

人工智能之表示学习

Report of Representation Learning

2020年第7期



清华大学人工智能研究院
北京智源人工智能研究院
清华-中国工程院知识智能联合研究中心

2020年9月

目录

报告说明.....	1
1. 研究范围.....	1
2. 研究方法.....	2
1. 概述篇.....	4
1.1 表示学习的概念.....	4
1.2 表示学习的特点和形式.....	5
1.3 技术发展历程.....	6
1.4 表示学习的典型应用.....	10
1.4.1 语音识别和信号处理.....	10
1.4.2 自然语言处理.....	11
1.4.3 内容推荐.....	12
2. 技术篇.....	14
2.1 表示学习的理论基础.....	14
2.1.1 向量空间模型.....	14
2.1.2 词袋模型.....	16
2.1.3 主题模型.....	18
2.1.4 独热表示与分布式表示.....	19
2.2 网络表示学习的主要算法.....	20
2.2.1 基于网络结构的网络表示学习.....	20
2.2.2 结合外部信息的网络表示学习.....	23
2.3 知识表示学习的主要方法模型.....	25
2.3.1 距离模型/结构表示	25
2.3.2 单层神经网络模型.....	25
2.3.3 能量模型.....	26
2.3.4 双线性模型.....	26
2.3.5 张量神经网络模型.....	27
2.3.6 矩阵分解模型.....	27

2.3.7 平移模型.....	27
2.4 表示学习领域必读论文解读.....	28
2.5 表示学习话题模型.....	35
2.6 领域专利申请情况.....	37
2.7 领域相关的国家自然科学基金 NSFC 项目.....	39
2.8 表示学习领域研究前沿动态.....	40
3. 人才篇.....	57
3.1 表示学习领域学者情况概览.....	57
3.2 代表性学者简介.....	61
3.2.1 国外代表性学者.....	61
3.2.2 国内代表性学者.....	73
4. 趋势篇.....	90
4.1 技术研究发展趋势.....	90
4.2 国家研究发展趋势.....	91
4.3 技术发展面临的挑战.....	91
参考文献.....	93

图目录

图 1	数据表示学习和神经网络的发展历程.....	8
图 2	Transformer 模型架构图.....	34
图 3	BERT 的整体预培训和微调程序	35
图 4	LDA 结构图	36
图 5	2010 至 2019 年期间表示学习相关专利申请量.....	38
图 6	2010 至 2019 年期间表示学习专利受理局排名.....	38
图 7	2010 至 2019 年期间表示学习相关专利申请排名前十机构.....	39
图 8	2010-2020 年国家自然科学基金 NSFC 项目数量前十的项目类型	40
图 9	2010-2020 年国家自然科学基金 NSFC 项目量前十依托单位	40
图 10	表示学习领域全球顶级学者分布图.....	57
图 11	表示学习领域顶级学者数量 TOP10 国家	58
图 12	表示学习领域顶级学者数量 TOP10 机构	58
图 13	表示学习领域学者的 h-index 分布	59
图 14	我国表示学习领域顶级学者分布图.....	60
图 15	表示学习领域中国学者合作论文数量 TOP10 国家	61
图 16	表示学习领域热点技术趋势图.....	90
图 17	表示学习领域国家的研究发展趋势.....	91

表目录

表 1	表示学习领域的顶级期刊和会议.....	1
表 2	VSM 模型中文本与空间的映射表.....	15
表 3	主题模型的四个类别.....	19
表 4	表示学习话题模型.....	36
表 5	2020 年表示学习领域研究前沿动态.....	41

报告说明

深度学习下的表示学习旨在将研究对象的语义信息表示为稠密低维实值向量,便于在低维空间中进行对象关系的语义关联计算,并有效解决数据稀疏问题,显著提升自然语言处理、计算机视觉和机器学习算法等任务的性能。

《人工智能之表示学习》报告主要从概念、理论模型、领域人才、技术趋势等 4 个部分,介绍表示学习的技术发展和最新研究进展,并展望该技术的未来发展方向与前景。

1. 研究范围

(1) 研究对象

期刊和会议所收录的表示学习主题相关的论文数据、以及专利数据等。

(2) 时间范围

报告研究时段为 2010-2020 年期间。

(3) 领域的国内外顶级期刊和会议范围

本报告所采用的表示学习领域顶级期刊和会议,是根据《CCF 推荐国际学术期刊和会议目录》和 ACM 计算机学分类系统相关子领域的 A 类期刊和会议作为数据来源,并征求领域顾问专家意见,而最终确定了可作为研究对象的表示学习领域的顶级期刊和会议,共计 10 个,包括 ICLR、NeurIPS、ICML、AAAI、IJCAI、ACL、EMNLP、CVPR、ICCV 以及 ECCV。这些期刊和会议的具体详细信息,如表 1 所示。

表 1 表示学习领域的顶级期刊和会议

序号	期刊/会议名称	简称
1	International Conference on Learning Representations	ICLR
2	Annual Conference on Neural Information Processing Systems	NeurIPS
3	International Conference on Machine Learning	ICML
4	AAAI Conference on Artificial Intelligence	AAAI
5	International Joint Conference on Artificial Intelligence	IJCAI
6	Annual Meeting of the Association for Computational Linguistics	ACL
7	Conference on Empirical Methods on Natural Language Processing	EMNLP

8	IEEE Conference on Computer Vision and Pattern Recognition	CVPR
9	IEEE International Conference on Computer Vision	ICCV
10	European Conference on Computer Vision	ECCV

2. 研究方法

借助科技情报大数据挖掘与服务系统平台 AMiner，本报告综合运用了文献分析、大数据分析和挖掘技术、特征抽取、人才画像等研究方法。

通过对 2010-2020 年期间上述来源的论文数据进行挖掘，基于“表示学习”领域的关键词，通过关键词智能匹配挖掘出所有相关论文。基于这些论文，进行进一步挖掘分析。

其中，“表示学习”领域的关键词由表示学习领域顾问组给出，具体包括：表示学习（Representation Learning）、分布式表示（Distributed Representation）、符号表示（Symbol Representation）、知识表示（Knowledge Representation）、语义表示（Semantic Representation）、稀疏表示（Sparse Representation）、词典学习（Dictionary Learning）、嵌入（Embedding）、特征学习（Feature Learning）、特征提取（Feature Extraction）、特征工程（Feature Engineering）、特征表示（Feature Representation）。

（1）人才画像分析法

通过以上领域关键词，对挖掘出的指定研究时段内该领域国内外顶级期刊和会议所收录的论文数据进行分析，获取论文学者信息，通过命名消歧和信息抽取等大数据分析和挖掘技术，对表示学习领域的专家学者进行学者画像，构建表示学习领域人才智库，然后根据学者画像信息进行领域人才相关分析。此外，还抽取论文作者的供职机构和机构信息，对不同国家和机构的研究者及论文数量进行统计。本报告中，人才分析维度包括作者所在机构、机构所属国家等。

（2）技术趋势分析法

借助 AMiner 平台的领域技术分析系统（<http://trend.aminer.cn>），通过挖掘和分析论文数据，获取表示学习领域相关论文中的关键词，然后统计这些关键词的起止年份，再按照窗格统计词频，对其进行词频分析和对比，得到表示学习领域的技术研究热点和发展趋势、国际趋势及机构趋势等相关结果。



1. 概述篇

1. 概述篇

近年来，以深度学习为代表的表示学习技术热度高涨，在语音识别、图像分析和自然语言处理领域获得广泛关注。表示学习旨在将研究对象的语义信息表示为稠密低维实值向量，在该低维向量空间中，两个对象距离越近则说明其语义相似度越高^[2]。知识表示学习则面向知识库中的实体和关系进行表示学习，该技术可以在低维空间中高效计算实体和关系的语义联系，有效解决数据稀疏问题，使知识获取、融合和推理的性能得到显著提升。本篇主要介绍表示学习的概念、特点以及技术发展历程。

1.1 表示学习的概念

表示学习（Representation Learning），也叫特征学习（Feature Learning），是一种将原始数据转换成为能够被机器学习方法有效开发的一种技术的集合。Bengio 等学者（2013）^[1]指出，数据的表示学习是为了能在构建分类器或其他预测器时更容易提取有用的信息；在概率模型中，好的表示是可以捕捉到所观察到输入的潜在因素的后验分布，也可用作有监督预测器的输入。

国内学者刘知远和孙茂松等^[2]认为，知识表示学习是面向知识库中实体和关系的表示学习。通过将实体或关系投影到低维向量空间，能够实现对实体和关系的语义信息的表示，从而高效地计算实体、关系及其之间的复杂语义关联。这对知识库的构建、推理与应用均有重要意义。

国内学者涂存超等^[3]（2017）、李志义等^[4]（2018）认为，表示学习旨在将研究对象的语义信息表示为稠密低维实值向量，以在低维空间中高效计算实体和关系的语义联系，并有效解决数据稀疏问题，使知识获取、融合和推理的性能显著提升。由于这种低维度的表示向量能够有效地显示出词语之间的语义关系，且更易于被应用到其他的系统当中，目前知识表示学习中的距离模型、单层神经网络模型、双线性模型、矩阵分解和翻译等模型已广泛应用在信息抽取、知识库自动问答系统，以及多媒体信息资源的处理与识别中。特别地，以深度学习为代表的表示学习技术在语音识别、图像分析和自然语言处理领域获得了更大关注，特征表示学习（Feature Representation Learning）逐步成为机器学习的一个新兴分支。

孙晓玲和丁莹^[5]（2018）研究文章指出，深度学习中的表示学习，将研究对象（如词汇、短语、句子等）的语义信息表示为稠密低维的实值向量。这种分布式表示可以看作是对人脑神经系统的多个神经元的模拟，对象在该语义空间中的相对距离代表它们之间的语义关联度。

1.2 表示学习的特点和形式

在表示学习算法出现之前，机器学习研究人员需要利用手动特征工程（Manual Feature Learning）等技术从原始数据的领域知识（Domain Knowledge）建立特征，然后再部署相关的机器学习算法。虽然手动特征工程对于应用机器学习很有效，但它同时也是很困难、很昂贵、很耗时的，并依赖于强大专业知识。特征学习弥补了这一点，它使得机器不仅能学习到数据的特征，并能利用这些特征来完成一个具体的任务。

类似于机器学习，表示学习可以被分为两类：**监督式表示学习（Supervised Representation Learning）**和**无监督式表示学习（Unsupervised Representation Learning）**。在监督式表示学习中，被标记过的数据被当作特征用来学习，例如神经网络（Neural Networks）、多层感知器（Multi-Layer Perception）和监督字典学习（Supervised Dictionary Learning）等。在无监督式表示学习中，未被标记过的数据被当作特征用来学习，例如无监督字典学习（Unsupervised Dictionary Learning）、主成分分析（Principal Component Analysis）、独立成分分析（Independent Component Analysis）、自动编码（Auto-encoders）、矩阵分解（Matrix Factorization）、各种聚类分析（Clustering）及其变形等。

网络表示是衔接网络原始数据和网络应用任务的桥梁。网络表示学习算法则是从网络数据中学习得到网络中每个节点的向量表示，作为节点的特征应用于后续的网络应用任务，如节点分类、链接预测和可视化等^[3]。

知识表示学习实现了对实体和关系的分布式表示，**具有显著提升计算效率、有效缓解数据稀疏、实现异质信息融合三大优势^[2]**，对于知识库的构建、推理和应用具有重要意义。

(1) **显著提升计算效率**。基于独热表示的知识库三元组表示，需要设计专门的图算法计算实体间的语义和推理关系，计算复杂度高、可扩展性差。而表示学习得到的分布式表示，则能够高效地实现语义相似度计算等操作。

(2) **有效缓解数据稀疏**。由于表示学习将对象投影到统一的低维空间中，使每个对象均对应一个稠密向量，从而有效缓解数据稀疏问题。一方面，基于独热表示的图算法，由于受到大规模知识图谱稀疏特性的影响，往往无法有效计算很多对象之间的语义相似度。而表示学习中每个对象的向量均为稠密有值的，可以度量任意对象之间的语义相似程度。另一方面，表示学习将大量对象投影到统一空间的过程，也能够将高频对象的语义信息用于帮助低频对象的语义表示，提高低频对象的语义表示的精确性。

(3) **实现异质信息融合**。不同来源的异质信息需要融合为整体，才能得到有效应用。目前不同知识库的构建规范和信息来源均有不同，大量实体和关系在不同知识库中的名称也不同。如果基于网络表示，该任务只能通过设计专门图算法来实现，效果和效率都低下。通过设计合理的表示学习模型，将不同来源的对象投影到同一个语义空间中，就能够建立统一的表示空间，实现多知识库的信息融合。此外，表示学习能为异质对象提供统一表示空间，轻而易举实现词、句子、文档和知识库实体等异质对象之间的语义关联计算。

1.3 技术发展历程

从模型层次的角度,可将表示学习分为**浅层特征学习 (Shallow Learning)**和**深度特征学习 (Deep Learning)**两个阶段。

大约 100 多年前，许多数据表示学习方法被提出。其中，为了通过线性投影来学习数据的低维表示，K. Pearson 在 1901 年提出主成分分析 (Principal Component Analysis, PCA)，之后 R. Fisher 在 1936 年提出线性判别分析 (Linear Discriminant Analysis, LDA)。PCA 和 LDA 都是最早的数据表示学习算法。然而，PCA 是一种无监督的方法，而 LDA 是一种有监督的方法。基于 PCA 和 LDA，人们提出了各种扩展，如 kernel PCA 和广义判别分析 (General Discriminant Analysis, GDA)。

2000 年，机器学习界开展了流形学习的研究，旨在发现高维数据的内在结构。不同于以前的全局方法，如 PCA 和 LDA，流形学习方法通常是基于局部的，如等距特征映射（Isomap）和局部线性层理（Locally Linear Embedding, LLE）。2006 年，G. Hinton 和他的合著者成功地将深度神经网络应用于降维，并提出了“深度学习”的概念^[12]。如今，深度学习算法因效率高，已被应用于人工智能之外的许多领域。

另一方面，人工神经网络的研究经历了一个艰难的过程，有很多成功和困难。1943 年，W. McCulloch 和 W. Pitts^[6]创造了第一个用于神经网络的人工神经元——线性阈值单元，在之后的研究中也称为 M-P 模型。1949 年，D. Hebb 提出了基于神经可塑性机制的学习假设，也被称为 Hebbian 理论^[7]。从本质上说，M-P 模型和 Hebbian 理论为人工智能领域的神经网络研究和连接主义的发展铺平了道路。1958 年，F. Rosenblatt^[8]创建了感知器（Perceptron）模型，一种用于二进制分类的双层神经网络。然而，M. Minsky 和 S. Papert^[9]指出感知器甚至不能解决异或（XOR）问题。

神经网络的研究曾一度停滞不前。直到 1974 年，P. Werbos^[10]提出了 BP (Back Propagation, BP) 算法来训练多层感知器（MLP）。在 1986 年，D. Rumelhart, G. Hinton 和 R. Williams^[11]提出了经典的浅层特征学习算法——神经网络反向传播算法（Error Back-Propagation, BP 算法），成为表示学习研究正式进入浅层特征学习阶段的标志。其文章同时指出，反向传播算法可以在神经网络的隐藏层中生成有用的数据内部表示。它利用人工神经网络将大量训练数据中的特征以统计学的方法进行获取与预测，更适合于学习和存储大量输入-输出模式的映射关系。BP 神经网络模型虽被称作多层感知器，但实际上只支持一个隐藏层（Hidden Layer），其拓扑结构包括输入层（Input Layer）、隐藏层（Hidden Layer）和输出层（Output Layer）。

使用反向传播算法，虽然理论上可以训练多层神经网络，但存在两个问题：模型过拟合和梯度扩散。2006 年，G. Hinton^[12]通过对深度神经网络进行贪婪的分层预训练和精细化的思想，在表示学习研究上取得了突破性进展。这个使神经网络社区感到困惑的问题得到了相应的解决。随后，又有许多深入算法被提出，并成功地应用于各个领域。

表示学习的技术发展历程，如图 1 所示。




Fig. 1. The development of data representation learning and neural networks.

