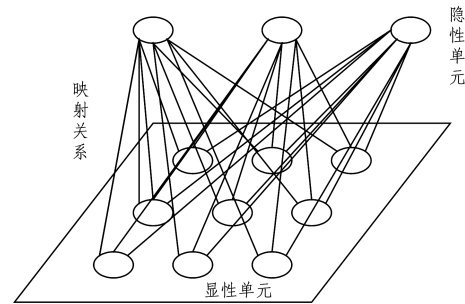


图2 受限玻尔兹曼机的模型示意图

深度置信网络(Deep Belief Network)^[17-19]是由若干个受限玻尔兹曼机叠加成的网络结构。大部分情况下,深度置信网络都是通过逐层贪婪无监督学习进行训练的,也可以在最后一层网络结构上加上SoftMax分类器进行有监督训练。

3.1.3 自动编码器

自动编码器(Auto Encoder, AE)^[20]是由Rumelhart于1986年提出的一种典型的无监督式机器学习方法。自动编码器主要由编码器和解译器两部分组成,其结构如图3所示。编码器的作用是将输入的信号压缩表示传递给下一层网络,类似于图3中输入层到隐藏层的过程;而解译器的作用则是解译编码器压缩重建的数据信号,传递输出信号,类似于图3中隐藏层到输出层的过程。编码器和解译器在本质上都是对输入的信号进行某种变换,从而复原输入信号。




图3 自动编码器的结构示意图

随着对自动编码器研究的深入,基于自动编码器的改进结构模型不断涌现出来。2006年,深度自动编码器(Deep Auto Encoder, DAE)^[21]被Hinton等提出,相比于原自动编

码器,其加深了模型层数;2007年,Bengio团队提出了堆叠自动编码器(Stacked Auto Encoders,SAE)^[22],它是由深度置信网络与自动编码器重组后生成的模型;同年,Ranzato团队提出了稀疏自动编码器(Sparse Auto Encoder,SAE)^[23];Vincent等则依次于2008年和2010年提出了降噪自动编码器(Denoising Auto Encoder,dAE)^[24]和堆叠降噪自动编码器(Stacked Denoising Auto Encoders,SDAE)^[25];2011年,Jonathan等^[26]提出了堆叠卷积自动编码器(Stacked Convolutional Auto Encoder,SCAE);2013年,Jiang^[27]团队提出了堆叠稀

疏自动编码器(Stacked Sparse Auto Encoders,SSAE)。

3.2 主流深度学习框架

深度学习框架是专为深度学习领域开发的具有一套独立的体系结构、统一的风格模板、可以复用的解决方案。它一般具有高内聚、严规范、可扩展、可维护、高通用的特点,且拥有统一的代码风格、模板化的结构,能减少大量重复代码的编写。随着深度学习的日益火热,越来越多的深度学习框架被开发出来。目前主流深度学习框架主要有以下6种,如表1所列。

表1 主流深度学习框架

框架名称	维护团队	支持语言	支持系统	特点
Caffe ^[28]	加州大学伯克利分校视觉与学习中心	C++,Python,MATLAB	Linux,Mac OS X,Windows	模块化,表示和实现分离,测试覆盖全面,接口丰富
TensorFlow ^[29]	谷歌	C++,Python	Linux,Mac OS X,Windows,iOS,Android	高灵活性、强拓展性、自动求微分、可视化
Microsoft Cognitive Toolkit (CNTK) ^[30]	微软研究院	C++,Python,BrainScript	Linux,Windows	性能导向、高灵活性、强拓展性
MXNet ^[31]	分布式机器学习社区(DMLC)	C++,Python,Julia,MATLAB,Go,R,Scala	Linux,Mac OS X,Windows,iOS,Android	支持多机多节点多GPU、支持内存管理、支持Torch
Torch ^[32]	Facebook,Twitter,Google	Lua,LuaJIT,C	Linux,Mac OS X,Windows,iOS,Android	强大的n维数组、丰富的索引、切片、支持高效的GPU
Theano ^[33]	蒙特利大学	Python	Linux,Mac OS X,Windows	紧密集成Numpy、透明使用GPU、高效符号分解、速度稳定性能优化、广泛单元测试与稳定性优化