来源: Zhong et al (2016). An overview on data representation learning: From traditional feature learning to recent deep learning

图 1 数据表示学习和神经网络的发展历程^[13]

20 世纪 90 年代后，多种浅层机器学习模型相继出现，包括 Cortes 等^[14]提出的支持向量机（SVM）模型，Greene^[15]提出的最大熵（LR）以及 Boosting 模型等，在内容推荐、分类、网页搜索等方面取得了显著效果。这些模型的共同特点是不含隐藏层或仅有一层隐藏层节点，在学习过程中容易因隐藏层数量不足而造成学习效率低、收敛速度慢的问题。其次，模型的学习信号在反向传播的过程中会逐渐减弱，学习过程对神经网络的设计要求较高，而隐藏层节点数量的确定问题目前仍缺乏较全面的指导理论。由于浅层学习算法存在的局限，Hinton 等^[16]学者提出了基于深度信任网络（Deep Belief Network）的无监督贪婪逐层训练算法。其主要观点是：①充分利用多隐层人工神经网络的特征学习能力，将学习得到的特征用于数据分类处理与可视化；②通过无监督“逐层初始化”（Layer-Wise Pre-Training）以应对深度神经网络在训练上所带来的困难。随后，Ngiam 等^[17]进一步提出了多层自动编码器（Multilayer Auto-encoder），为解决深层网络结构的相关优化问题带来了突破。自此，表示学习研究进入深度特征学习阶段。

与浅层特征学习相比，深度学习凸显的特点有：（1）**强调模型结构的深度**，通常有 5 层以上，甚至多达 10 余层的隐藏层节点，利用多层隐藏层对海量数据进行充分的处理，得到更有针对性的特征，从而提升学习分类或预测的准确性。

（2）**突出特征学习的重要性**，通过逐层特征变换，将样本在原空间的特征表示到一个新的特征空间，从而简化分类与预测的过程。（3）**能够通过深层非线性网络结构的学习实现复杂函数逼近**，完成输入数据的分布式表示，具有从样本数

据集中学习数据集本质特征的能力。(4)能够自动学习数据的另一种表示方法,并将其作为特征加入原有问题的特征集合中,从而进一步提高学习效果。

研究^[4]显示,深度学习的成果不断涌现。2009年,Bengio^[18]在研究中指出,用特定的方法设定训练样本的初始分布和排列顺序可以产生更好的训练结果;Glorot等^[19]探讨了隐层非线性映射关系的选择和网络的深度相互影响的问题;2012年,Bengio等学者^[20]进一步描述了用于有效训练的大型深度结构神经网络的超参数的影响因素。此类以深度学习为代表的算法在各种单模态数据处理上的成功为其应用到复杂多模态数据处理奠定了基础。吴海燕^[21]提出了同时进行特征学习和有监督的分类学习的联合框架以及半监督自动编码器模型;2013年Tomas Mikolov和Jeff Dean等人做word2vec,占据“天时、地利、人和”,深度学习因算法简单有效而开始发热。现在word2vec已有超过1万多引用,后面的扩展也很多,如pharagraph2vec、doc2vec, context2vec。最近的进展是ELMo、OpenAI的GPT和谷歌的BERT。2016年,Andreas等^[22]提出了基于模块神经网络(NMN)的视觉问答框架,利用模块化神经网络对图像进行成分切分,实现动态识别图像内容及颜色;朱陶等^[23]在K-means聚类获取训练样本虚拟标签和卷积核学习之上,提出了前向无监督卷积神经网络的人脸表示学习方法;李志宇等^[24]提出了基于动态阻尼正负采样的社会网络结构特征嵌入模型(DNPS),构建了针对新增节点的动态特征学习方法。在特征抽取方面,李志义等^[25]在条件随机场模型(Conditional Random Fields, CRFs)的基础上,提出了基于依存语法的<评价特征,评价词>对抽取方法。不难看出,关于表示学习的研究已从最初的简单图像、语音识别转向到了基于深度学习的情感分类、人体行为识别、跨模态检索、信息推荐等更复杂的领域发展。

表示学习的另一个脉络就是扩展到网络数据上,在NLP领域的Structured Embedding、TransE等模型更多的是语言中的局部结构信息,而网络中还有更加复杂的拓扑结果。原Stony Brook大学的Bryan提出DeepWalk,把word2vec稍微扩展了一下,应用于网络数据,这篇文章获得了当年KDD的最佳论文和后来KDD的最佳博士论文。很快这个工作吸引了大量关注,Jian Tang(原北大、微软,现在MILA)等人做了两阶扩展,斯坦福的Jure Leskovec做了面向社交网络的“三阶”扩展node2vec,后来清华也给出了一个理论证明,证明这些不同方法

本质上都在做一个矩阵分解，并基于此提出了一个 NetMF 的算法以及其适用于大规模网络的实现 NetSMF。ProNE 是另一个清华作品，其主要特点是高效和高精度。该方法非常简单，本质上是在原来的表示学习上引入了一个类似卷积但又不是卷积的操作，大大提高了精度。

最近的网络表示学习更多的是用卷积网络直接对图做，大方向是 Graph Neural Network，最早是 Siena 大学的 Marco 等人在 2005 和 2009 年提出的，但当时没引起太大关注。后来 Yann Lecun 提出的 Graph Convolutional Networks，还有 Kipf & Welling 等人提出的 Semi-Supervised 的 GCN。这一系列的研究本质上就是 Neural Message Passing，在最近引起大量关注。斯坦福的 Jure 也提出了 GraphSage，利用 NMP 简化了卷积，提高了速度，并且支持 Inductive Learning，再后来 Yoshua 团队又提出了 Graph Attention Network，进一步提高了图卷积精度。最近网络表示学习非常热，在未来若干年还会继续是个研究热点。

1.4 表示学习的典型应用

知识表示学习距离真正实用还很远。不过，知识表示学习得到的分布式表示有以下典型应用^[2]：相似度计算、知识图谱补全、关系抽取、自动问答、实体链指等。

1. **相似度计算**。利用实体的分布式表示，我们可以快速计算实体间的语义相似度，这对于自然语言处理和信息检索的很多任务具有重要意义。

2. **知识图谱补全**。构建大规模知识图谱，需要不断补充实体间的关系。利用知识表示学习模型，可以预测 2 个实体的关系，这一般称为知识库的链接预测（Link Prediction），又称为知识图谱补全（Knowledge Graph Completion）。

3. **其他应用**。知识表示学习已被广泛用于关系抽取、自动问答、实体链指等任务，展现出巨大的应用潜力。随着深度学习在自然语言处理各项重要任务中得到广泛应用，这将为知识表示学习带来更广阔的应用空间。

1.4.1 语音识别和信号处理

广义上讲，表示学习是一种通过输入数据的转换来学习输入数据表示的技术，其主要目标是在诸如分类、预测等任务中产生抽象且有用的表示。有学者研究表

明^[26]，在语音技术中利用表示学习技术的一个重要原因是语音数据与二维图像数据的根本不同。图像可以整体或以补丁的形式进行分析，但是研究语音必须按顺序分析以捕获上下文背景。

相关研究表明，近年来学界和工业界对神经网络、深度学习和表示学习的重新关注在语音识别（Speech Recognition）领域产生了重大影响。微软在 2012 年发布了基于深度学习的微软音频视频索引服务（Microsoft Audio Video Indexing Service, MAVIS）语音系统的新版本^[27]。与基于高斯混合技术进行声学建模和训练的最新模型相比，在相同数量的数据（309 小时的语音）的情况下，微软研究团队在四个主要基准上将单词错误率降低了约 30%（例如，在 RT03S 上从 27.4% 降至 18.5%）。在更小的大型词汇语音识别基准上（具有 40 小时的语音的 Bing 移动业务搜索数据集），Dahl 等人^[28]进一步降低了 16% 到 23% 的错误率。表示学习算法也已应用于音乐，表现大大超过了复音转录的最新技术^[29]，相对误差在 4 个数据集的标准基准下降低了 5% 至 30%。

1.4.2 自然语言处理

表示学习能够充分利用自然语言对象间的语义相似度信息，弥补短文本在有效表示、数据稀疏干扰等方面的不足。

有研究显示，除语音识别外，表示学习同样在自然语言处理（Natural Language Processing, NLP）领域有很多应用。Hinton^[30]于 1986 年引入了符号数据的分布式表示形式，并由 Bengio 等人^[31]首先在统计语言建模的背景下于神经网络语言模型^[32]当中进行了开发。它们都是基于学习每个单词的分布式表示而建立的，被称为单词嵌入。加上卷积架构，Collobert 等人^[33]开发了 SENNA 系统，该系统在语言建模，词性标记，分块，命名实体识别，语义角色标记和句法解析等任务之间共享表示。SENNA 在这些任务上接近甚至超越了当前最新技术，但比传统预测器更简单迅速。学习单词嵌入可以与学习图像表示相结合，以使得文本和图像相连接。这种方法已成功用于构建 Google 的图像搜索，使用大量数据在同一空间中匹配图像和查询请求^[34]，这个方法最近已扩展到更深的多模式表示形式^[35]。通过增加隐藏层的递归，神经网络语言模型得到了改进^[36]。类似的模型已经应用于统计机器翻译中^[37]，并改进了困惑度和 BLEU 评分。递归自动编

码器（可归纳递归网络）也已被用来在全句复述检测中，它的效果超过了最新技术^[38]，几乎使复述检测的 F1 分数翻了一番。表征学习还可以用于执行词义歧义消除^[39]，将 Senseval-3 的子集的准确性从 67.8% 提高到 70.2%（可以应用于主谓宾句子）。并且它也已成功地用于超越情绪分析领域的技术^{[40][41]}。

随着以深度学习为代表的表示学习技术在多个领域的成功应用，许多研究者^[42]开始着手研究基于表示学习的知识库问答技术（Question Answering Over Knowledge Base, KBQA）。KBQA 的基本假设是把知识库问答看作是一个语义匹配的过程。通过表示学习知识库以及用户问题的语义表示，将知识库中的实体、关系以及问句文本转换为一个低维语义空间中的数值向量，在此基础上，利用数值计算，直接匹配与用户问句语义最相似的答案。

1.4.3 内容推荐

研究显示^[5]，随着大数据时代的信息资源大幅增加，海量数据与个性化信息获取之间的矛盾日益突出。为缓解这一问题，学术推荐技术受到了重视。个性化推荐在现实中具有重要的意义，如何有效地反映用户的不同偏好以及提高推荐的准确性是非常值得研究的课题。

基于内容的推荐主要依据推荐对象（论文、用户等）本身特征与用户基本特征或行为特征之间的匹配程度，决定是否向某一用户推荐某对象。内容推荐目前主要将用户或推荐对象表示成基于文本特征的向量空间模型，或者是利用潜在语义分析方法进行分析。但是，由于大量信息往往具有多模态、数据异构、稀疏等复杂特征，融合多源异构数据的推荐研究面临着严峻的挑战。

深度学习中的表示学习由于能够表征研究对象的语义特征，以及将不同类型的数据映射到一个相同的空间中，能够有效地利用多元异构数据。已经有学者探讨将深度学习技术融入推荐系统中，通过从海量用户生成内容中学习用户和项目的语义表示，构建推荐模型。



2. 技术篇

2. 技术篇

在语音交互的 AI 时代，深度学习的出现与发展使自然语言处理（NLP）技术取得了重大的突破。深度学习的重点之一则是语言表示学习，本篇主要从表示学习的理论基础、主要方法、最新科研进展及代表性论文解读等方面进行相关技术介绍。

2.1 表示学习的理论基础

表示学习可以看作是对人脑的学习能力这一工作机制的模仿。现实世界中的实体是离散的，不同对象之间有明显的界限。人脑通过大量神经元上的激活和抑制存储这些对象，形成内隐世界。分布式表示的向量可以看作模拟人脑的多个神经元，每维对应一个神经元，而向量中的值对应神经元的激活或抑制状态。

本节主要介绍了表示学习的几种理论模型，包括向量空间模型（Vector Space Model）、词袋模型（Bag-Of-Words Model）、主题模型（Topic Model）、独热表示（One-Hot Representation）与分布式表示（Distributed Representation）等。

2.1.1 向量空间模型

向量空间模型（Vector Space Model, VSM）由 Salton 等人于 20 世纪 60 年代末提出，用于文本的自动索引构建，并成功地应用于著名的 SMART 文本检索系统。之后，VSM 在文本分类、自动标引、信息检索等许多领域得到了广泛的应用。近年来 VSM 是在文本挖掘系统中应用较多且效果较好的方法，其基本思想是以向量表示文本，多个文本向量组成文本集的表达。

VSM 用简洁的特征向量来表示文档，在进行特征选择时，不使用大量的句法语法信息，也无需对文档进行复杂的语义处理^[43]。

向量空间模型将包含 n 个文本和 m 个不重复词语的文本集合表示成一个大小为 $n \times m$ 的文本-词条矩阵（Document - Term Matrix）。这样，文本集可以用文本集矩阵 $M(n, m)$ 表示， n 代表文本数， m 代表词数，矩阵行代表文本，矩阵列代表文本中出现的词。

在向量空间模型中，文本空间被看作是由一组正交词条向量所组成的向量空间，每个文本表示为其中的一个范化特征向量 $V(d)=(t_1, w_1; t_2, w_2; \dots t_m, w_m)$ ，其中 t_j 为词条项，可以为单词，也可以为词组； w_j 为 t_j 在文本 d 中的权值，一般定义为 t_j 在文本 d 中出现频率或频率的函数。将 $t_1, t_2, \dots t_m$ 看成一个 m 维坐标系中的坐标轴， $w_1, w_2, \dots, w_m$ 为在坐标系中对应文本 d 的坐标值。这样，这些正交词条向量就组成了一个文本向量空间，每个文本都可映射为此向量空间的一个向量：

$$(d)=(t_1, w_1; t_2, w_2; \dots t_m, w_m), \text{ 简称 } d(w_1, w_2, \dots, w_m)$$

这样，就可以把文本信息的表示和匹配问题转化为向量空间中向量的表示和匹配问题来处理。

文本与向量空间的关系描述，如表 2 所示。

表 2 VSM 模型中文本与空间的映射表^[43]

文本视角	向量空间模型视角
文本	向量空间中的一个向量
单词或词组	向量的一个维
文本集合	分布在空间中的一组向量集
词的权重	向量的一个维度值
两文本之间的相似程度	空间中两个向量的夹角 θ

当文本被表示成向量空间模型时，可以借助向量之间的某种距离来表示文本之间的相似程度，目前常用的相似度计算公式有下面两种方法：

1. 向量之间的内积

$$\text{sim}(d_1, d_2)=\sum_{k=1}^m w_{1k} \times w_{2k}$$

内积代数数值越大，相似度越大。

2. 夹角的余弦值

$$\text{sim}(d_1, d_2)=\cos \theta = \frac{\sum_{k=1}^m w_{1k} \times w_{2k}}{\sqrt{(\sum_{k=1}^m w_{1k}^2)(\sum_{k=1}^m w_{2k}^2)}}$$

其中， w_{1k}, w_{2k} 是向量 d_1, d_2 中的单词的权重。夹角越小，余弦值越大，相似度越大，两个文本越相似，所以最常用的文本相似性度量方法还是夹角的余弦值。

VSM 的优点^[43]主要表现在：

1. 将复杂的文本简单地表示为由特征项组成的多维空间中的一个向量，

这易于操作和计算。

2. 特征项权重的引入改善了布尔模型的缺陷。
3. 通过相似度函数的计算来匹配两个相似文本，使得属性相似的文本尽可能地聚在一起，从而提高了匹配效率。
4. 对大规模的文本集合有较快的处理速度，能够保证许多应用中的时间复杂性要求。
5. 不依赖于某个特定领域。

但是，VSM 也存在一些不足：

1. 当文档数目比较大并且特征向量是高维的情况下相似度的计算会变得相当大^[43]。
2. 向量空间模型的基本假设是特征词之间是相互独立的，这个假设在实际中并非总是适合的，因为在自然语言中，词与词之间存有同义、近义、从属等关系^[43]。
3. 对处理结果的可解释性较差^[44]。
4. 在当前大规模或超大规模真实文本环境中的算法有效性需要验证^[44]。

VSM 理论在文本信息处理中具有广泛适应性的应用基础。自被提出 30 余年来，凭借着简洁的形式化表示、有效的匹配算法设计以及较为满意的处理结果，向量空间模型在文本信息处理领域中一直占据着非常重要的地位，并近乎成为文本处理领域的经典方法。当前，典型的基于 VSM 理论的文本信息处理主要包括以下几个分支领域：文本检索（Text Retrieval）、文本分类（Text Categorization/Classification）、文本过滤（Text Filtering）、文本聚类（Text Clustering）、文本浏览与可视化（Text Browsing and Visualization）等。

2.2.2 词袋模型

词袋（Bag of Words, BOW）是用于描述文本的一个简单数学模型，也是常用的一种文本特征提取方式。在信息检索中，词袋模型（Bag-of-Words Model）假定一个文本是若干个词汇的集合。该文本中，每个词汇都是互不相关的且忽略其次序和语法。词袋模型从文档的所有单词中提取特征单词，记录这些单词的数

量，并且用这些特征项矩阵建模。由此，将文本转换成数值形式，用于机器学习算法训练^[45]。

一个文档的单词矩阵是一个记录出现在文档中的所有单词的次数。因此，一份文档能被描述成各种单词权重的组合体。通过设置条件，可以筛选出更有意义的单词，还可以构建出现在文档中所有单词的频率直方图，这就是一个特征向量。这个特征向量被用于文本分类^[45]。

每一样本都以特征向量集的形式与词袋模型相关联。记为 $X_i = \{x_{ij}, |i=1, 2, \dots, N; j=1, 2, \dots, N_i\}$ 表示第 i 个样本对应的特征向量集，其中 $x_{ij} \in \mathbb{R}^D$ 表示第 i 个样本的第 j 个特征向量， D 为特征向量的维数。对于图像样本而言，特征向量可以是 SIFT 特征、LBP 特征等，对于文本样本，特征向量可以是词频特征，具体要根据样本类内一致性和类间差异性来选择最优的特征向量。 N_i 表示第 i 个样本所提取的特征向量的数量^[45]。

经典词袋模型使用其量化特征的固定长度直方图表示每一个样本，其中每个直方图 bin 都对应一个码字。在硬分配中，每个特征被量化到其距离最近的码字，而在软分配中，计算每个特征对不同码字的权重。为了学习码本，对于 N 个样本构成的特征向量集合 $S = \{X_i | i=1, 2, \dots, N\}$ ，首先要进行聚类运算，将特征向量划分到不同的簇中。假设簇的数量为 N_k ，也即通过聚类运算将 N 个特征向量集划分到 N_k 个簇中。每一个簇都有一个聚类中心，称为质心，对应的码字记为 $\mathbf{v}_k \in \mathbb{R}^D$ ($k=1, 2, \dots, N_k$)。由这样码字可以生成码本 $V \in \mathbb{R}^{D \times N_k}$ ，其中，码本的列向量是每一个簇的质心的特征向量集。这些质心用于对特征向量进行量化。通常只对 s 的一个子集进行聚类，这样可以减少训练时间，而且对学习结果几乎没有影响。还应该注意的是，码本只需要学习一次，然后就可以用其对任何样本进行编码^[45]。

为了对第 i 个样本进行编码，计算每个特征向量 x_{ij} 和每个码字 $\mathbf{v}_k$ 之间的相似度，为

$$d(x_{ij}, \mathbf{v}_k) = \exp\left(\frac{-\|\mathbf{v}_k - x_{ij}\|_2}{g}\right) \quad (1)$$

参数 g 用于控制量化过程，硬分配使用较小的值(通常取 $g < 0.01$)，软分配使用较大的值(通常取 $g > 0.01$)。

然后，采用 L1 范数对相似度进行归一化，为

$$u(x_{ij}, v_k) = \frac{d(x_{ij}, v_k)}{\|d(x_{ij}, v_k)\|_1} \quad (2)$$

该向量描述了特征向量 x_{ij} 与码字 v_k 之间的相似性。

最后，统计第 i 个样本的特征向量集 X_i 中所有样本的相似度，得到直方图特征，为

$$s(X_i) = \frac{1}{N_i} \sum_{j=1}^{N_j} u(x_{ij}, v_k) \quad (3)$$

这些直方图特征可以用于描述每个样本，进一步进行样本的检索。

需要注意，经典词袋模型的训练和编码过程是无监督的，不需要标签数据。

2.2.3 主题模型

主题模型 (Topic Model) 是通过建模的方法，找出文字中隐含的主题^[46]。它是一种应用十分广泛的生成式模型 (Generative Model)，在信息检索、文本挖掘、自然语言处理和机器学习中都有广泛的应用。

主题就是一个概念、一个方面。它表现为一系列相关的词语，而与这个主题时常一起出现的词，则与这个主题具有较高的相似性。主题模型大多是基于数学方法进行计算的。通常可以用概率的方法来计算，与主题词越为相关的词，往往其概率值较大。

在主题模型的算法中，最经典的、最常用的模型之一是隐含狄利克雷分配 (Latent Dirichlet Allocation, LDA)，其他的主题模型大都充分利用了 LDA 的思想去设计。

LDA 模型是一种对离散数据集 (如文档集) 建模的概率增长模型，可以对文本数据的主题信息进行建模，另外，在保留文档本质统计信息的同时进行简短的描述，有助于高效地处理大规模的文档集^[46]。LDA 认为一个离散数据集合 (如文档集合、图片集合) 是由隐含在数据集合背后的主题集生成的，这个集的每一个主题都是词的概率分布。

LDA 模型是典型的有向概率图模型，具有清晰的层次结构，包含词、主题、文档三层，因此又被称为三层贝叶斯概率模型。其中，文档到主题服从狄利克雷

分布，主题到词服从多项式分布。这样，每一篇文档由一些主题所构成的概率分布组成，而每一个主题又由很多单词所构成的概率分布组成^[46]。此外，LDA 模型中是基于词袋假设的，也就是在模型中不考虑词汇出现的顺序而只是考虑它们出现的次数^[46]。

在应用的过程中，传统的 LDA 模型可能存在强制分配隐含主题的问题，另外，由于自动分配隐含主题，可能会造成主题模型密度过于稀疏的问题。由此，Ramage 等人于 2009 年提出了 Labeled-LDA (Labeled Latent Dirichlet Allocation) 模型。Labeled-LDA 模型是一个有监督的机器学习技术，所要刻画的文档集合的结构是：文档集合中的所有文档被按类别划分，每一类又讨论若干个隐含主题。这样，Labeled-LDA 模型比标准的 LDA 模型多了一层，即文档类别层，而主题是在模型训练初期给定的。

主题模型可以分为四大类：（1）无监督的、无层次结构的主题模型；（2）无监督的、层次结构的主题模型；（3）有监督的、无层次结构的主题模型；（4）有监督的、层次结构的主题模型。如表 3 所示。

表 3 主题模型的四个类别

类别	对应模型
无监督的、无层次结构	PLSA, LDA, Correlated Topic Model, PAM, Concept Topic Model 等
无监督的、有层次结构	HLDA, HDP, HPAM 等
有监督的、无层次结构	S-LDA, Disc-LDA, MM-LDA, Author-Model, Labeled LDA, PLDA 等
有监督的、有层次结构	hLLDA, HSLDA 等

2.2.4 独热表示与分布式表示

独热表示 (One-Hot Representation) 是把文本的单词作为基本单位进行编码，编码后的向量中只有数字 0 和 1，且其中只有一个维度是 1，而其位置即表示这个单词在词汇表里的位置，其他维度的值都是 0。独热表示存在两大问题：一是独热表示的向量为稀疏表示，词汇表的大小决定了向量的维度大小，而当词汇表里单词很多时，向量的维度就会很大；且其表示能力弱，N 维度大小的向量仅能表示 N 个单词。二是不同单词使用独热表示得到的向量之间是相互独立的，不能表示一个单词与另一个单词的语义相似度^[47]。

分布式表示 (Distributed Representation) 的概念最早由 Hinton 等人^[48]为了区别于独热表示而提出。与独热表示只使用向量的一个维度不同, 分布式表示则是用稠密实数向量来表示一个单词 (向量多于一个维度非 0, 通常为低维向量)。

相比于独热表示, 分布式表达具有许多优点^[49]。首先, **分布式表示可以编码不同单词之间的语义关联**。分布式表示使用低维稠密实数向量来表示单词。在该低维向量空间中, 可以根据距离或角度等度量方式, 衡量两个单词间的相似程度。其次, **分布式表示具有更强的泛化能力**。当学习到已有概念 a 的新知识时, 使用分布式表示, 可以自动的泛化到相似的概念 b 。假设对于概念 a , 学习到新知识 a 喜欢概念 c , 表示为 $\text{like}(a, c)$, 则此知识可以自动泛化到 $\text{like}(b, c)$, 因为 a 与 b 具有相似的表达输入。再者, **分布式表示具有比独热表示更强的表示能力**。

分布式表示自提出以来, 已被广泛应用于单词、短语、概念、句子、文档和社会网络等对象的表示学习中。在实际应用中, **分布式表示能有效缓解数据稀疏问题**。对于分布式表示的性能, 当前业内学者存在着许多争论, 也并无定论, 还有待进一步深入研究^[49]。

需要注意, 在自然语言处理领域, 有一个容易与分布式表示混淆的概念: 分布表示 (Distributional Representation) 或分布语义 (Distributional Semantic)。分布语义主要是指单词的语义是通过上下文的分布来表示, 一般表示形式是高维向量, 每个维度对应于与单词的上下文。这与分布式表示是两个层面的概念。分布语义强调单词的语义来自于其上下文, 这里的“分布”指的是概率分布。而分布式表示, 则是强调表示形式采用的是一种分布式的形式。

2.2 网络表示学习的主要算法

网络表示学习算法将网络信息转化为低维稠密的实数向量, 并将其用作已有的机器学习算法的输入。本部分将介绍几种主要的网络表示学习算法。

2.2.1 基于网络结构的网络表示学习

2.2.1.1 基于矩阵特征向量计算

早期的用于网络表示学习的算法基本都属于此类, 主要包括: 局部线性表示 (Locally Linear Embedding)、Laplace 特征表 (Laplace Eigenmap)、有向图表

示(Directed Graph Embedding)等。这类计算方法强烈地依赖于关系矩阵的构建,并且对于大规模的网络数据来说是非常耗时的^[3]。

局部线性表示,假设节点的表示是从同一个流形中采样得到的。一个节点的表示可以通过它的邻居节点的表示的线性组合来近似得到。局部线性表示使用邻居节点表示的加权和与中心节点表示的距离作为损失函数,将最小化损失函数的优化问题最终转化成某个关系矩阵特征向量计算问题求解。

Laplace 特征表,假设两个相连的节点的表示应该相近,而表示相近是由向量表示的欧氏距离的平方来定义。该优化问题可以类似地转化为 Laplace 矩阵的特征向量计算问题。

有向图表示,进一步扩展了 Laplace 特征表方法,给不同点的损失函数以不同的权重。其中,点的权重是由基于随机游走的排序方法来决定,如 PageRank。

2.1.1.2 基于简单神经网络的算法

基于简单神经网络的表示学习算法主要包括 DeepWalk 算法、LINE 算法等。

DeepWalk 算法^[50]将深度学习中的技术引入到网络表示学习领域。DeepWalk 算法充分利用了网络结构中的随机游走序列的信息,只依赖于局部信息,所以可以适用于分布式和在线系统,避免了使用邻接矩阵把所有信息存储于内存中处理而面临着较高的计算时间和空间消耗的缺陷;此外,对随机游走序列进行建模还可以降低建模 0-1 二值邻接矩阵的方差和不确定性。

DeepWalk 首先在网络上采样生成大量的随机游走序列,然后用 Skip-gram 和 Hierarchical Softmax 模型对随机游走序列中每个局部窗口内的节点对进行概率建模,最大化随机游走序列的似然概率,并最终使用随机梯度下降学习参数。

另一个代表性的网络表示学习算法 LINE 算法^[51]是适用于大规模的有向带权图的表示学习算法。为了对节点间的关系进行建模,LINE 算法用观察到的节点间连接刻画了第一级相似度关系,用不直接相连的两个节点的共同邻居刻画了这两个点之间的第二级相似度关系。具体来说,LINE 算法对所有的第一级相似度和第二级相似度节点对进行了概率建模,并最小化该概率分布和经验分布之间的 KL 距离。参数学习由随机梯度下降算法决定。

2.1.1.3 基于矩阵分解的方法

矩阵分解算法是学习网络表示的一种重要手段。基于矩阵分解或者可以转化为矩阵分解的算法框架^[52]是首先构建节点间的关系矩阵，然后对该矩阵进行矩阵分解操作得到网络表示。

GraRep 算法^[53]通过 SVD 分解对某一关系矩阵进行降维从而得到 k 步网络表示。假设首先对邻接矩阵 A 进行归一化处理，使得矩阵 A 中每行的加和等于 1，GraRep 算法在计算 k 步网络表示时分解了矩阵 A_k ，该关系矩阵中的每个单元对应着两个节点间通过 k 步的随机游走抵达的概率。并且 GraRep 尝试将不同 k 值对应的 k 步网络表示拼接起来，组成维度更高、表达能力也更强的节点表示。虽然更高阶的关系矩阵 A_k 的构建可以提升网络表示的效果，GraRep 算法的主要缺点在于其在计算关系矩阵 A_k 的时候计算效率很低^[3]。

2.1.1.4 基于深层神经网络的方法

基于深层神经网络的代表性表示学习方法是 SDNE (Structural Deep Network Embedding)。SDNE^[54]使用深层神经网络对节点表示间的非线性进行建模。整个模型可以被分为两个部分：一个是由 Laplace 矩阵监督的建模第一级相似度的模块，另一个是由无监督的深层自编码器对第二级相似度关系进行建模。最终 SDNE 算法将深层自编码器的中间层作为节点的网络表示^[3]。

SDNE 的主要目标就是保持网络结构的一阶相似性和二阶相似性。一阶相似性是指网络中边相连的节点对之间具有的相似性。二阶相似性是指在一个网络中拥有共同邻居但是不直接向相连的两个节点具有的相似性。

2.1.1.5 基于社区发现的算法

从社区发现角度学习网络表示，就是让节点表示的每一维对应该节点从属于一个社区的强度，然后设计最优化目标进行求解。这类算法会学习得到上述的社区强度关系表示，然后转化为社区发现的结果。而学习社区强度关系表示的过程可以看作是无监督的非负节点表示学习的过程^[3]。

BIGCLAM^[55]作为一个可覆盖社区发现算法，为每个网络中的节点学习了一个 k 维非负向量表示。BIGCLAM 算法对网络中每条边的生成概率进行建模：两个点的向量表示内积越大，那么这两个点之间形成边的概率也就越高。该算法的

最大化目标是整个网络结构的最大似然概率。最优化求解参数的过程由随机梯度下降算法实现^[3]。

2.1.1.6 保存特殊性质的网络表示

多数网络表示学习方法使用向量表示间的内积或者余弦距离刻画节点相似度。但内积或者余弦距离都是无向的，会丢失网络中的非对称性。另一方面，一些依赖于网络结构定义的性质，如社区（Community）等信息也会在网络表示学习的过程中丢失。

基于此，出现了一些保存特殊性质的网络表示算法，如 HOPE 算法、CNRL 算法等。HOPE 算法^[56]为每个节点刻画了两种不同的表示，并着眼于保存原始网络中的非对称性信息。HOPE 构建了不同的非对称的关系矩阵，然后使用 JDGSVD 算法进行矩阵降维得到节点的网络表示。

CNRL 算法^[57]考虑了在节点表示中嵌入网络隐藏的社区信息，假设每个节点属于多个社区，也就是每个节点在所有的社区上有一个概率分布。CNRL 将网络中的社区看作文本中的主题，也就是说，网络中相关的节点倾向于形成社区，而文本中相关的词则会构成主题。因此，CNRL 算法在生成的随机游走序列上，将每个节点序列看成一篇文档，通过基于 Gibbs 采样的 LDA^[58]来学习每个节点的社区分布，并通过随机采样的方式，来给序列中的节点分配其对应的社区标签。随后，在 Skip-Gram 模型的基础上，用中心节点的节点表示和对应的社区表示同时去预测随机游走序列中的邻近节点，从而将社区结构信息保存在节点表示中。

2.2.2 结合外部信息的网络表示学习

真实世界中的网络节点往往会伴随着丰富的外部信息，例如文本信息、标签类别信息等。传统网络表示学习主要依赖于网络拓扑结构信息，而忽略了这些异质的外部信息。因此，考虑这些外部信息，可以提高网络表示的质量和增强表示向量在网络分析任务上的效果^[3]。

2.2.1 结合文本信息的方法

这种方法利用网络用户状态或者博客内容等文本信息作为网络结构信息的补充，来增强网络节点表示的强度和效果。

例如，TADW 算法^[59]在矩阵分解框架下，将节点的文本特征引入网络表示学习。CANE 算法^[60]利用网络节点的文本信息来对节点之间的关系进行解释，来为网络节点根据不同的邻居学习上下文相关的网络表示。CANE 假设每个节点的表示向量由文本表示向量及结构表示向量构成，其中，文本表示向量的生成过程与边上的邻居相关，所以生成的节点表示也是上下文相关的。CANE 利用卷积神经网络对一条边上两个节点的文本信息进行编码，在文本表示生成的过程中，利用相互注意力机制，选取两个节点彼此最相关的卷积结果构成最后的文本表示向量^[3]。

2.2.2 半监督的网络表示学习

无监督的网络表示学习中，其后续任务很多是以节点表示作为特征的节点分类任务。之前的工作主要基于无监督的网络表示学习，在针对节点分类等机器学习任务时，缺少区分性。半监督的网络表示学习则是把已标注节点的节点类别或者标签加入到网络表示学习的过程中，从而可以有针对性地提升节点网络表示在后续分类任务中的效果。

MMDW^[61]是一种半监督的网络表示学习方法。它同时学习矩阵分解形式的网络表示模型和最大间隔分类器。为了增大网络表示的区分性，MMDW 会针对分类边界上的支持向量计算其偏置向量，使其在学习过程中向正确的类别方向进行偏置，从而增大表示向量的区分能力。DDRW 算法^[62]也采用了类似的方式，同时训练 DeepWalk 模型和最大间隔分类器，来提高网络节点分类的效果。

Node2vec 算法^[63]通过改变随机游走序列生成的方式对 DeepWalk 算法进行扩展。该算法通过引入两个参数 p 和 q 将宽度优先搜索和深度优先搜索引入到随机游走序列的生成过程。其中，宽度优先搜索注重邻近的节点并刻画了相对局部的一种网络表示，宽度优先中的节点一般会出现很多次以降低刻画中心节点的邻居节点的方差；深度优先搜索则反映了更高层面上的节点间的同质性。

其他的半监督网络表示学习方法还包括：GCN 算法^[64]设计了一种作用于网络结构上的卷积神经网络，并使用一种基于边的特征传播规则；Planetoid 算法^[65]联合地预测一个节点的邻居节点和类别标签，类别标签同时取决于节点表示和已知节点标签^[3]。

2.2.3 结合边上标签信息的网络表示学习

除了节点本身附加的文本、标签等信息外，节点与节点之间也存在着丰富的交互信息，即社会关系信息。为了解决社会关系抽取问题，TransNet 模型^[66]利用平移机制，假设头结点表示向量加上关系表示向量等于尾节点表示向量。其中，通过关键词抽取、命名实体识别等方式，对交互文本抽取出标签集合来表示关系。随后，通过深层自动编码器对标签集合进行压缩，来得到关系的表示向量。TransNet 模型能够有效地预测未标注的边上的标签集合，在社会关系抽取任务上效果提升显著^[3]。

2.3 知识表示学习的主要方法模型

知识表示学习领域存在多种模型用于学习知识库中的实体和关系的表示。本部分主要介绍其中几种代表方法，包括：距离模型、单层神经网络模型、能量模型、双线性模型、张量神经网络模型、矩阵分解模型和翻译模型等。

2.3.1 距离模型/结构表示

距离模型/结构表示（Structured Embedding, SE）是将头实体向量和尾实体向量通过关系 r 的两个矩阵投影到 r 的对应空间中，在此空间中计算两投影向量的距离，该距离反映了两个实体在关系 r 下的语义相关度，距离越小，说明两个实体存在这种关系^[2]。

实体向量和关系矩阵是 SE 模型的参数。SE 将知识库三元组作为学习样例，优化模型参数使知识库三元组的损失函数值不断降低，从而使实体向量和关系矩阵能够较好地反映实体和关系的语义信息^[2]。

SE 模型的缺陷是它对头、尾实体使用 2 个不同矩阵进行投影，协同性较差，无法精确刻画两实体与关系之间的语义联系^[2]。

2.3.2 单层神经网络模型

单层神经网络模型（Single Layer Model, SLM）是采用单层神经网络的非线性操作，减轻 SE 无法协同精确刻画实体与关系的语义联系的问题^[2]。

人工神经网络是人工智能的一个研究分支。它是基于生物学中神经网络的基本原理而建立的，构造解决实际问题的有效算法。**人工神经网络主要有两类模型：前向（feed-forward）神经网络和反馈（feed-back）神经网络。**前向型人工神经网络的特点是将神经元分为层，神经元只在层内进行信息交流，各层之间同步地参加计算。反馈型神经网络则将整个网络看成一个整体，各神经元间具有相互作用。