4 深度学习的应用

随着深度学习在MNIST数据集数字识别上的成功应用,越来越多的人开始注意到并尝试运用深度学习这种新方法,同时,深度学习涉及的行业也越来越广。通过对深度学习最新相关文献的阅读,本文将从图像、语音、视频、文本、数据分析这5个方面对深度学习的应用现状展开论述。

4.1 图像领域

卷积神经网络最早应用在图像识别上,它在人脸识别、车牌识别方面都有较好的应用,如LeNet模型、GoogLeNet模型、FCN模型等都是典型的卷积神经网络模型。魏英姿等^[34]通过构建深度卷积神经网络模型,在MATLAB平台上成功地对玉米籽粒的完整性进行了识别,并选用了BP算法作比较,验证了深度卷积神经网络模型的适用性;李楠^[35]则借助深度学习框架Caffe,采用LeNet-5模型对破损路面进行了识别,准确率达92%;杜敬^[36]构建了深度卷积神经网络模型(DCNN)来进行遥感水体的识别,实验采用无人机获取的遥感图像,并将支持向量机法和面向对象法作为对比方法,结果显示DCNN模型的识别效果最佳;寇广等^[37]结合Caffe框架对云服务中僵尸云的检测做了详尽的研究,实验中不仅改进了LeNet-5模型,建立了基于LeNet-5模型的6种不同网络结构的卷积神经网络模型,更设置了不同的池采样方案,以对比决策树法和支持向量机法,最终结果显示了深度学习方法具有无可比拟的优越性;付罡等则提出了基于改进全卷积网络模型的高分辨率遥感影像准确分类的方法,并选用高分彩色遥感图像进行实验,结果所提方法获得了较高的精度。除此之外,还有许多成功应用CNN模型的研究,在此不一一赘述。

除卷积神经网络外,深度置信网络(DBN)、层叠去噪自编码器(SDAE)这两年也在图像处理方面有较好的应用。刘大伟等^[38]构建了合适的DBN模型,完成了对高分辨率遥感影

像的分类研究;樊恒等^[39]利用KTH数据库来训练DBN模型,以识别人体行为;李婷^[40]构建了SDAE模型来学习盲文,解决了盲文识别中特征自动提取和降维的问题;阚希等^[41]采用多光谱卫星遥感数据,以无监督训练结合有监督训练来进行全局微调,训练出合适的SDAE模型,并将其成功运用到青藏高原地区的积雪识别中,最终绘制出青藏高原的积雪分布图。

4.2 语音领域

随着信息科技的发展,海量数据已成为各个领域发展中的必然趋势,如何利用大数据也是各个行业面临的必然挑战。传统的语音识别方法在大语音数据中难以获得较好的效果,而深度学习作为新方法,恰好能提供新的思路,目前在语音识别领域已有较好的应用。Hinton等^[42]改进了传统的混合高斯-隐马尔科夫模型GMM-HMM,将模型中的GMM替换为深度神经网络(DNN),从而生成了新的模型DNN-HMM。相比于原模型,改进后的模型的词汇错误率大大降低。王山海等^[43]则尝试将深度自动编码器(DAE)应用到孤立词语音识别中,通过在MATLAB2012上搭建模型,与BP算法的结果进行对比,最终验证了DAE模型在语音识别上的适用性。王强等^[44]引入CNN模型和DBN模型,并将其运用到水声识别中,验证了这两种模型在声音识别上的可行性。

语音的高质量 and 可读性是语音数据里最重要的部分,也是语音增强中的核心内容。近几年,深度学习在语音增强方面同样有亮眼的表现,如深度循环神经网络(DRNN)^[45]、堆叠式降噪自动编码(SCAE)^[46]和LSMT神经网络^[47]等都能很好地提高语音质量。

4.3 视频领域

深度学习在视频领域的应用主要集中在交通监管和目标跟踪上。杨红红等^[48]构建了基于稀疏约束的DAE模型,以非监督训练监督式微调的方法来训练模型,将其运用到交通目标跟踪上。实验选取了一组视频,将IVT,MIL,OAB3种