根据前向型人工神经网络的层数，可分为：**单层前向神经网络和多层前向神经网络。**在单层前向神经网络中，只有输入层和输出层。输入层中的元素表示轴突，输出层中的元素代表神经元的内核。单层神经网络只有一个输入层和一个输出层，各层间的元素无信息交流。单层神经网络模型主要用于模式识别^[67]。

在表示学习中，单层神经网络模型的缺陷在于它的非线性操作只提供了比较微弱的联系，却引入了更高的计算复杂度^[2]。

2.3.3 能量模型

语义匹配能量模型（Semantic Matching Energy, SME）是通过更复杂的操作，寻找实体和关系之间的语义联系。在 SME 中，每个实体和关系都用低维向量表示。在此基础上，SME 定义若干投影矩阵，刻画实体与关系的内在联系。具体而言，SME 为每个三元组（h, r, t）主要定义了线性形式和双线性形式两种评分函数^[2]。

2.3.4 双线性模型

隐变量模型（Latent Factor Model, LFM）提出利用基于关系的双线性变换，刻画实体和关系之间的二阶联系。LFM 为每个三元组（h, r, t）定义了双线性评分函数。与以往模型相比，LFM 通过简单有效的方法刻画了实体和关系的语义联系，协同性较好，计算复杂度低^[2]。

后来的 DISTMULT 模型还探索了 LFM 的简化形式：将关系矩阵设置为对角阵，这种简化不仅极大降低了模型复杂度，而且模型效果得到显著提升^[2]。

2.3.5 张量神经网络模型

张量神经网络模型 (Neural Tensor Network, NTN) 的基本思想是, 用双线性张量取代传统神经网络中的线性变换层, 在不同的维度下将头、尾实体向量联系起来。可以看出, 前述 SLM 是 NTN 的简化版本, 是 NTN 将其中张量的层数设置为 0 时的特殊情况^[2]。

与以往模型不同, NTN 中的实体向量是该实体中所有单词向量的平均值。这样做的好处是, 实体中的单词数量远小于实体数量, 可以充分重复利用单词向量构建实体表示, 降低实体表示学习的稀疏性问题, 增强不同实体的语义联系。缺点在于, 由于 NTN 引入了张量操作, 虽然能够更精确地刻画实体和关系的复杂语义联系, 但是计算复杂度非常高, 需要大量三元组样例才能得到充分学习, 在大规模稀疏知识图谱上的效果较差^[2]。

2.3.6 矩阵分解模型

矩阵分解是得到低维向量表示的重要途径。因此, 也有研究者提出采用矩阵分解进行知识表示学习。这方面的代表方法是 RESACL 模型。在该模型中, 知识库三元组构成一个大的张量 X 。张量分解旨在将每个三元组对应的张量值分解为实体和关系表示。RESACL 的基本思想与前述 LFM 类似。不同之处在于, RESACL 会优化张量中的所有位置, 包括值为 0 的位置; 而 LFM 只会优化知识库中存在的三元组^[2]。

2.3.7 平移模型

表示学习在自然语言处理领域受到广泛关注起源于 Mikolov 等人^[73]^[68]于 2013 年提出的 Word2vec 词表示学习模型和工具包。利用该模型, Mikolov 等人发现词向量空间存在有趣的平移不变现象。例如, $C(\text{king}) - C(\text{queen}) \approx C(\text{man}) - C(\text{woman})$, 也就是说, 词向量能够捕捉到单词 king 和 queen 之间、man 和 woman 之间的某种相同的隐含语义关系。受到该现象的启发, Bordes 等人^[74]提出了**平移模型 (TransE 模型)**, 将知识库中的关系看作实体间的某种平移向量。对于每个三元组 (h, r, t) , TransE 用关系 r 的向量 $\mathbf{l}_r$ 作为头实体向量 $\mathbf{l}_h$ 和尾实体向量 $\mathbf{l}_t$ 之间的平移, 也可以将 $\mathbf{l}_r$ 看作从 $\mathbf{l}_h$ 到 $\mathbf{l}_t$ 的翻译, 因此 TransE 也被称为翻译模型。

与以往模型相比，TransE 模型参数较少，计算复杂度低，能直接建立实体和关系之间的复杂语义联系，性能较以往模型有显著提升。因此，TransE 已经成为知识表示学习的代表模型^[2]。

2.3.8 其他模型

TransE 模型虽然在大规模知识图谱上效果明显，但是在处理知识库的复杂关系时受到局限。由此，相继出现了 TransH, TransR, TransD, TranSparse, TransA, TransG 和 KG2E 等多种模型，从不同角度尝试解决复杂关系建模问题。在相关数据集上的实验表明，这些方法均较 TransE 有显著的性能提升^[2]。

TransH 模型提出让一个实体在不同的关系下拥有不同的表示。TransR 模型则认为，一个实体是多种属性的综合体，不同关系关注实体的不同属性，对每个三元组，首先应将实体投影到对应的关系空间中，然后再建立从头实体到尾实体的翻译关系。TransD 模型设置了两个分别将头实体和尾实体投影到关系空间的投影矩阵 M_{rh} 和 M_{rt} ，解决了原来 TransR 模型参数过多的问题。为了解决实体和关系的异质性，TranSparse 提出使用稀疏矩阵代替 TransR 模型中的稠密矩阵，其中，投影矩阵 M_r 的稀疏度由关系 r 连接的实体对数量决定，由头、尾实体共享。

TransA 模型则将损失函数中的距离度量改用马氏距离，并为每一维学习不同的权重。TransG 模型提出使用高斯混合模型描述头、尾实体之间的关系，认为一个关系会对应多种语义，每种语义用一个高斯分布来刻画。KG2E 模型使用高斯分布来表示实体和关系，其中，高斯分布的均值表示的是实体或关系在语义空间中的中心位置，而高斯分布的协方差则表示该实体或关系的不确定度^[2]。

在 TransE 的多种扩展模型以外，还有一个近年来提出的全息表示模型（Holographic Embeddings, Hole）^[69]。Hole 模型提出使用头、尾实体向量的“循环相关”操作来表示实体对。循环相关操作具有较强的表达能力，也具有不可交换性、相关性和计算效率高 3 个优点。但是该模型的效果尚未得到验证^[2]。

2.4 表示学习领域必读论文解读

基于 AMiner 系统的“Topic 必读论文”功能，通过本领域专家以及热心专业读者推荐，本部分选取其中代表性的十篇论文进行解读。如欲查看表示学习

领域更多的必读论文，请查看网站：

<https://www.aminer.cn/topic/5e7ef61ac1b7e55a5aea64d2>。

1. *Distributed Representations* ^[70]

论文链接	https://www.aminer.cn/pub/53e9979bb7602d9701f682af/
发表年份	1984
作者	Hinton, Geoffrey E
作者单位	加拿大多伦多大学

本文描述了一种表示类型，即每个实体由分布在多个计算元素上的活动模式表示，而每个计算元素则表示许多不同实体。这种复杂表示法的优点在于它具有利用简单的、类似神经元的计算元素进行网络处理的效率。

本文认为，分布表示提供了一种使用并行硬件实现最佳匹配搜索的有效方法，其基本思想相当简单。并且指出了分布式表示的三大优势，即具备建设性特征、能够自动泛化至新的情景、在变化环境中可调节性。相对于本地化表示，分布式表示仅需与更少的单元建立任意关联，可以在不分配新硬件的情况下创建新概念，并且可以更有效地保存信息。

分布式表示似乎不适合实现纯粹的任意映射，因为没有底层结构，所以泛化只会导致不必要的干扰。在有效地使用分布式表示之前，必须解决几个难题：一是决定用于表示项目的活动模式。所选模式与其他现有模式之间的相似性将决定所发生的泛化和干扰的类型。搜索要使用的合适模式等同于搜索域的底层正则值。二是澄清分布式表示和人工智能中使用的技术（如模式或层次结构描述）之间的关系。现有的人工智能程序很难快速找到最适合当前情况的模式。并行网络提供了将大量知识快速应用于这种最佳搜索的潜力，但是实现这种潜力却需要在并行网络中有一种很好的实现模式的方法限制。

2. *Learning representations by back-propagating errors* ^[71]

论文链接	https://www.aminer.cn/pub/5b076eb4da5629516ce741de/
发表年份	1986
作者	David E. Rumelhart, Geoffrey E. Hinton, Ronald J. Williams
作者单位	美国斯坦福大学、加拿大多伦多大学、美国东北大学

本文描述了一种用于类神经元单位的网络的学习过程，即反向传播。该过程反复调整网络中连接的权重，以尽量减小实际输出向量与期望输出向量之间的差值。由于权重调整，不属于输入输出部分的内部隐藏单元代表了任务域的重要特征，而任务中的常规单元则被这些单元的相互作用而所捕捉到。反向传播具有产生有用的新特征的能力，使其明显区别于早期的简单方法（如感知器收敛过程）。

本文指出，学习过程最明显的缺点是错误曲面可能包含局部极小值，因此梯度下降并不能保证找到全局极小值。然而，许多任务的经验表明，网络很少会陷入比全局最小值差得多的局部极小值。只有在有足够的连接来执行任务的网络中遇到这种不受欢迎的行为，再加上几个连接，就会在权重空间中产生额外的维度。这些维度提供了绕过障碍物的路径，从而在低维子空间中产生了局部极小值。将该过程应用于各种任务，可以通过权重空间中的梯度下降来构造有趣的内部表示。

3. *Representation Learning: A Review and New Perspectives* ^[72]

论文链接 <https://www.aminer.cn/pub/53e9986eb7602d97020a7ef9/>
 发表年份 2013
 作者 Yoshua Bengio, Aaron Courville, Pascal Vincent
 作者单位 加拿大蒙特利尔大学

这是一篇综述论文。本文回顾了在无监督特征学习和深度学习领域的近期研究，包括概率模型、自动编码器、流形学习和深度网络的研究进展。在学习表示的各种方法中，本文主要关注于深度学习方法：那些由多个非线性变换组合而成的方法，其目标是产生更抽象的表示，并最终产生更有用的表示。

本文分析了表示学习和深度学习的三种方法：概率模型（包括定向和无向模型，例如稀疏编码、玻耳兹曼机等），有关自动编码的基于重建的算法和几何动机多样学习方法。在这些方法之间建立联系是当前一个非常活跃的研究领域，并且很可能继续产生利用每种范例的相对优势的模型和方法。

4. *Distributed Representations of Words and Phrases and their Compositionality* ^[73]

论文链接 <https://www.aminer.cn/pub/53e9b108b7602d9703b85b88/>
 发表年份 2013
 作者 Tomas Mikolov, Ilya Sutskever, Kai Chen, Greg Corrado, Jeffrey Dean
 作者单位 谷歌

本文在 Skip-gram 模型上提出了可以提高向量质量和训练速度的几个扩展。首先，通过对常用词进行子抽样，实现了 2~10 倍的加速效果，提高了表示低频词的准确性，并学习了更多的常用词表示形式。其二，本文描述了一种简单的替代分层 softmax 方法，称为负抽样。负抽样是一个简化的噪声对比估计（Noise Contrastive Estimation），可以从负面例子中用逻辑回归分辨出正面例子，而不是从整个词汇中选出正确的分类。通过类比推理任务，本文证明了负样本比先前的分层 softmax 表现好很多。其三，单词表示的固有限制在于无视词序和无法表示惯用短语。例如，“Canada”和“Air”的意思很难结合在一起而得到“加拿大航空”。受此示例的启发，作者提出了一种用于在文本中查找短语的简单方法，并表明学习数百万个短语的良好矢量表示形式是可行的。

5. *Translating Embeddings for Modeling Multi-relational Data* ^[74]

论文链接	https://www.aminer.cn/pub/53e9a7ddb7602d970311b83d/
发表年份	2013
作者	Antoine Bordes, Nicolas Usunier, Alberto Garcia-Duran, Jason Weston, Oksana Yakhnenko
作者单位	康比涅科技大学、谷歌

本文提出了 TransE，即一种通过将关系解释为在实体的低维嵌入上操作的转换来建模关系的方法。该方法简单有效，即对于（头实体、关系、尾实体）这种数据，通过把关系（relationship）转化为头实体（head）和尾实体（tail）之间的 translation embedding 的思想，来学习三种数据的嵌入。通过这种合理的假设，整个模型需要优化的参数很少、效果很好。本文用 Wordnet 和 Freebase 两个数据库进行实验后，在链接预测上取得了当年最高水平的效果。而这种把关系建立成 translating embedding 的建模假设，在后续的其他应用（例如推荐系统）文章上也取得了良好的效果。它解决了多关系数据在低维向量空间中的嵌入问题，且该模型易于训练、包含参数较少，可以扩展到非常大的数据库。

6. *Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation* ^[75]

论文链接	https://www.aminer.cn/pub/5550411645ce0a409eb38730/
发表年份	2014

作者	Kyunghyun Cho, Bart van Merriënboer, Caglar Gulcehre, Dzmitry Bahdanau, Fethi Bougares, Holger Schwenk, Yoshua Bengio
作者单位	蒙特利尔大学、德国不来梅雅各布大学、法国缅因大学

Seq2Seq 是机器翻译、对话聊天、文本摘要等工作的重要模型，而本文提出的神经网络模型 RNN Encoder-Decoder 是 Seq2Seq 模型的前身。RNN 编码器-解码器模型是由两个循环神经网络（RNN）组成。一个 RNN 将一个符号序列编码成一个定长向量表示，而另一个则将该表示解码成另一个符号序列。这个模型的编码器和解码器被联合训练以最大化给定源序列的目标序列的条件概率。通过英法短语翻译测试发现，在已有的对数线性模型中添加 RNN Encoder-Decoder，并利用该模型计算出的短语组的条件概率，使得统计机器翻译系统的性能得到了改善。该模型可以学习到一个效果比较好的 Word Embedding 结果。不仅如此，本文还提出了 GRU 的门结构，它相比 LSTM 更加简洁，而且效果不输 LSTM。

7. *DeepWalk: Online Learning of Social Representations*^[76]

论文链接	https://www.aminer.cn/pub/53e9b253b7602d9703cf4028/
发表年份	2014
作者	Bryan Perozzi, Rami Al-Rfou, Steven Skiena
作者单位	美国石溪大学

网络表示的稀疏性使得设计有效的离散算法成为可能，但也使它在统计学习中更难推广。网络中的机器学习应用程序（如网络分类、内容建议、异常检测和丢失链接预测）必须能够处理这种稀疏性才能生存。本文在网络分析中引入了在自然语言处理中的深度学习（无监督特征学习）技术，提出了一种新的 DeepWalk 方法来学习网络中顶点的潜在表示。这些潜在的表征将社会关系编码在一个连续的向量空间中，易被统计模型利用。DeepWalk 涵盖了语言建模和深度学习从单词序列到图表的最新进展。DeepWalk 使用从截短的随机游走中获得的局部信息，通过把游走当作句子的等分来学习潜在的表示。研究表明，DeepWalk 比基线表现更好，而这些基线可以对网络进行全局观察，尤其是在存在缺失信息的情况下。当标记数据稀疏时，DeepWalk 的表示在 F1 分数上可以比其他方法高 10%。在一些实验中，DeepWalk 的表现能够超越所有的基线方法，并同时减少 60% 的训练数据。另外，DeepWalk 是一种可扩展的在线学习算法，可生成有用的增量

结果，并且可并行化。这些特性使其广泛适合于现实世界应用，如网络分类和异常检测。

8. *Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks* ^[77]

论文链接 <https://www.aminer.cn/pub/573696006e3b12023e514358/>

发表年份 2016

作者 Alec Radford, Luke Metz, Soumith Chintala

作者单位 Indico, Facebook

本文介绍了可以在大多数场景中稳定训练的深度卷积生成对抗网络（DCGAN）。该模型的建立方法如下：首先将均匀的噪声分布 z 送入生成器的第一层，该第一层可以是一个全连通层。这一层用于矩阵乘法，其结果被重新构造成一个四维向量。对于鉴别器，最后一层被压平，然后输入单个 sigmoid 输出。而池化层则在鉴别器中被步幅卷积替代，在生成器中被部分步幅卷积替代。为了防止模式崩溃，该模型使用了批处理规范化。由于可能会导致样本振荡和模型不稳定，所以批处理归一化未应用于生成器的输出层和鉴别器的输入层。最后，生成器使用 ReLU 激活所有层，但对输出使用 Tanh。而鉴别器则对所有层使用 LeakyReLU 激活。通过实验发现，即使是在没有训练过的 CIFAR-10 数据集上，DCGAN 得出的结果也很高，表明了它学习特征的鲁棒性。这项技术可以用来生成更高分辨率的图像，也可以通过使用矢量算法来减少复杂图形分布建模所需的数据量。

9. *Attention Is All You Need* ^[78]

论文链接 <https://www.aminer.cn/pub/5c8b4d794895d9cbc67f0e33/>

发表年份 2017

作者 Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N. Gomez, Lukasz Kaiser, Illia Polosukhin

作者单位 谷歌大脑、谷歌研究、加拿大多伦多大学

本文提出了一种称为 Transformer 的简单网络结构。这个结构完全基于注意力机制、省去了递归和卷积。Transformer 由三部分组成：编码器、解码器以及它们之间的连接。编码器和解码器都是由 6 个相同的层组成以提高性能。

在本文中，注意力机制成为从编码器到解码器获取信息的唯一来源，允许解码器关注它们所关注的编码器的权重。经过在 2014 年 WMT 英法和英德翻译的两个机器翻译任务上的实验表明，这些模型在质量上具有更高的可并行性、更少训练时间的优势。该模型在 2014 年 WMT 英德翻译任务中达到 28.4 BLEU，比现有的最佳结果（包括集成部分）提高了 2 个 BLEU 以上。在 2014 年的 WMT 英法翻译任务中，该模型在 8 个 GPU 上进行了 3.5 天的培训后，创造了新的目前最高水平的单模型 BLEU 评分 41.8。结论表明，Transformer 可以很好地推广到其他任务，应用到具有大量和有限训练数据的英语集合解析中。




图 2 Transformer 模型架构图^[78]

10. BERT: *Pre-training of Deep Bidirectional Transformers for Language Understanding*^[79]

论文链接 <https://www.aminer.cn/pub/5bdc31b417c44a1f58a0b8c2/>

发表年份 2018

作者 Jacob Devlin, Ming-Wei Chang, Kenton Lee, Kristina Toutanova

作者单位 谷歌

该文介绍了一种称为 BERT（Bidirectional Encoder Representations from Transformers）的新语言表示模型。BERT 是基于 Transformer 的 encoder 来做的。

与其他近期的语言表示模型不同，BERT 通过在所有层中对左、右上下文进行联合条件作用，来预先训练未标记文本的深层双向表示。因此，只需一个额外的输出层，就可以对预先训练的 BERT 模型进行优化，从而为各种任务（如回答问题和语言推断）创建最先进的模型，而无需对特定任务的体系结构进行大量修改。BERT 概念简单，且实验证明非常强大。它在 11 个自然语言处理任务上获得了最佳结果，包括将 GLUE 基准分数提至 80.5%，MultiNLI 精度提至 86.7%，SQuAD v1.1 问答测试 F1 分数提至 93.2，以及 SQuAD v2.0 测试 F1 提至 83.1。




图 3 BERT 的整体预训练和微调程序^[79]

2.5 表示学习话题模型

本节针对 AMiner 平台上收录的 100 篇必读论文（<https://www.aminer.cn/topic/5e7ef61ac1b7e55a5aea64d2>），采用经典的隐含狄利克雷分配（Latent Dirichlet Allocation, LDA）模型来分析这些相关论文的研究话题模型（Topic Model）。

LDA 模型假定文本中的每个词由一些混合的话题产生的，每个话题都有一定的权重，即 $p(w) = \sum_z p(w|z)p(z)$ ，其中 $p(z)$ 又是由一个 Dirichlet 分布产生。LDA 的贝叶斯网络结构如图 4 所示，图中 K 为话题个数， M 论文总数， N 是某个论文中单词总数， α 和 β 分别是每个话题下词的多项式分布和每个论文下话题的多项分布的 Dirichlet 先验参数。LDA 模型中有一组隐含变量 z ，参数求解采用吉布斯采样，构建 Markov 链，逼近目标概率分布。获取参数后可以计算论文的主题关键词， $p(w|d) = \sum_z p(w|z)p(z|d)$ 。




图 4 LDA 结构图^[1]

利用 LDA 模型算法，本报告设置话题数 $K=5$ ，通过对论文的标题和摘要进行分析，获取了这些表示学习领域研究论文的话题模型，结果如表 4 所示。

表 4 表示学习话题模型

话题模型	相关论文	作者
sparse	<i>Close the Loop: Joint Blind Image Restoration and Recognition with Sparse Representation Prior</i> (2011)	Haichao Zhang; Jianchao Yang; Yanning Zhang; Nasser M. Nasrabadi; Thomas S. Huang
	<i>Robust Sparse Coding for Face Recognition</i> (2011)	Meng Yang; Lei Zhang; Jian Yang; D. Zhang
	<i>On A Nonlinear Generalization of Sparse Coding and Dictionary Learning</i> (2013)	Jeffrey Ho; Yuchen Xie; Baba C. Vemuri
feature	<i>Efficient Learning of Sparse, Distributed, Convolutional Feature Representations for Object Recognition</i> (2011)	Kihyuk Sohn; Dae Yon Jung; Honglak Lee; Alfred O. Hero
	<i>Learning Human Pose Estimation Features with Convolutional Networks</i> (2014)	Arjun Jain; Jonathan Tompson; Mykhaylo Andriluka; Graham W. Taylor; Christoph Bregler
	<i>Learning with Augmented Features for Heterogeneous Domain Adaptation</i> (2012)	Lixin Duan; Dong Xu; Ivor W. Tsang
unsupervised	<i>Robust Unsupervised Feature Selection</i> (2013)	Mingjie Qian; Chengxiang Zhai
	<i>Convolutional Deep Belief Networks for Scalable Unsupervised Learning of Hierarchical Representations</i> (2009)	Honglak Lee; Roger Grosse; Rajesh Ranganath; Andrew Y. Ng
	<i>Fixed-rank Representation for Unsupervised Visual Learning</i> (2012)	Risheng Liu; Zhouchen Lin; Fernando De La Torre; Zhixun Su


¹ Wikipedia, https://en.wikipedia.org/wiki/Latent_Dirichlet_allocation

话题模型	相关论文	作者
semi supervised	<i>Semi-supervised Learning of Compact Document Representations with Deep Networks</i> (2008)	Marc' Aurelio Ranzato; Martin Szummer
	<i>Co-Tracking Using Semi-Supervised Support Vector Machines</i> (2007)	Feng Tang; Shane Brennan; Qi Zhao; Hai Tao
	<i>Semi-Supervised Adapted HMMs for Unusual Event Detection</i> (2005)	Dong Zhang; Daniel Gatica-Perez; Samy Bengio; Iain McCowan
reinforcement	<i>Relational Reinforcement Learning</i> (2001)	Sošo Džeroski; Luc De Raedt; Kurt Driessens
	<i>Reinforcement Learning of Local Shape in the Game of Go</i> (2007)	David Silver; Richard S Sutton; Matthias S Muller
	<i>The Adaptive K-Meteorologists Problem and Its Application to Structure Learning and Feature Selection in Reinforcement Learning</i> (2009)	Carlos Diuk; Lihong Li; Bethany R. Leffler

2.6 领域专利申请情况

根据“表示学习”领域关键词，从专利数据库中查找出 2010 至 2020 年期间“标题和摘要”中包含领域关键词的全球相关专利申请情况。领域关键词包括：表示学习（Representation Learning）、分布式表示（Distributed Representation）、符号表示（Symbol Representation）、知识表示（Knowledge Representation）、稀疏表示（Sparse Representation）、特征表示（Feature Representation）。


过去十年期间，表示学习领域全球专利申请量共计 7670 条，整体来看，相关专利申请量少。从申请趋势上看，专利申请量呈现稳步上升态势，2018 年相关专利申请量达到峰值 1008 条，如图 5 所示，2020 年相关专利申请量预计将达到 1200 条。



数据来源：智慧芽

图 5 2010 至 2020 年期间表示学习相关专利全球申请量

从专利受理量排名前十的受理局来看，如图 6 所示，表示学习相关专利在中国地区申请受理量最多，达 3822 件，这反映出中国对该技术创新发展的高度关注，高于美国、日本、世界知识产权组织等其他受理局的相关专利受理量。




数据来源：智慧芽

图 6 2010 至 2020 年期间表示学习专利受理量排名前十的受理局

从专利申请人排名看，表示学习相关专利申请量前十的机构来自中国、美国、加拿大和日本几个国家。中国相关专利申请量居前的机构都是国内大学或科研机

构，其中，西安电子科技大学申请量最多，为 264 件；其他大学的相关专利申请量如图 7 所示。



数据来源：智慧芽

图 7 2010 至 2020 年表示学习相关专利申请量排名前十的申请人

2.7 领域相关的国家自然科学基金 NSFC 项目

根据“表示学习”领域关键词（包括：表示学习、分布式表示、符号表示、知识表示、稀疏表示、嵌入、特征表示），借助 AMiner 数据库，查询国家自然科学基金在 2010 至 2020 年支持的计算机科学、人工智能和自动化相关项目。结果显示，过去十年间国家自然科学基金共计支持了 1661 个表示学习相关项目（包含未结题的项目），其中，项目数量前十的类型分布如图 8 所示，包含 740 个面上项目、648 个青年科学基金项目、101 个地区科学基金项目，其余的支持类型的项目数量均不足 100 个。




图 8 表示学习领域 2010-2020 年国家自然科学基金 NSFC 项目数量前十的项目类型

研究期间，在表示学习领域，国家自然科学基金项目数量前十的依托单位如图 9 所示。由图可见，西安电子科技大学是相关项目批准量最多的机构，共计有 50 个，该单位获批支持的面上项目数量 26 个、青年科学基金项目 19 个，是相应项目类型中获得支持的最多依托单位。




图 9 表示学习领域 2010-2020 年国家自然科学基金 NSFC 项目量前十依托单位

2.8 表示学习领域研究前沿动态

AMiner 会议系统 (<https://www.aminer.cn/conf>) 是一个会议智图开放平台，它不仅提供多个顶会会议的召开时间、地点、收录的论文数量，以及会议简介、

官网地址等，而且提供论文、作者（包括华人学者、一作华人学生）、论文 PPT 和视频等多维分析服务。

基于 AMiner 会议系统，本报告整理分析了 2020 年顶级会议上发表的表示学习领域的最新论文，如表 5 所示。

表 5 2020 年表示学习领域研究前沿动态

顶会名称	简称	会议时间	表示学习主题论文量（篇）
International Joint Conference on Artificial Intelligence	IJCAI	1.05-1.10	10
International Conference on Learning Representations	ICLR	4.26-5.02	39
IEEE Conference on Computer Vision and Pattern Recognition	CVPR	6.16-6.18	14
Annual Meeting of the Association for Computational Linguistics	ACL	7.05-7.10	14
International Conference on Machine Learning	ICML	7.12-7.18	10

2020 年 IJCAI、ICLR、CVPR、ACL 和 ICML 顶级会议上发表的表示学习领域论文详细信息如下。

IJCAI2020 会议的表示学习相关论文

1. 题目：*On the Importance of Word and Sentence Representation Learning in Implicit Discourse Relation Classification*（词语和句子表征学习在隐式话语关系分类中的重要性）

作者：Liu Xin（刘昕）、Ou Jiefu、Song Yangqiu（宋阳秋）、Jiang Xin

论文 URL：<https://www.aminer.cn/pub/5ea8009091e0111d387ee83a/>

2. 题目：*Exploiting Mutual Information for Substructure-aware Graph Representation Learning*（利用互信息进行子结构感知图表示学习）

作者：Pengyang Wang、Yanjie Fu、Yuanchun Zhou、Kunpeng Liu、Xiaolin Li、Kien Hua

论文 URL：<https://www.aminer.cn/pub/5ef96b048806af6ef27721ae/>

3. 题目：*Multi-View Joint Graph Representation Learning for Urban Region Embedding*（城市区域嵌入任务中的多视图联合图表示学习）

作者: Mingyang Zhang、Tong Li、Yong Li (李勇)、Pan Hui

论文 URL: <https://www.aminer.cn/pub/5ef96b048806af6ef2772226/>

4. 题目: *Communicative Representation Learning on Attributed Molecular Graphs* (基于属性分子图的交际表征学习)

作者: Ying Song、Shuangjia Zheng、Zhangming Niu、Zhang-hua Fu、Yutong Lu (卢宇彤)、Yuedong Yang (杨跃东)

论文 URL: <https://www.aminer.cn/pub/5ef96b048806af6ef27720fb/>

6. 题目: *Joint Representation Learning of Legislator and Legislation for Roll Call Prediction* (立法者与立法者之联合表示学习及点名预测之立法)

作者: Yuqiao Yang、Xiaoqiang Lin、Geng Lin、Zengfeng Huang、Changjian Jiang、Zhongyu Wei

论文 URL: <https://www.aminer.cn/pub/5ef96b048806af6ef2772088/>

7. 题目: *G2RL: Geometry-Guided Representation Learning for Facial Action Unit Intensity Estimation* (G2RL: 几何指导下的面部动作单元强度估计表示学习)

作者: Yingruo Fan、Zhaojiang Lin

论文 URL: <https://www.aminer.cn/pub/5ef96b048806af6ef2772031/>

8. 题目: *TransRHS: A Representation Learning Method for Knowledge Graphs with Relation Hierarchical Structure* (TransRHS: 一种关系层次结构知识图的表示学习方法)

作者: Fuxiang Zhang、Xin Wang、Zhao Li、Jianxin Li

论文 URL: <https://www.aminer.cn/pub/5ef96b048806af6ef277218e/>

9. 题目: *Unsupervised Representation Learning by Predicting Random Distances* (通过预测随机距离进行无监督表示学习)

作者: Wang Hu, Pang Guansong, Shen Chunhua, Ma Congbo

论文 URL: <https://www.aminer.cn/pub/5e09caba3a55ac662f721bd7/>

10. *HID: Hierarchical Multiscale Representation Learning for Information Diffusion* (HID: 信息扩散的分层多尺度表示学习)

作者: Honglu Zhou, Shuyuan Xu, Zuohui Fu, Gerard de Melo, Yongfeng Zhang, Mubbasir Kapadia

论文 URL: <https://www.aminer.cn/pub/5ef96b048806af6ef277219e/>

ICLR 2020 会议的表示学习相关论文

1. 题目: *Inductive and Unsupervised Representation Learning on Graph Structured Objects* (图结构对象的归纳和无监督表示学习)

作者: Lichen Wang (王莅尘)、Bo Zong、Qianqian Ma (马倩倩)、Wei Cheng、Jingchao Ni、Wenchao Yu、Yanchi Liu、Dongjin Song、Haifeng Chen、Yun Fu

论文 URL: <https://www.aminer.cn/pub/5e5e18bc93d709897ce2c131/>

2. 题目: *ALBERT: A Lite BERT for Self-supervised Learning of Language Representations* (ALBERT: 用于语言表征自监督学习任务的轻量级 BERT)

作者: Zhenzhong Lan、Mingda Chen (陈明达)、Sebastian Goodman、Kevin Gimpel、Piyush Sharma、Radu Soricut

论文 URL: <https://www.aminer.cn/pub/5e5e18e493d709897ce3a0f2/>

3. 题目: *Multi-Scale Representation Learning for Spatial Feature Distributions using Grid Cells* (基于网格单元的空间特征分布多尺度表示学习)

作者: Gengchen Mai、Krzysztof Janowicz、Bo Yan、Rui Zhu、Ling Cai、Ni Lao (劳逆)

论文 URL: <https://www.aminer.cn/pub/5e5e18bf93d709897ce2d13c/>

4. 题目: *Contrastive Representation Distillation* (对比表征蒸馏)

作者: Yonglong Tian、Dilip Krishnan、Phillip Isola

论文 URL: <https://www.aminer.cn/pub/5e718f5c9e795e1c35c5f807/>

5. 题目: *Mutual Information Gradient Estimation for Representation Learning* (表征学习中的互信息梯度估计)

作者: Wen Liangjian、Zhou Yiji、He Lirong (贺丽荣)、Zhou Mingyuan (周明远)、Xu Zenglin (徐增林)

论文 URL: <https://www.aminer.cn/pub/5e5e18b693d709897ce29abf/>

6. 题目: *InfoGraph: Unsupervised and Semi-supervised Graph-Level Representation Learning via Mutual Information Maximization* (InfoGraph: 基于互信息最大化的无监督和半监督图级表示学习方法)

作者: Fan-Yun Sun、Jordan Hoffman、Vikas Verma、Jian Tang (唐建)

论文 URL: <https://www.aminer.cn/pub/5e5e189a93d709897ce1e760/>

7. 题目: *ELECTRA: Pre-training Text Encoders as Discriminators Rather Than Generators* (ELECRA: 作为鉴别器而不是生成器的预训练文本编码器)

作者: Kevin Clark、Minh-Thang Luong、Quoc V. Le、Christopher D. Manning

论文 URL: <https://www.aminer.cn/pub/5e5e18d593d709897ce33b3c/>

8. 题目: *StructPool: Structured Graph Pooling via Conditional Random Fields* (StructPool: 基于条件随机场的结构化图池算法)

作者: Hao Yuan、Shuiwang Ji

论文 URL: <https://www.aminer.cn/pub/5e5e18d793d709897ce34a43/>

9. 题目: *Phase Transitions for the Information Bottleneck in Representation Learning* (表征学习中信息瓶颈的相变问题)

作者: Tailin Wu、Ian Fischer

论文 URL: <https://www.aminer.cn/pub/5e5e18bb93d709897ce2b712/>

10. 题目: *On Mutual Information Maximization for Representation Learning* (论表征学习中的互信息最大化)

作者: Michael Tschannen、Josip Djolonga、Paul K. Rubenstein、Sylvain Gelly、Mario Lucic

论文 URL: <https://www.aminer.cn/pub/5e5e18b993d709897ce2ad5c/>

11. 题目: *Prediction, Consistency, Curvature: Representation Learning for Locally-Linear Control* (预测、一致性、曲率: 局部线性控制的表示学习)

作者: Nir Levine、Yinlam Chow、Rui Shu、Ang Li、Mohammad Ghavamzadeh、Hung Bui

论文 URL: <https://www.aminer.cn/pub/5e5e18b293d709897ce2852d/>

12. 题目: *Hyper-SAGNN: a self-attention based graph neural network for hypergraphs* (Hyper-SAGNN: 一种基于自注意力机制的超图神经网络)

作者: Ruochi Zhang、Yuesong Zou、Jian Ma (马坚)

论文 URL: <https://www.aminer.cn/pub/5e5e18dc93d709897ce36d0b/>

13. 题目: *Target-Embedding Autoencoders for Supervised Representation Learning*
(用于监督表示学习的目标嵌入自编码器)

作者: Daniel Jarrett、Mihaela van der Schaar

论文 URL: <https://www.aminer.cn/pub/5e5e189d93d709897ce1fe51/>

14. 题目: *Conditional Learning of Fair Representations* (公平表征的条件学习)

作者: Han Zhao (赵晗)、Amanda Coston、Tameem Adel、Geoffrey J. Gordon

论文 URL: <https://www.aminer.cn/pub/5e5e18f493d709897ce3f451/>

15. 题目: *Inductive representation learning on temporal graphs* (时态图的归纳表示学习)