算法进行比较,最终发现,基于系数约束的 DAE 模型在不同的场景下都有较高的准确率。司朋举等^[49]在 GooLeNet 模型的基础上改进并构建了一个三分类的卷积神经网络模型,并将其成功运用在仿生眼监控系统中,以人对人与车进行识别。王慧燕等^[50]提出了基于卷积神经网络的辅助跟踪方法——TaNet,并验证了该方法在长距离、多目标、目标遮挡、目标消失重现等多种场景下具有极高的准确性。文孟飞等^[51]建立了一种异构多模态深度学习结构,将视频数据描述为视与听模式,分别利用 CNN 模型和 RBM 模型进行处理,通过共享特征建立关联,最终实现对视频信息目标的识别。

4.4 文本领域

近年来,对文本领域的研究也都基本集中在深度学习上。张立民等^[52]构建了基于浅层结构 RSM 的 DBN 模型,在 MATLAB 平台上,利用 20-newgroups 文档集进行训练和测试,证明了该模型在大规模文本分析上的可行性。周盈盈等^[53]以 topic2vec 词向量模型作为模型的输入特征,改进了卷积神经网络,并将改进后的模型运用到文本分类问题的研究上。基于知乎实验数据的测试结果表明,该模型对于短文本的分类准确度能达到 93.27%,对于长文本的分类准确度高达 98.06%。李阳辉等^[54]则利用降噪自动编码器模型在深度学习框架 theano 下展开对文本的情感分析研究,证实了降噪自动编码器模型在文本信息分析上的优越性。

4.5 数据分析领域

在大数据时代,有深度的数据分析不仅是日常的业务要求,更是准确把握行业现状及趋势的必要条件。深度学习作为信息爆炸时代下的新方法,在大数据的处理上有着不可替代的优势,目前在数据诊断、参数估计、建模预测等方面均有所应用。

雷亚国等^[55]在分析机械监测系统的大数据后,通过构建深度神经网络(DNN)模型,对监测数据进行数据诊断,准确识别了不同故障方案设置下的系统健康状况;潘儒扬等^[56]则将深度学习技术应用在恒星大气物理参数估计上,该研究构建了五层栈式自编码神经网络模型,选用了 5 万条美国巡天项目实测光谱数据进行模型的训练和测试,结果表明深度学习模型在非线性数据处理上具有巨大的潜力。

谭娟等^[57]主要选取交通流参数、环境、时段 3 方面因素来进行交通拥堵预测研究,在模型设计上选用深度学习方法中的自编码模型和 SoftMax 分类器,在运行平台则选择 MATLAB 2012R,通过大量训练,最终该预测模型获得了较好的应用效果:早高峰拥堵预测的准确率为 86.7%,晚高峰拥堵预测的准确率为 84.2%。潘志刚等^[58]基于 NWP 预报数据,选用深度信念网络进行数据校正,建立了风电场功率短期预测模型;实验结果显示,该模型能有效提高功率短期预测精度。夏春江等^[59]和姚俊杨等^[60]通过深度置信网络分别完成了对木材含水率预测模型和湖库藻类水华预测模型的研究。

5 深度学习的现状分析

目前,深度学习尽管已经取得了很多成果,在图像、语音等领域的表现也十分亮眼,但是该领域依然存在很多亟需解决的问题。

1)训练模式的优化问题。目前,深度学习模型训练在大多数情况下还是以监督学习为主,而监督学习的开展需要大

量的人工标注训练样本,这个过程往往会耗费较长的时间,也需要投入大量的人力,极其繁杂。其次,训练样本的多少、训练规模的大小会直接影响模型应用的精度,因此如何平衡训练规模、训练时间、训练精度和研究基础条件间的关系也是每项研究开展时所必须面临的问题。

2)理论创新问题。大部分深度学习模型都是基于卷积神经网络、受限玻尔兹曼机、自动编码器等最简单的神经网络结构叠加或混合组成的,在解决一些数据类型多样、数据结构复杂、数据关系繁复的问题时,往往难以获得较好的效果,因此,在深度学习模型结构的创新上还需要更深层次的研究与探索。

3)应用规模化问题。目前,大多数深度学习研究都还只是处于科研阶段,即使在语音和图像等比较成熟的领域,也少有规模化投入生产生活的应用产品。

4)中文资料较少的问题。深度学习这项技术起源于国外,能被及时译制的中文基础资料还较少,市面上大部分也都是些炒概念的书籍,真正实用的工具资料较少。因此,文献资料的普及、核心技术的推广也是国内研究需要努力的方向。

随着 TensorFlow Windows 版本的推出以及 Caffe 2 在 Facebook 平台的落户,未来深度学习将会有更多的人参与,上述问题与挑战也终将被解决和完成;其次,行业大数据化也会为深度学习提供更宽广的舞台。未来深度学习发展将会呈现出多平台、深层次、全网络的趋势。

参考文献

- [1] MCCULLOCH W S, PITTS W H. A logical calculus of ideas imminent in nervous activity[J]. *Biol Math Biophys*, 1943, 5: 115-133
- [2] ROSENBLATT F. Two Theorems of Statistical Separability in the Perceptron[OL]. https://www.researchgate.net/publication/243614378_Two_Theorems_of_Statistical_Separability_in_the_Perceptron.
- [3] MINSKY M L, PAPER S. Perceptrons: an introduction to computational geometry [M] // *Perceptrons: An Introduction to Computational Geometry*. The MIT Press, 1969: 3356-62.
- [4] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning internal representation by back-propagation of errors[J]. *Nature*, 1986, 323(323): 533-536.
- [5] HINTON G E, OSINDERO S, TEH Y W. A Fast Learning Algorithm for Deep Belief Nets[J]. *Neural Computation*, 2006, 18(7): 1527.
- [6] BROWNE M, GHIDARY S S. Convolutional Neural Networks for Image Processing: An Application in Robot Vision[C] // *Conference on Ai: Advances in Artificial Intelligence*. DBLP, 2003: 641-652.
- [7] HAYKIN S, KOSKO B. *Gradient Based Learning Applied to Document Recognition* [M]. New Jersey: Wiley-IEEE Press, 2009: 306-351.
- [8] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. *Nature*, 2015, 521(7553): 436-444.
- [9] PALIY I. Face detection using Haar-like features cascade and convolutional neural network[C] // *Proceedings of International Conference on Modern Problems of Radio Engineering, Telecommunications and Computer Science*. IEEE, 2008: 375-377.