作者: Da Xu、Chuanwei Ruan、Evren Korpeoglu、Sushant Kumar、Kannan Achan

论文 URL: <https://www.aminer.cn/pub/5e5e18bb93d709897ce2bace/>

16. 题目: *Self-labelling via simultaneous clustering and representation learning* (基于同时聚类 and 表征学习的自标记)

作者: Y M Asano、C Rupprecht、A Vedaldi

论文 URL: <https://www.aminer.cn/pub/5e5e18ac93d709897ce260c1/>

17. 题目: *Semantically-Guided Representation Learning for Self-Supervised Monocular Depth* (单目深度问题中的语义指导表示学习)

作者: Vitor Guizilini、Rui Hou、Jie Li、Rares Ambrus、Adrien Gaidon

论文 URL: <https://www.aminer.cn/pub/5e5e18c993d709897ce31464/>

18. 题目: *Gradients as Features for Deep Representation Learning* (梯度作为深度表征学习的特征)

作者: Fangzhou Mu (穆方舟)、Yingyu Liang、Yin Li

论文 URL: <https://www.aminer.cn/pub/5e5e18a893d709897ce24284/>

19. 题目: *Rapid Learning or Feature Reuse? Towards Understanding the Effectiveness of MAML* (快速学习还是特征重用? 理解 MAML 的高效性)

作者: Aniruddh Raghu、Maithra Raghu、Samy Bengio、Oriol Vinyals

论文 URL: <https://www.aminer.cn/pub/5e5e18a793d709897ce23f77/>

20. 题目： *Unsupervised Model Selection for Variational Disentangled Representation Learning* (变分消解表示学习的无监督模型选择)

作者: Sunny Duan、Loic Matthey、Andre Saraiva、Nick Watters、Chris Burgess、Alexander Lerchner、Irina Higgins

论文 URL: <https://www.aminer.cn/pub/5e5e18b993d709897ce2affa/>

21. 题目： *Learning to Plan in High Dimensions via Neural Exploration-Exploitation Trees* (基于神经探索-开发树的高维规划学习)

作者: Binghong Chen、Bo Dai (戴勃)、Qinjie Lin、Guo Ye、Han Liu、Le Song

论文 URL :<https://www.aminer.cn/pub/5e5e18b093d709897ce27b8d/>

22. 题目： *Differentiation of Blackbox Combinatorial Solvers* (黑箱组合求解器的微分)

作者: Marin Vlastelica Pogančić、Anselm Paulus、Vit Musil、Georg Martius、Michal Rolínek

论文 URL: <https://www.aminer.cn/pub/5e5e18ad93d709897ce2642c/>

23. 题目： *A Mutual Information Maximization Perspective of Language Representation Learning* (语言表征学习的一种互信息最大化视角)

作者: Lingpeng Kong (孔令鹏)、Cyprien de Masson d'Autume、Lei Yu、Wang Ling、Zihang Dai、Dani Yogatama

论文 URL: <https://www.aminer.cn/pub/5e5e18a793d709897ce23d3f/>

24. 题目： *Learning Hierarchical Discrete Linguistic Units from Visually-Grounded Speech* (从视觉背景的语音学习分层离散语言单元)

作者: David Harwath、Wei-Ning Hsu、James Glass

论文 URL: <https://www.aminer.cn/pub/5e5e18c193d709897ce2e06e/>

25. 题目： *Dynamics-Aware Embeddings* (动态感知嵌入)

作者: William Whitney、Rajat Agarwal、Kyunghyun Cho、Abhinav Gupta

论文 URL: <https://www.aminer.cn/pub/5e718f639e795e1c35c5f813/>

26. 题目： *Memory-Based Graph Networks* (基于记忆的图网络)

作者: Amir Hosein Khasahmadi、Kaveh Hassani、Parsa Moradi、Leo Lee、Quaid Morris

论文 URL: <https://www.aminer.cn/pub/5e718f639e795e1c35c5f814/>

27. 题目: *V4D: 4D Covolutional Neural Networks for Video-level Representations Learning* (V4D: 4D 卷积神经网络在视频表示学习任务中的应用)

作者: Shiwen Zhang、Sheng Guo、Weilin Huang、Matthew R. Scott、Limin Wang (王利民)

论文 URL: <https://www.aminer.cn/pub/5e5e189793d709897ce1d28f/>

28. 题目: *vq-wav2vec: Self-Supervised Learning of Discrete Speech Representations* (vq-wav2vec: 离散语音表示的自监督学习)

作者: Alexei Baevski、Steffen Schneider、Michael Auli

论文 URL: <https://www.aminer.cn/pub/5e5e18e393d709897ce3952f/>

29. 题目: *Higher-Order Function Networks for Learning Composable 3D Object Representations* (学习可组合三维对象表示的高阶函数网络)

作者: Eric Mitchell、Selim Engin、Volkan Isler、Daniel D Lee

论文 URL: <https://www.aminer.cn/pub/5e5e18ca93d709897ce319cc/>

30. 题目: *Contrastive Learning of Structured World Models* (结构化世界模型的对比学习)

作者: Thomas Kipf、Elise van der Pol、Max Welling

论文 URL: <https://www.aminer.cn/pub/5e5e18bf93d709897ce2d2a0/>

31. 题目: *A Fair Comparison of Graph Neural Networks for Graph Classification* (图神经网络在图分类任务中的公平比较)

作者: Federico Errica、Marco Podda、Davide Bacciu、Alessio Micheli

论文 URL: <https://www.aminer.cn/pub/5e5e18d393d709897ce32e5b/>

32. 题目: *Disentanglement by Nonlinear ICA with General Incompressible-flow Networks (GIN)* (通用不可压缩流网络 (GIN) 中非线性 ICA 的解纠缠)

作者: Peter Sorrenson、Carsten Rother、Ullrich Köthe

论文 URL: <https://www.aminer.cn/pub/5e718f6f9e795e1c35c5f824/>

33. 题目: *A critical analysis of self-supervision, or what we can learn from a single*

image (对自监督的批判性分析, 或者说我们可以从一幅图像中学到什么)

作者: Y M Asano、C Rupprecht、A Vedaldi

论文 URL: <https://www.aminer.cn/pub/5e5e18b993d709897ce2afbe/>

34. 题目: *RGBD-GAN: Unsupervised 3D Representation Learning From Natural Image Datasets via RGBD Image Synthesis* (RGBD-GaN: 基于 RGBD 图像合成的自然图像数据集中无监督三维表示学习)

作者: Atsuhiko Noguchi、Tatsuya Harada

论文 URL: <https://www.aminer.cn/pub/5e5e18ac93d709897ce25d72/>

35. 题目: *Weakly Supervised Disentanglement with Guarantees* (带保证的弱监督解纠缠)

作者: Rui Shu、Yining Chen、Abhishek Kumar、Stefano Ermon、Ben Poole

论文 URL: <https://www.aminer.cn/pub/5e5e18e893d709897ce3bc9d/>

36. 题目: *Identifying through Flows for Recovering Latent Representations* (基于流识别来恢复潜在表示)

作者: Shen Li、Bryan Hooi、Gim Hee Lee

论文 URL: <https://www.aminer.cn/pub/5e5e18a793d709897ce24014/>

37. 题目: *Learning Robust Representations via Multi-View Information Bottleneck* (利用多视图信息瓶颈学习鲁棒表示)

作者: Marco Federici、Anjan Dutta、Patrick Forré、Nate Kushman、Zeynep Akata

论文 URL: <https://www.aminer.cn/pub/5e5e18a393d709897ce2218b/>

38. 题目: *Probability Calibration for Knowledge Graph Embedding Models* (知识图嵌入模型的概率校正)

作者: Pedro Tabacof、Luca Costabello

论文 URL: <https://www.aminer.cn/pub/5e5e189793d709897ce1d3bf/>

39. 题目: *Pre-training Tasks for Embedding-based Large-scale Retrieval* (基于嵌入的大规模检索的预训练任务)

作者: Wei-Cheng Chang、Felix X. Yu、Yin-Wen Chang、Yiming Yang、Sanjiv Kumar

论文 URL: <https://www.aminer.cn/pub/5e718f569e795e1c35c5f7fa/>

CVPR 2020 会议的表示学习相关论文

1. 题目: *Gait Recognition via Semi-supervised Disentangled Representation Learning to Identity and Covariate Features* (基于半监督解纠缠表示学习的步态识别方法用于解开恒等和协变特征问题)

作者: Xiang Li (李贤均)、Yasushi Makihara、Chi Xu、Yasushi Yagi、Mingwu Ren (任明武)

论文 URL: <https://www.aminer.cn/pub/5eccb534e06a4c1b26a839cc/>

2. 题目: *Transformation GAN for Unsupervised Image Synthesis and Representation Learning* (转换 GAN 用于无监督图像合成与表示学习任务)

作者: Jiayu Wang、Wengang Zhou (周文罡)、Guo-Jun Qi、Zhongqian Fu、Qi Tian (田奇)、Houqiang Li (李厚强)

论文 URL: <https://www.aminer.cn/pub/5eccb534e06a4c1b26a834cf/>

3. 题目: *HigherHRNet: Scale-Aware Representation Learning for Bottom-Up Human Pose Estimation* (HigherHRNet: 自底向上人体姿态估计的尺度感知表示学习)

作者: Bowen Cheng (程博文)、Bin Xiao、Jingdong Wang (王井东)、Honghui Shi、Thomas S. Huang (黄煦涛)、Lei Zhang (张磊)

论文 URL: <https://www.aminer.cn/pub/5eccb534e06a4c1b26a836b7/>

4. 题目: *DeFeat-Net: General Monocular Depth via Simultaneous Unsupervised Representation Learning* (DeFeat-Net: 基于同时无监督表示学习的一般单目深度表示学习网络)

作者: Jaime Spencer、Richard Bowden、Simon Hadfield

论文 URL: <https://www.aminer.cn/pub/5eccb534e06a4c1b26a83a3a/>

5. 题目: *Large Scale Video Representation Learning via Relational Graph Clustering* (基于关系图聚类的大规模视频表示学习)

作者: Hyodong Lee、Joonseok Lee、Joe Yue-Hei Ng、Paul Natsev

论文 URL: <https://www.aminer.cn/pub/5eccb534e06a4c1b26a83744/>

6. 题目: *Towards Universal Representation Learning for Deep Face Recognition* (面向深度人脸识别的通用表示学习)

作者: Shi Yichun、Yu Xiang (喻祥)、Sohn Kihyuk、Chandraker Manmohan、Jain Anil K.

论文 URL: <https://www.aminer.cn/pub/5e58e53c91e01189527e2993/>

7. 题目: *Deep Representation Learning on Long-tailed Data: A Learnable Embedding Augmentation Perspective* (长尾数据的深度表示学习: 一种可学习的嵌入增强方法)

作者: Liu Jialun、Sun Yifan (孙奕帆)、Han Chuchu、Dou Zhaopeng、Li Wenhui

论文 URL: <https://www.aminer.cn/pub/5e5644103a55ac122e36c4c8/>

8. 题目: *Online Deep Clustering for Unsupervised Representation Learning* (基于在线深度聚类的无监督表示学习)

作者: Xiaohang Zhan (詹晓航)、Jiahao Xie、Ziwei Liu (刘子纬)、Yew-Soon Ong、Chen Change Loy (吕健勤)

论文 URL: <https://www.aminer.cn/pub/5eccb534e06a4c1b26a83738/>

9. 题目: *Evolving Loss for Unsupervised Video Representation Learning* (无监督视频表示学习的演化损失)

作者: Piergiovanni AJ、Angelova Anelia、Ryoo Michael S.

论文 URL: <https://www.aminer.cn/pub/5e58e54091e01189527e2ae3/>

10. 题目: *Video Playback Rate Perception for Self-Supervised Spatio-Temporal Representation Learning* (基于视频回放速率感知的自监督时空表示学习)

作者: Yuan Yao、Chang Liu、Dezhao Luo、Yu Zhou (周宇)、Qixiang Ye (叶齐祥)

论文 URL: <https://www.aminer.cn/pub/5eccb534e06a4c1b26a8372a/>

11. 题目: *Towards Backward-Compatible Representation Learning* (向后兼容的表示学习)

作者: Shen Yantao (沈岩涛)、Xiong Yuanjun (熊元骏)、Xia Wei (夏威)、Soatto Stefano

论文 URL: <https://www.aminer.cn/pub/5e7dcebb91e0115bf014c468/>

12. 题目: *Global-Local Bidirectional Reasoning for Unsupervised Representation Learning of 3D Point Clouds* (面向三维点云中无监督表示学习的全局-局部双向推理)

作者: Yongming Rao、Jiwen Lu (鲁继文)、Jie Zhou (周杰)

论文 URL: <https://www.aminer.cn/pub/5eccb534e06a4c1b26a836b6/>

13. 题目: *Decoupled Representation Learning for Skeleton-Based Gesture Recognition* (面向基于骨架的手势识别任务的解耦表示学习)

作者: Jianbo Liu、Yongcheng Liu、Ying Wang、Véronique Prinet、Shiming Xiang (向世明)、Chunhong Pan (潘春洪)

论文 URL: <https://www.aminer.cn/pub/5eccb534e06a4c1b26a836db/>

14. 题目: *Cross-domain Face Presentation Attack Detection via Multi-domain Disentangled Representation Learning* (基于多区域解纠缠表示学习的跨区域人脸显示攻击检测)

作者: Wang Guoqing、Han Hu (韩琥)、Shan Shiguang (山世光)、Chen Xilin (陈熙霖)

论文 URL: <https://www.aminer.cn/pub/5e8da0bf91e011f2de5835a6/>

ACL 2020 会议的表示学习相关论文

1. 题目: *Unsupervised Cross-lingual Representation Learning at Scale* (无监督跨语言表征学习的规模)

作者: Conneau Alexis、Khandelwal Kartikay、Goyal Naman、Chaudhary Vishrav、Wenzek Guillaume、Guzmán Francisco、Grave Edouard、Ott Myle、Zettlemoyer Luke、Stoyanov Veselin

论文 URL: <https://www.aminer.cn/pub/5dc3eb4e3a55ac3c4bb657f5/>

2. 题目: *Improving Disentangled Text Representation Learning with Information-Theoretic Guidance* (在信息论指导下改进解纠缠文本表征学习)

作者: Pengyu Cheng、Martin Renqiang Min、Dinghan Shen、Christopher Malon、Yizhe Zhang (张轶哲)、Yitong Li、Lawrence Carin

论文 URL: <https://www.aminer.cn/pub/5ec49a639fcd0a24b4de80e/>

3. 题目: *Representation Learning for Information Extraction from Form-like Documents* (用于表单文档的信息抽取任务的表示学习)

作者: Bodhisattwa Prasad Majumder、Navneet Potti、Sandeep Tata、James Bradley Wendt、Qi Zhao、Marc Najork

论文 URL: <https://www.aminer.cn/pub/5ec49a639fced0a24b4de8c9/>

4. 题目: *A Comprehensive Analysis of Preprocessing for Word Representation Learning in Affective Tasks* (情感任务中词汇表征学习预处理的综合分析)

作者: Nastaran Babanejad、Ameeta Agrawal、Aijun An、Manos Papagelis、

论文 URL: <https://www.aminer.cn/pub/5ec49a639fced0a24b4de70f/>

5. 题目: *SPECTER: Document-level Representation Learning using Citation-informed Transformers* (SPECTER: 使用基于引文的 Transformer 模型处理文档表示学习任务)

作者: Arman Cohan、Sergey Feldman、Iz Beltagy、Doug Downey、Daniel Weld

论文 URL: <https://www.aminer.cn/pub/5ec49a639fced0a24b4de8f7/>

6. 题目: *Bayesian Hierarchical Words Representation Learning* (贝叶斯层次词表示学习)

作者: Barkan Oren、Rejwan Idan、Caciularu Avi、Koenigstein Noam

论文 URL: <https://www.aminer.cn/pub/5e982ccd91e0119e8a9525ca/>

7. 题目: *On the Cross-lingual Transferability of Monolingual Representations* (论单语言表征任务的跨语言迁移性问题)

作者: Artetxe Mikel、Ruder Sebastian、Yogatama Dani

论文 URL: <https://www.aminer.cn/pub/5db6c73a3a55acec0731cee4/>

8. 题目: *HyperCore: Hyperbolic and Co-graph Representation for Automatic ICD Coding* (HyperCore: 用于自动 ICD 编码的双曲线和余图表示框架)

作者: Pengfei Cao、Yubo Chen (陈玉博)、Kang Liu (刘康)、Jun Zhao (赵军)、Shengping Liu (刘升平)、Weifeng Chong

论文 URL: <https://www.aminer.cn/pub/5ec49a639fced0a24b4de808/>

9. 题目: *Towards Debiasing Sentence Representations* (学习无偏句子表示)

作者: Paul Pu Liang、Irene Mengze Li、Emily Zheng、Yao Chong Lim、Ruslan Salakhutdinov、Louis-Philippe Morency

论文 URL: <https://www.aminer.cn/pub/5ec49a639fced0a24b4de922/>

10. 题目: *ExpBERT: Representation Engineering with Natural Language Explanations* (ExpBERT: 自然语言解释的表示工程)

作者: Murty Shikhar、Koh Pang Wei、Liang Percy

论文 URL: <https://www.aminer.cn/pub/5eb3dc4191e011ce31f27fe0/>

11. 题目: *Span-ConveRT: Few-shot Span Extraction for Dialog with Pretrained Conversational Representations* (Span-ConveRT: 用预训练的会话表示方法用于少镜头跨度提取任务)

作者: Coope Sam、Farghly Tyler、Gerz Daniela、Vulić Ivan、Henderson Matthew

论文 URL: <https://www.aminer.cn/pub/5ec3ae5691e0112b1608a125/>

12. 题目: *Biomedical Entity Representations with Synonym Marginalization* (同义词边缘化的生物学实体表征)

作者: Sung Mujeen、Jeon Hwisang、Lee Jinhyuk、Kang Jaewoo

论文 URL: <https://www.aminer.cn/pub/5eafe7e091e01198d39865fd/>

13. 题目: *Interpreting Pretrained Contextualized Representations via Reductions to Static Embeddings* (通过对静态嵌入的简化来解释经过预训练的上下文表示问题)

作者: Rishi Bommasani、Kelly Davis、Claire Cardie

论文 URL: <https://www.aminer.cn/pub/5ec49a639fced0a24b4de828/>

14. 题目: *Probing Linguistic Features of Sentence-Level Representations in Relation Extraction* (关系抽取任务中句子表示的语言特征探讨)

作者: Christoph Alt、Aleksandra Gabryszak、Leonhard Hennig

论文 URL: <https://www.aminer.cn/pub/5ec49a639fced0a24b4de8b3/>

ICML 2020 会议的表示学习相关论文

1. 题目: *Convex Representation Learning for Generalized Invariance in Semi-Inner-Product Space* (半内积空间中广义不变性的凸表示学习)

作者: Ma Yingyi、Ganapathiraman Vignesh、Yu Yaoliang (于耀亮)、Zhang Xinhua (张歆华)

论文 URL: <https://www.aminer.cn/pub/5ea8009091e0111d387ee6a2/>

2. 题目: ***Semiparametric Nonlinear Bipartite Graph Representation Learning with Provable Guarantees*** (具有可证明保证的半参数非线性二分图表示学习)

作者: Na Sen、Luo Yuwei、Yang Zhuoran (杨卓然)、Wang Zhaoran、Kolar Mladen

论文 URL: <https://www.aminer.cn/pub/5e5f7c4791e011df604ecaae/>

3. 题目: ***Provable Representation Learning for Imitation Learning via Bi-level Optimization*** (基于双层优化的模拟学习任务中的可证明表示学习)

作者: Arora Sanjeev、Du Simon S. (杜少雷)、Kakade Sham、Luo Yuping、Saunshi Nikunj

论文 URL: <https://www.aminer.cn/pub/5e5644103a55ac122e36c3ae/>

4. 题目: ***Automatic Shortcut Removal for Self-Supervised Representation Learning*** (面向自监督表示学习的自动快捷方式删除方法)

作者: Minderer Matthias、Bachem Olivier、Houlsby Neil、Tschannen Michael

论文 URL: <https://www.aminer.cn/pub/5e4faa9f3a55ac969512bbdb/>

5. 题目: ***A Free-Energy Principle for Representation Learning*** (表征学习的自由能原理)

作者: Gao Yansong、Chaudhari Pratik

论文 URL: <https://www.aminer.cn/pub/5e5cd97391e011498fe97186/>

6. 题目: ***Robust Graph Representation Learning via Neural Sparsification*** (基于神经稀疏化的鲁棒图表示学习)

作者: Cheng Zheng、Bo Zong、Wei Cheng、Dongjin Song、Jingchao Ni、Wenchao Yu、Haifeng Chen、Wei Wang

论文 URL: <https://www.aminer.cn/pub/5ede0553e06a4c1b26a83fa8/>

7. 题目: ***Informative Dropout for Robust Representation Learning: A Shape-bias Perspective*** (面向鲁棒表征学习任务中的信息缩减方法: 一种形状偏差的视角)

作者: Baifeng Shi、Dinghuai Zhang、Qi Dai、Jingdong Wang（王井东）、Zhanxing Zhu（朱占星）、Yadong Mu（穆亚东）

论文 URL: <https://www.aminer.cn/pub/5ede0553e06a4c1b26a83e53/>

8. 题目: *Adaptive Adversarial Multi-task Representation Learning*（自适应对抗性多任务表示学习）

作者: Yuren Mao、Weiwei Liu（刘威威）、Xuemin Lin（林学民）

论文 URL: <https://www.aminer.cn/pub/5ede0553e06a4c1b26a83eb4/>

9. 题目: *Understanding Contrastive Representation Learning through Alignment and Uniformity on the Hypersphere*（用超球面上的对齐性和均匀性来理解对比表示学习）

作者: Tongzhou Wang、Tongzhou Wang

论文 URL: <https://www.aminer.cn/pub/5ede0553e06a4c1b26a84184>

10. 题目: *Representation Learning via Adversarially-Contrastive Optimal Transport*（基于对抗性最优传输的表征学习）

作者: Anoop Cherian、Shuchin Aeron

论文 URL: <https://www.aminer.cn/pub/5ede0553e06a4c1b26a841ea/>



3. 人才篇

3. 人才篇

本篇通过 AMiner 科技情报大数据平台对表示学习领域的 10 个顶级学术会议及期刊（ICLR、NeurIPS、ICML、AAAI、IJCAI、ACL、EMNLP、CVPR、ICCV、ECCV）论文进行关键词挖掘，获得这些会议和期刊最近 10 年的研究论文，再通过提取论文中的所有作者信息进行人才整体分析，例如地区分布、学术水平分析、研究机构分布等。

3.1 表示学习领域学者情况概览

● 全球顶级领域学者概况

学者分布地图对于进行学者调查、分析各地区竞争力现况尤为重要，图 10 为表示学习领域全球顶尖学者分布状况。地图根据学者当前就职机构地理位置进行绘制，其中颜色越深表示学者越集中。从地区角度来看，欧洲中部、美国的东部和西部人才最为集中，亚洲东部也有较多的人才分布，大洋洲、非洲、南美洲的学者数量稀少。



图 10 表示学习领域全球顶级学者分布图

● 领域顶级学者数量 TOP10 国家分布

表示学习领域顶级学者数量 TOP10 国家分布如图 11 所示。从国家角度来看，中国在表示学习领域的人才数量遥遥领先，美国次之，其余国家领域学者数量不足千人。




图 11 表示学习领域顶级学者数量 TOP10 国家

- 领域顶级学者数量 TOP10 机构分布

表示学习领域顶级学者数量 TOP10 机构分布如图 12 所示，全部来自于中国和美国。从所在机构分布来看，美国卡耐基梅隆大学在表示学习领域的人才数量居首，微软和谷歌次之。中国的中国科学院在表示学习领域的人才数量居于第四位，清华大学、北京大学领域学者数量分别位于第五、第六位。




图 12 表示学习领域顶级学者数量 TOP10 机构

- 领域顶级学者 h-index 分布

表示学习领域学者的 h-index 分布如图 13 所示，整体上学术水平都较高，分布大体呈阶梯状，其中 h-index 在 10 以下区间的人数最多，有 2760 人；在 60 以上的只有 200 多人。




图 13 表示学习领域学者的 h-index 分布

● 中国领域学者分布

我国专家学者在表示学习领域的分布如图 14 所示。可以看出，京津冀在本领域的人才数量最多，随后是长三角和珠三角地区，黑龙江、湖北等地区也有较多分布。此外，通过观察中国周边国家的学者数量情况，特别是与日韩、东南亚等亚洲国家相比，中国在表示学习领域学者数量方面有绝对优势。




图 14 我国表示学习领域顶级学者分布图

● 表示学习领域的中外合作情况

中国与其他国家在表示学习领域的论文合作情况可以由 AMiner 科技情报大数据平台分析得到。在上述期刊/会议中合作论文数量 TOP10 的国家如图 15 所示，从中可以看出中美两国学者在本领域合作的论文数量遥遥领先，体现出中美学者在表示学习领域的密切合作关系。




图 15 表示学习领域中国学者合作论文数量 TOP10 国家

3.2 代表性学者简介


本章节依托 AMiner 平台，针对表示学习领域，综合参考 h-index 指标和领域专家推荐意见，筛选了国外和国内各 10 位代表性学者进行学者画像展示和简要介绍（排名不分先后）。限于报告篇幅，本报告不能对所有学者逐一罗列，如有疏漏或要获得更多学者信息，请与 AMiner 编者联系，或者登录 <https://www.aminer.cn/> 获取更多资料。

“学者画像”是 AMiner 平台的核心服务功能之一。学者画像的特色在于除了提供专家学者如姓名、单位、地址、联系方式、个人简介、教育经历等个人基本信息之外，还利用团队多年的命名排歧技术，建立了较为完善的学者-论文映射关系，提供学者研究兴趣发展趋势分析、学者合作关系网络分析等，同时支持用户交互，通过众包方式丰富更新专家学者的相关信息。

3.2.1 国外代表性学者

Yoshua Bengio

加拿大蒙特利尔大学教授



Bengio 于 1991 年获得加拿大麦吉尔大学计算机科学博士学位，曾是麻省理工学院和贝尔实验室的博士后。目前是加拿大蒙特利尔大学计算机科学和运筹学系教授、机器学习实验室（MILA）主任、CIFAR 项目的 CIFAR 神经计算和自适应感知项目的联合主任与高级研究员（并共同指导其在机器和大脑学习计划）、加拿大统计学习算法研究主席、MILA（蒙特利尔大学学习算法学院）的创始人兼科学主任、NSERC-Ubisoft 工业主席、NEURIPS 基金会的董事会成员，也是 NEURIPS 的课程主席和总裁。此外，目前还担任《机器学习研究》杂志的行动编辑、《神经计算》杂志的副编辑、《机器学习的基础和趋势》杂志的编辑，还曾担任《机器学习》杂志和《IEEE 神经网络汇刊》的副编辑。2016 年 10 月，Bengio 联合创立了 Element AI（一家位于蒙特利尔的企业孵化器，致力于将人工智能研究转化为实际的商业应用）；2017 年 5 月，Bengio 宣布加入蒙特利尔的法律创业公司 Botler AI，担任战略顾问。

自 2014 年以来，他一直致力于深度学习。目前，他的研究兴趣包括关于深度学习和表征学习的基本问题、高维空间中的泛化几何、多元学习、生物学启发式学习算法以及统计机器学习的具有挑战性的应用。主要研究目标是理解产生智力的学习原理。

Yoshua Bengio 与 Geoffrey Hinton、Yann LeCun 一起，被称为人工智能三大奠基人。他在人工神经网络和深度学习方面做出了突出贡献，撰写了三本书，超过 500 种出版物，经常被引用在深度学习、复现神经网络、概率学习算法、自然语言处理和多元学习领域，其中，*Deep Learning* 是他与 GAN 之父 Ian Goodfellow 等人合著的入门深度学习必读经典教程；他的论文 *A neural probabilistic language model* 开创了神经网络 Language Model（语言模型）的先河，其思路和见解对自然语言处理领域任务产生了巨大而持久的影响，包括语言翻译、问题回答和视觉

回答。自 2010 年以来，Bengio 关于生成式深度学习的论文，特别是与 Ian Goodfellow 一起开发的生成式对抗网络（GANs），在计算机视觉和计算机图形学领域引发了一场革命。

所获得奖项荣誉包括：2009 年 ACFAS Urgel-Archambault 奖、2017 年加拿大勋章官员、2017 加拿大皇家学会会员、2018 加拿大 AI 协会终身成就奖、2018 年图灵奖、2019 年 Killam 计算机科学奖、2019 IEEE CIS 神经网络先锋奖等。

表示学习领域论文发布量 **36** 篇，引用量 **47076** 次。

领域代表作

（1）论文标题： *Representation Learning: A Review and New Perspectives*

发表期刊/会议： IEEE Trans. Pattern Anal. Mach. Intell

发表年份： 2013

URL： <https://www.aminer.cn/pub/53e9986eb7602d97020a7ef9/>

引用数： 6920

（2）论文标题： *Gradient-Based Learning Applied to Document Recognition*

发表期刊/会议： Proceedings of the IEEE


发表年份： 1998

URL： <https://www.aminer.cn/pub/53e9b85bb7602d970441f6c2/>

引用数： 27652

Geoffrey Hinton

加拿大多伦多大学教授



Hinton 于 1978 年获得爱丁堡大学人工智能博士学位。在卡内基梅隆大学任职五年后，他转任多伦多大学，目前是荣誉退休教授。此外，他还是谷歌的副总

裁和工程研究员以及向量研究所的首席科学顾问。Hinton 是英国皇家学会会员、美国国家工程学院外籍成员和美国艺术与科学学院外籍成员。

在 1986 年的一篇“学习误差传播内部表示”论文中，Hinton 与 David Rumelhart 和 Ronald Williams 一起证明了神经网络反向传播算法允许发现自己的内部表示的数据，使该算法可以使用神经网络来解决问题，这个问题曾经被认为是无解的。反向传播算法是目前大多数神经网络的标准算法。1983 年，Hinton 与 Terrence Sejnowski 一起发明了玻尔兹曼机器，这是第一批能够学习不属于输入或输出的神经元内部表征的神经网络之一。2012 年，Hinton 和他的学生 Alex Krizhevsky 和 Ilya Sutskever 一起改进了卷积神经网络，使用了整流线性神经元（ReLU）和 dropout 正则化。在著名的 ImageNet 竞赛中，Hinton 和他的学生几乎将物体识别的错误率降低了一半，并重塑了计算机视觉领域。

所获奖项包括：2001 年 Rumelhart 奖、2005 年 IJCAI（国际人工智能联合会议）卓越研究奖、2012 年享有加拿大诺贝尔奖之称的 Killam 奖、IEEE 弗兰克 Rosenblatt 奖牌、IEEE James Clerk Maxwell 金牌、NEC C&C 奖、西班牙对外银行奖、2010 年 NSERC 赫兹伯格金牌（这是加拿大在科学和工程的最高奖项），2018 年因在深度学习方面的贡献获得图灵奖。

表示学习领域论文发布量 14 篇，引用量 42363 次。

领域代表作

（1）论文标题：*Distributed representations*

发表期刊/会议：Parallel distributed processing: explorations in the microstructure of cognition

发表年份：1986

URL: <https://www.aminer.cn/pub/53e9979bb7602d9701f682af/>

引用数：2002

（2）论文标题：*Learning representations by back-propagating errors*

发表期刊/会议：Neurocomputing: foundations of research


发表年份：1986

URL: <https://www.aminer.cn/pub/53e99997b7602d97021d8b06/>

引用数：40644

Yann LeCun

脸书 AI 研究院研究主任



LeCun 获得法国皮埃尔和玛丽居里大学计算机博士学位，1987 年至 1988 年曾是多伦多大学 Geoffrey Hinton 实验室的博士后研究员。目前担任脸书 AI 研究院的主任，也是纽约大学数据科学、计算机科学、神经科学和电子工程的教授、纽约大学摩尔-斯隆数据科学环境（Moore-Sloan Data Science Environment）项目的主要教员、美国纯粹与应用数学研究所（Institute for Pure and Applied Mathematics）的科学顾问委员会成员。曾任 IJCV、IEEE PAMI、IEEE Trans 的编委。

他的研究兴趣包括人工智能、机器学习、深度学习方法、计算机感知、移动机器人和计算神经科学。他已经发表了 180 多篇关于这些课题的技术论文和书籍章节。

他以使用卷积神经网络（CNN）进行光学字符识别和计算机视觉方面的工作而闻名，是卷积网络的创始人。他在贝尔实验室开发的字符识别技术被世界各地的多家银行用于读取支票，本世纪初，该技术读取的支票数量占美国所有支票总数的 10% 至 20%。他的图像压缩技术被称为 DjVu，被数百家网站、出版商和数百万用户用来访问网上的扫描文件。

所获奖项荣誉包括：2014 年 IEEE 神经网络先锋奖、2015 年 IEEE PAMI 杰出研究员奖、2016 年墨西哥 IPN 荣誉博士、2018 年图灵奖等。

表示学习领域论文发布量 **31** 篇，引用量 **37429** 次。

领域代表作

论文标题：*Gradient-Based Learning Applied to Document Recognition*

发表期刊/会议：Proceedings of the IEEE

发表年份：1998

URL: <https://www.aminer.cn/pub/53e9b85bb7602d970441f6c2/>

引用数：27652

吴恩达（Andrew Y. Ng）

斯坦福大学客座教授



吴恩达于 2002 年获得加州大学伯克利分校的博士学位，并从这年开始在斯坦福大学工作。2010 年加入谷歌开发团队 XLab；2014 年 5 月加入百度，担任百度公司首席科学家，负责百度研究院的领导工作，尤其是 Baidu Brain 计划；2017 年 10 月出任 Woebot 公司董事长；2017 年 12 月，成立人工智能公司 Landing.ai，并担任公司的首席执行官；2018 年 1 月，成立了投资机构 AI Fund。

他的主要兴趣领域在机器学习、深度学习、机器人、人工智能和计算机视觉等方面。

他在 2013 年前共有 128 项学术著作，如 Deep Learning with COTS HPC Systems（发表于 ICML 2013）、Parsing with Compositional Vector Grammars 等。2018 年出版 Machine Learning Yearning 一书，该书面向的用户群体为机器学习从业者，主要介绍机器学习实际使用时的一些策略和技巧。他最知名的事情是，所开发的人工神经网络通过观看一周 YouTube 视频，自主学习识别哪些是关于猫的视频。这个案例为人工智能领域翻开崭新一页。

所获奖项荣誉包括：2007 年获得斯隆奖（Sloan Fellowship）；2008 年入选“the MIT Technology Review TR35”，即《麻省理工科技创业》杂志评选出的科技创新 35 俊杰，以及计算机思维奖（Computers and Thought Award）；2013 年入选《Time》杂志年度全球最有影响力的 100 人之一，其中共 16 位科技界人物。