- [10] HUBEL D H, WIESEL T N. Receptive fields, binocular interaction and functional architecture in the cat's visual cortex[J]. *Journal of Physiology*, 1962, 160(1): 106-154.
- [11] KRUTHIVENTI S S S, AYUSH K, BABU R V. DeepFix: A Fully Convolutional Neural Network for Predicting Human Eye Fixations[J]. *IEEE Transactions on Image Processing*, 2015, 26(9): 4446-4456.
- [12] 郭昕, 陈琳, 沉敏. 分层自适应深度卷积神经网络及其在轴承故障诊断中的应用[J]. *测量*, 2016, 93: 490-502.
- [13] SMOLENSKY P. Information processing in dynamical systems: foundations of harmony theory[M] // *Parallel distributed processing: explorations in the microstructure of cognition*. MIT Press, 1986: 194-281.
- [14] SALAKHUTDINOV R, LAROCHELLE H. Efficient Learning of Deep Boltzmann Machines[OL]. https://www.researchgate.net/publication/220320264_Efficient_Learning_of_Deep_Boltzmann_Machines.
- [15] 罗恒. 基于协同过滤视角的受限玻尔兹曼机研究[D]. 上海: 上海交通大学, 2011.
- [16] LAROCHELLE H, MANDEL M, PASCANU R, et al. Learning algorithms for the classification restricted Boltzmann machine [J]. *Journal of Machine Learning Research*, 2012, 13(1): 643-669.
- [17] SCHÖLKOPF B, PLATT J, HOFMANN T. Greedy Layer-Wise Training of Deep Networks[C] // *International Conference on Neural Information Processing Systems*. MIT Press, 2006: 153-160.
- [18] LEE H, GROSSE R, RANGANATH R, et al. Unsupervised learning of hierarchical representations with convolutional deep belief networks[J]. *Communications of the Acm*, 2011, 54(10): 95-103.
- [19] HALKIAS X, PARIS S, GLOTIN H. Sparse Penalty in Deep Belief Networks; Using the Mixed Norm Constraint [EB/OL]. (2013-01-16). <http://arxiv.org/pdf/1301.3533v1.pdf>.
- [20] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative Adversarial Networks[J]. *Advances in Neural Information Processing Systems*, 2014, 3: 2672-2680.
- [21] HINTON G E, SALAKHUTDINOV R R. Reducing the Dimensionality of Data with Neural Networks[J]. *Science*, 2006, 313(5786): 504-507.
- [22] BENGIO Y, LAMBLIN P, POPOVICI D, et al. Greedy layer-wise training of deep networks[C] // *International Conference on Neural Information Processing Systems*. MIT Press, 2006: 153-160.
- [23] RANZATO M, BOUREAU Y L, LECUN Y. Sparse feature learning for deep belief networks[C] // *Advances in Neural Information Processing Systems*. 2007: 1185-1192.
- [24] VINCENT P, LAROCHELLE H, BENGIO Y, et al. Extracting and composing robust features with denoising autoencoders[C] // *27th International Conference on Machine Learning*. ACM, 2008: 1096-1103.
- [25] VINCENT P, LAROCHELLE H, LAJOIE I, et al. Stacked Denoising Autoencoders: Learning Useful Representations in a Deep Network with a Local Denoising Criterion. [J]. *Journal of Machine Learning Research*, 2010, 11(12): 3371-3408.
- [26] MASCI J, MEIER U, DAN C, et al. Stacked Convolutional Auto-Encoders for Hierarchical Feature Extraction[C] // *International Conference on Artificial Neural Networks*. 2011: 52-59.
- [27] JIANG X, ZHANG Y, ZHANG W, et al. A novel sparse auto-encoder for deep unsupervised learning[C] // *Sixth International Conference on Advanced Computational Intelligence*. IEEE, 2014: 256-261.
- [28] JIA Y, SHELHAMER E, DONAHUE J, et al. Caffe: Convolutional Architecture for Fast Feature Embedding[C] // *Acm International Conference on Multimedia*. ACM, 2014: 675-678.
- [29] ABADI M. TensorFlow: learning functions at scale[J]. *Acm Sigplan Notices*, 2016, 51(9): 1.
- [30] SEIDE F. Keynote: The computer science behind the Microsoft Cognitive Toolkit: An open source large-scale deep learning toolkit for Windows and Linux[C] // *Ieee/acm International Symposium on Code Generation and Optimization*. IEEE, 2017.
- [31] YANG H, FRITZSCHE M, BARTZ C, et al. BMXNet: An Open-Source Binary Neural Network Implementation Based on MX-Net[C] // *ACM*. 2017: 1209-1212.
- [32] SANKARAN A, ARALIKATTE R, MANI S, et al. DARVIZ: deep abstract representation, visualization, and verification of deep learning models[C] // *Ieee/acm, International Conference on Software Engineering: New Ideas and Emerging Technologies Results Track*. IEEE, 2017: 47-50.
- [33] BOUFENAR C, BATOUCHE M. Investigation on deep learning for off-line handwritten Arabic Character Recognition using Theano research platform[C] // *Intelligent Systems and Computer Vision*. IEEE, 2017.
- [34] 魏英姿, 谭龙田, 欧阳海飞, 等. 玉米籽粒完整性识别的深度学习方法[J]. *沈阳理工大学学报*, 2016, 35(4): 1-6.
- [35] 李楠. 基于深度学习框架 Caffe 的路面裂缝识别研究[J]. *工程技术研究*, 2017(3): 20, 28.
- [36] 杜敬. 基于深度学习的无人机遥感影像水体识别[J]. *江西科学*, 2017, 35(1): 158-161.
- [37] 寇广, 汤光明, 王硕, 等. 深度学习在僵尸云检测中的应用研究[J]. *通信学报*, 2016, 37(11): 114-128.
- [38] 刘大伟, 韩玲, 韩晓勇. 基于深度学习的高分辨率遥感影像分类研究[J]. *光学学报*, 2016, 36(4): 298-306.
- [39] 樊恒, 徐俊, 邓勇, 等. 基于深度学习的人体行为识别[J]. *武汉大学学报(信息科学版)*, 2016, 41(4): 492-497.
- [40] 李婷. 基于深度学习的盲文识别方法[J]. *计算机与现代化*, 2015, 238(6): 37-40.
- [41] 阙希, 张永宏, 曹庭, 等. 利用多光谱卫星遥感和深度学习方法进行青藏高原积雪判识[J]. *测绘学报*, 2016, 45(10): 1210-1221.
- [42] HINTON G, DENG L, YU D, et al. Deep Neural Networks for Acoustic Modeling in Speech Recognition: The Shared Views of Four Research Groups[J]. *IEEE Signal Processing Magazine*, 2012, 29(6): 82-97.
- [43] 王山海, 景新幸, 杨海燕. 基于深度学习神经网络的孤立词语音识别的研究[J]. *计算机应用研究*, 2015, 32(8): 2289-2291.
- [44] 王强, 曾向阳. 深度学习方法及其在水下目标识别中的应用[C] // *中国声学学会水声学分会学术会议*. 2015: 139-141.
- [45] 张剑. 连续语音识别中的循环神经网络语言模型技术研究[D]. 郑州: 解放军信息工程大学, 2014.
- [46] LU X G, TSAO Y, MATSUDA S, et al. Speech enhancement based on deep denoising autoencoder[C] // *The 14th Annual Conference of the International Speech Communication Association*. Lyon: ISCA Archive, 2013: 436-440

- cation and endorsement[C]//European Conference on Programming Languages and Systems. Springer-Verlag,2010:64-84.
- [30] ASKAROV A,MYERS A. Attacker control and impact for confidentiality and integrity[J]. Logical Methods in Computer Science,2011,7(3):563-572.
- [31] VOLPANO D,SMITH G. Verifying secrets and relative secrecy [C]// Proceedings of 27th ACM SIGPLAN-SIGACT Symposium on Principles of Programming Languages. Boston, MA: ACM Computer Society Press,2000:268-276.
- [32] VOLPANO D. Secure introduction of one-way functions[C]// Proceedings of 13th IEEE Computer Security Foundations Workshop. Cambridge: IEEE Computer Society Press, 2000: 246-254.
- [33] CHONG S,MYERS A C. Security policies for downgrading [C] // 11th ACM Conference on Computer and Communications Security. Washington DC: ACM Computer Society Press,2004:198-209.
- [34] YAO J,TANG Y. Security Downgrading Policies for Competitive Bidding System[M]//Software Engineering and Knowledge Engineering: Theory and Practice. Springer Berlin Heidelberg, 2012:587-95.
- [35] 吴泽智,陈性元,杨智,等. 信息流控制研究进展[J]. 软件学报, 2017,28(1):135-159.
- [36] 孙聪,唐礼勇,陈钟. 基于下推系统可达性分析的程序机密消去机制[J]. 软件学报,2012,23(8):2149-2162.
- [37] 孙聪,唐礼勇,陈钟. 基于下推系统可达性分析的输出信道信息流检测[J]. 计算机学报,2011,38(7):103-107.
- [38] MICINSKI K,FETTER-DEGGES J,JEON J,et al. Checking Interaction-Based Declassification Policies for Android Using Symbolic Execution[C]//Proceedings of 20th European Symposium on Research in Computer Security. Vienna:Springer International Publishing,2015:520-538.
- [39] SABELFELD A,RUSSO A. From dynamic to static and back: Riding the roller coaster of information-flow control research [M]//Perspectives of Systems Informatics. Springer Berlin Heidelberg,2010,5947:352-365.
- [40] SHROFF P,SMITH S,THOBER M. Dynamic Dependency Monitoring to Secure Information Flow[C]// Proceedings of the 20th IEEE Symposium on Computer Security Foundations. Venice:IEEE Computer Society Press,2007:203-217.
- [41] RUSSO A,SABELFELD A. Securing timeout instructions in web applications[C]// Proceedings of the 22nd IEEE Symposium on Computer Security Foundations. Port Jefferson: IEEE Computer Society Press,2009:92-106.
- [42] 金丽,朱浩. 基于自动机监控的二维降密策略[J]. 计算机学报, 2015,42(7):194-199.
- [43] ASKAROV A,SABELFELD A. Tight enforcement of information-release policies for dynamic languages[C]// Proceedings of the 25th IEEE Symposium on Computer Security Foundations. Port Jefferson:IEEE Computer Society Press,2012:43-59.
- [44] SRIDHAR M,HAMLEN K W. Flexible in-lined reference monitor certification: challenges and future directions[C]// Proceedings of the 5th ACM Workshop on Programming Languages Meets Program Verification. Austin, Texas: ACM,2011:55-60.
- [45] 朱浩,陈建平,金丽. 二维降密策略的内联引用监控方法[J]. 计算机学报,2016,43(11A):352-354.
- [46] BOLO I,GARG D. Asymmetric Secure Multi-execution with Declassification[C]// Proceedings of the 5th International Conference on Principles of Security and Trust. Netherlands:Springer-Verlag New York,2016:24-45.
- [47] VANHOEF M,GROEF W D,DEVRIESE D,et al. Stateful Declassification Policies for Event-Driven Programs[C]// Proceedings of the 2014 IEEE 27th Computer Security Foundations Symposium. Vienna:IEEE Computer Society,2014:293-307.
- [48] ASKAROV A,SABELFELD A. Localized delimited release: Combining the what and where dimensions of information release [C]// Proceedings of the 2007 Workshop on Programming Languages and Analysis for Security. San Diego: ACM,2007:53-60.
- [49] MAGAZINIUS J,ASKAROV A,SABELFELD A. Decentralized delimited release[C]// Proceedings of the 9th Asian Conference on Programming Languages and Systems. Kenting, Taiwan:Springer-Verlag,2011:220-237.
- [50] 姜励,陈健,平玲娣,等. 多线程程序的信息抹除和降密安全策略[J]. 浙江大学学报(工学版),2010,44(5):854-862.
- [51] 金丽,朱浩. 多线程环境中的二维降密策略[J]. 计算机学报, 2015,42(12):243-246,282.
- [52] VAN DER MEYDEN R. Architectural refinement and notions of intransitive noninterference [J]. Formal Aspects of Computing,2012,24(4):769-792.
- [53] 周盈盈,范磊. 基于改进词向量模型的深度学习文本主题分类[J]. 计算机科学与应用,2016,6(11):629-637.
- [54] 李阳辉,谢明,易阳. 基于深度学习的社交平台细粒度情感分析[J]. 计算机应用研究,2017,34(3):743-747.
- [55] 雷亚国,贾峰,周昕,等. 基于深度学习理论的机械装备大数据健康监测方法[J]. 机械工程学报,2015,51(21):49-56.
- [56] 潘儒扬,李乡儒. 基于深度学习技术的恒星大气物理参数自动估计[J]. 天文学报,2016,57(4):379-388.
- [57] 谭娟,王胜春. 基于深度学习的交通拥堵预测模型研究[J]. 计算机应用研究,2015,32(10):2951-2954.
- [58] 潘志刚,刘三明,李莹,等. 基于深度学习网络的风电场功率短期预测研究[J]. 科技与创新,2015,43(19):4-6.
- [59] 夏春江,王培良,张媛. 基于深度学习的木材含水率预测[J]. 杭州电子科技大学学报,2015,35(1):31-35.
- [60] 姚俊杨,许继平,王小艺,等. 基于深度学习的湖库藻类水华预测研究[J]. 计算机与应用化学,2015,32(10):1265-1268.

(上接第15页)