表示学习领域论文发布量 **15** 篇，引用量 **10068** 次。

领域代表作

论文标题：*An Analysis of Single-Layer Networks in Unsupervised Feature Learning*

发表期刊/会议：AISTATS


发表年份：2011

URL: <https://www.aminer.cn/pub/53e9b0d8b7602d9703b55ed5>

引用数：2092

Christopher D Manning

美国斯坦福大学教授



1989 年获得澳大利亚国立大学学士学位，1994 年获得斯坦福大学语言学博士学位。现任斯坦福大学语言和计算机科学系首位托马斯·西贝尔（Thomas M. Siebel）机器学习教授、斯坦福人工智能实验室（SAIL）主任，以及以人类为中心的斯坦福人工智能研究所（HAI）副主任。他是 ACM、AAAI、ACL 研究员及前 ACL 主席（2015 年）。

他的研究兴趣是自然语言处理，研究目标是让计算机能够智能地处理、理解和生成人类语言材料。

Manning 在将深度学习应用于自然语言处理方面处于领先地位，在树递归神经网络、词向量手套模型、情感分析、神经网络依赖解析、神经机器翻译、问题回答和深度语言理解等方面的研究广为人知。他还专注于分析、自然语言推断和多语言处理的计算语言方法。Manning 与人合著了关于自然语言处理的统计方法

(Manning and Schutze 1999) 和信息检索 (Manning, Raghavan, and Schutze 2008) 的主要教科书，以及关于运算性和复杂谓词的语言学专著。

表示学习领域论文发布量 **10** 篇，引用量 **2102** 次。

领域代表作

论文标题: *Improved Semantic Representations From Tree-Structured Long Short-Term Memory Networks*

发表期刊/会议: International Workshop on the ACL2 Theorem Prover and Its Applications

发表年份: 2015

URL: <https://www.aminer.cn/pub/573696d96e3b12023e5d8d36>

引用数: 1752

Honglak Lee

密歇根大学/谷歌大脑副教授



Honglak Lee 于 2010 年获得斯坦福大学计算机科学系博士学位，导师是吴恩达教授。现任密歇根大学安娜堡分校计算机科学与工程系的助理教授。他曾担任 IEEE TPAMI 深度架构学习专刊的客座编辑，以及 ICML、NIPS、ICCV、AAAI、IJCAI 和 ICLR 的区域主席。

他的研究兴趣集中在深度学习和表示学习上，涵盖无监督和半监督学习、监督学习、迁移学习、结构预测、图形模型和优化。他的方法已成功应用于计算机视觉和其他感知领域。

所获奖项荣誉包括: ICML 和 CEAS 的最佳论文奖、2011 年谷歌教员研究奖，2013 年被 IEEE 智能系统公司选为“人工智能 10 人观察”之一，2015 年获得美国国家科学基金会职业奖。

表示学习领域论文发布量 **25** 篇，引用量 **8709** 次。

领域代表作

论文标题: *Efficient Sparse Coding Algorithms*

发表期刊/会议: NIPS


发表年份: 2006

URL: <https://www.aminer.cn/pub/53e99a1ab7602d970226c43d/>

引用数: 2915

Ian Goodfellow

苹果公司研究主任



Ian Goodfellow 于 2009 年获得斯坦福大学硕士学位，师从吴恩达，2014 年获得蒙特利尔大学博士学位，跟随 Yoshua Bengio 研究机器学习，是机器学习领域备受关注的年轻学者之一。毕业后加入 Google，成为 Google Brain 研究团队的一员；2016 年离开谷歌加入新成立的 OpenAI 研究所，在 2017 年 3 月他重回谷歌研究院。2019 年加入苹果公司，领导机器学习特殊项目组。

他因提出了生成对抗网络（GANs）而闻名，被誉为“GANs 之父”。

表示学习领域论文发布量 **4** 篇，引用量 **109** 次。

领域代表作

论文标题: *Large-Scale Feature Learning with Spike-and-Slab Sparse Coding*

发表期刊/会议: ICML


发表年份: 2012

URL: <https://www.aminer.cn/pub/53e9b844b7602d9704407504>

引用数: 82

Tomas Mikolov

捷克信息、机器人与控制论研究所高级研究员



Tomas Mikolov 于 2012 年获得捷克布尔诺理工大学计算机博士学位。现任捷克信息、机器人与控制论研究所的高级研究员。曾在 2014 年 5 月至 2020 年 3 月担任 Facebook 人工智能研究中心研究科学家。之前，他曾是谷歌 Brain 团队的成员，在这个团队中，他开发并实现了计算单词的分布式表示的高效算法（word2vec 项目）。研究兴趣是基于递归神经网络的语言模型（RNLM），长期目标是研究开发能够使用自然语言学习和与人交流的智能机器。

表示学习领域论文发布量 3 篇，引用量 22049 次。

领域代表作

论文标题：*Distributed Representations of Words and Phrases and their Compositionality*

发表期刊/会议：Neural Information Processing Systems


发表年份：2013

URL：<https://www.aminer.cn/pub/53e9b108b7602d9703b85b88/>

引用数：17021

Antoine Bordes

脸书 AI 研究所研究科学家



2010 年获得法国皮埃尔和玛丽·居里大学机器学习博士学位。曾任蒙特利尔大学博士后和访问学者。2014 年加入脸书 AI 研究所，先后担任研究科学家、研究经理和研究总监。

表示学习领域论文发布量 4 篇，引用量 966 次。

领域代表作

论文标题: *Supervised Learning of Universal Sentence Representations from Natural Language Inference Data*

发表期刊/会议: EMNLP


发表年份: 2017

URL: <https://www.aminer.cn/pub/5c8a8df74895d9cbc633b9b9>

引用数: 919

唐建 (Jian Tang)

蒙特利尔学习算法研究院 (MILA) 助理教授



唐建于 2014 年获得北京大学 EECS 博士学位。目前担任蒙特利尔学习算法研究院 (MILA) 助理教授。曾任密歇根大学和卡内基梅隆大学的博士后，并在

2014 年至 2016 年期间在 Microsoft Research Asia 担任副研究员。研究兴趣包括：深度学习、深度生成模型、强化学习、图表示学习、图神经网络、自然语言的理解和推理、知识图、药物发现、推荐系统等。

表示学习领域论文发布量 **6** 篇，引用量 **125** 次。

领域代表作

论文标题: *An Attention-based Collaboration Framework for Multi-View Network Representation Learning*

发表期刊/会议: CIKM

发表年份: 2017

URL: <https://www.aminer.cn/pub/5a260c3517c44a4ba8a252a6/>

引用数: 67

Jure Leskovec

斯坦福大学副教授



Jure Leskovec 于 2004 年获得斯洛文尼亚卢布尔雅那大学计算机科学学士学位，2008 年获得卡内基梅隆大学计算机科学博士学位。目前担任斯坦福大学计算机科学系副教授。研究重点是对大型社会和信息网络数据挖掘和建模。

表示学习领域论文发布量 **7** 篇，引用量 **3745** 次。

领域代表作

论文标题: *node2vec: Scalable Feature Learning for Networks*

发表期刊/会议: KDD

发表年份: 2016


URL: <https://www.aminer.cn/pub/57aa28de0a3ac518da9896d5/>

引用数: 3274

3.2.2 国内代表性学者

孙茂松 (Maosong Sun)

清华大学计算机科学与技术系教授、博士生导师



孙茂松于 1988 年获得清华大学计算机硕士学位，2004 年获得香港城市大学计算语言学博士学位。现任清华大学计算机科学与技术系教授、博士生导师、党委书记，欧洲科学院（Academia Europaea）外籍院士，清华大学大规模在线教育研究中心主任，教育部在线教育研究中心副主任，清华大学-新加坡国立大学下一代搜索技术联合研究中心共同主任。曾于 2007-2010 年任清华大学计算机系系主任。

主要学术兼职（现任或曾任）为国务院学位委员会第六届学科评议组计算机科学与技术组成员，国家自然科学基金委员会第十二届和第十三届专家评审组成员，国家 973 计划项目首席科学家，国家社会科学基金重大项目首席专家，北京市语言文字工作委员会专家委员会副主任，中国中文信息学会副理事长，《中文信息学报》（计算机类全国核心期刊）主编，Journal of Computer Science and Technology、《中国计算机学会通讯》、《计算机研究与发展》、《计算机科学与探索》、《计算机教育》、《语言文字应用》、《南开语言学刊》、《澳门语言学刊》等期刊编委；中国计算机学会理事，中国人工智能学会理事，中关村开放实验室联盟副理事长，ACM 中国理事会理事，ACL SIGHAN 理事会理事，全国术语标准化技术委员会委员，多个教育部或省级、北京市级重点实验室（涵盖

计算语言学、语言监测、网络文化与数字传播、文化遗产数字化保护等多个领域)的学术委员会主任、副主任或委员,国家语言文字工作委员会“两岸语言文字交流与合作协调小组”成员、863 重点项目“中文为核心的多语言处理技术”总体专家组组长、全国语言学奥林匹克竞赛科学委员会共同主席等。他曾数十次任国际会议或全国性学术会议的大会主席、程序委员会主席或作大会特邀报告。

研究方向为汉语自动分词、自然语言理解、中文信息处理、Web 智能、社会计算和计算教育学等。

曾就汉语自动分词提出了若干重要概念,如“最大交集型歧义切分字段”“真切分歧义与伪切分歧义”“全局统计量与局部统计量”,并在大规模汉语语料库上对“最大交集型歧义切分字段”进行了穷尽式考察,给出了有效的处理策略,并以此为基础,研制出一个集自动分词、词性标注、专名识别和新词识别于一体的汉语分析软件 CSegTag,应用于清华与欧盟近 10 个国家合作的 FP6 项目“超对等语义搜索引擎”中。此外,还就与汉语分词相关联的若干问题进行了研究,如探讨了中文文本自动分类的基本单元是基于字的 N-gram 还是基于词这个问题,初步得到一个重要结论:在分类粒度较粗的条件下,基于字的 Bigram 的分类性能和基于词的分类性能几乎相当。在 2006 年全国“SEWM 中文 Web 信息检索评测”中,课题组集成相关成果的网页自动分类算法给出的结果在综合成绩中排名第一。此外,他还提出了“基于极大规模自然标注语料库的自然语言处理”的学术思想,其基本想法是系统地利用用户在 Web 环境下实现相关应用任务过程中不经意输入或建立的各类信息,以有效提高自然语言处理系统在开放环境下的处理能力(包括对 Web 的适应能力)。

作为项目负责人,主持 973 二级课题、863 重大专项二级课题和探索类课题、国家自然科学基金重点项目和面上项目、国际合作项目等约 20 项,主持完成信息处理用分词 ISO 国际标准 2 项。在国际刊物、国际会议、国内核心刊物上共发表论文 130 余篇。获国家发明专利 4 项,日本专利 1 项。

2012 年,他带领清华大学团队研发了国内中文慕课平台“学堂在线”(http://www.xuetangx.com/),“学堂在线”目前在国内外已形成了广泛影响。

表示学习领域论文发布量 21 篇,引用量 1364 次。

领域代表作

论文标题: *Network Representation Learning With Rich Text Information*

发表期刊/会议: IJCAI


发表年份: 2015

URL: <https://www.aminer.cn/pub/573697086e3b12023e602359/>

引用数: 552

刘知远 (Zhiyuan Liu)

清华大学计算机科学与技术系副教授



刘知远于 2011 年获得清华大学计算机系博士学位, 现任清华大学计算机科学与技术系、副教授。还担任中文信息学会青年工作委员会执委、副主任, 中文信息学会社交媒体处理专委会委员、秘书, SCI 期刊 *Frontiers of Computer Science* 青年编委, ACL、IJCAI、AAAI、NAACL、EMNLP、WWW、WSDM 等著名学术会议的程序委员会委员以及 TKDE、TOIS、JCST 等著名学术期刊审稿人。

主要研究方向为自然语言处理和知识图谱。

已在 AAAI、IJCAI、ACL 等人工智能领域的著名国际期刊和会议发表相关论文 30 余篇。作为项目骨干参与多项国家自然科学基金和 863 项目, 组织开发的“微博关键词”等社交媒体应用, 注册用户已超过 350 万。其团队在 2017 年先后开源了两个工具包 OpenNE (Open-Source Network Embedding) 和 OpenKE (Open-Source Knowledge Embedding), 分别对网络表示学习和知识表示学习进行了系统梳理。

曾获清华大学优秀博士学位论文奖、中国人工智能学会优秀博士学位论文奖、清华大学优秀博士后、中文信息学会青年创新奖，入选 CCF-Intel 青年学者提升计划、中国科协青年人才托举工程。2019 年 1 月，入选麻省理工科技评论“35 岁以下科技创新 35 人”中国区榜单。

表示学习领域论文发布量 **17** 篇，引用量 **1324** 次。

领域代表作

论文标题: *Learning Entity and Relation Embeddings for Knowledge Graph Completion*

发表期刊/会议: AAAI

发表年份: 2015

URL: <https://www.aminer.cn/pub/555048d045ce0a409eb71a69/>

引用数: 1192

赵军 (Jun Zhao)

中科院自动化研究所教授、博士生导师



赵军于 1998 年获得清华大学计算机科学与技术系博士学位。现任中国科学院自动化研究所教授、博士生导师。曾于 1998 年至 2002 年在香港科技大学计算机科学系做博士后、访问学者。2002 年 5 月至今在中科院自动化所模式识别国家重点实验室工作。曾担任 ACL-2016 研讨会联合主席。目前学术兼职包括：中国中文信息学会常务理事、中国中文信息学会语言与知识计算专业委员会副主任、

中国中文信息学会计算语言学专业委员会副主任、ACM Transaction on Asian and Low-Resource Language Information Processing 副主编、《中文信息学报》编委等。

主要研究方向包括：自然语言处理领域的计算语义学、深度学习下的自然语言处理、知识图谱的表示（符号化表示和分布式表示）、知识图谱的建立（实体识别、实体链接、关系抽取、事件抽取）、基于知识图谱的推理、问答系统、基于大规模文本数据的问答、机器阅读理解、社区问答等。

已在 ACL、SIGIR、TKDE、JLMR、IJCAI、EMNLP 等著名国际会议和期刊上发表了 50 余篇同行评审论文。拥有国家软件著作权登记 2 项、专利 8 项。

所获奖励荣誉包括：2018 年钱伟长中文信息处理科学技术奖一等奖、2014 年国家计算语言学大会 COLING-2014 最佳论文奖（论文“通过卷积深度神经网络进行关系分类”）、2011 年 ACM KDD-CUP 亚军。他的另一论文“网络文本中的集体实体链接：一种基于图形的方法”在 Google 学术搜索中最近五年 SIGIR 引用最多的论文中排名第 2。

表示学习领域论文发布量 4 篇，引用量 13 次。

领域代表作

论文标题：*Learning the Multilingual Translation Representations for Question Retrieval in Community Question Answering via Non-Negative Matrix Factorization*

发表期刊/会议：IEEE/ACM Trans. Audio, Speech & Language Processin


发表年份：2016

URL: <https://www.aminer.cn/pub/57a4e901ac44365e35c94ca6>

引用数：16

周国栋（Guodong Zhou）

苏州大学教授、博士生导师



周国栋于 1989 年获得西安交通大学计算机应用学士学位，1992 年获得上海交通大学计算机应用硕士学位，1997 年获得新加坡国立大学计算机学院博士学位。现任苏州大学计算机科学与技术学院特聘教授和博士生导师、苏州大学校学术委员会委员。曾于 1992 年至 1995 年在上海交通大学担任讲师；1998 年至 1999 年在新加坡国立大学计算机学院进行博士后研究；1999 年 04 月进入新加坡资讯通信研究院担任副科学家，2002 年 04 月升任科学家博导，2005 年 04 月升任副主任科学家博导；2006 年 08 月加入苏州大学计算机科学与技术学院担任特聘教授博导，组建苏州大学自然语言处理实验室。

目前学术兼职有 ACM Transaction on Asian Language Information Processing 杂志副主编、《软件学报》杂志责任编委、中国人工智能学会自然语言理解专委会和 CCF 中文信息技术专委会副主任委员，IEEE Computer Society、ACM 和 ACL 等多个国际学术机构的会员。曾经担任国际顶级期刊 Computational Linguistics 杂志编委和 2009-2014 年度 NSFC 信息学部会评专家，以及许多著名的 SCI 国际杂志和 ACL、EMNLP、SIGIR、IJCAI 和 CIKM 等国际会议的评审和委员会委员。

研究方向为自然语言处理、信息抽取、统计机器翻译、机器学习等。

表示学习领域论文发布量 **9** 篇，引用量 **199** 次。

领域代表作

论文标题: *Sentiment Classification and Polarity Shifting*

发表期刊/会议: International Conference on Computational Linguistics

发表年份: 2010

URL: <https://www.aminer.cn/pub/53e9b4efb7602d970401d216>

引用数: 100

王晓刚 (Xiaogang Wang)

香港中文大学副教授/商汤研究院院长



王晓刚于 2001 年获得中国科技大学少年班电子工程与信息科学学士学位，并获郭沫若奖，2004 年获得香港中文大学信息工程硕士学位，2009 年获得麻省理工学院人工智能实验室计算机博士学位。现任商汤研究院院长、香港中文大学电子工程系副教授。也是国际顶级计算机视觉会议 CVPR 2017、ICCV 2011、ICCV 2015、ICCV 2017、ECCV 2014、ECCV 2016、ACCV 2014 和 ACCV 2015 的领域主席。

研究兴趣包括计算机视觉、机器学习和医学图像。

他在顶级的国际期刊和会议发表论文超过 200 篇，Google Scholar 上的引用量超过 19000 次。

所获奖项荣誉包括：2011 年获得自动人物行为分析方面的杰出青年研究员、2012 年获得香港 RGC 杰出青年学者奖，2016 年获得 PAMI 杰出青年学者奖荣誉提名。他带领的商汤-香港中文大学团队于 2016 年和 2017 年获得 ImageNet 大规模视觉识别挑战赛的多项冠军。

表示学习领域论文发布量 24 篇，引用量 6948 次。

领域代表作

论文标题: *Pyramid Scene Parsing Network*

发表期刊/会议：CVPR


发表年份：2017

URL: <https://www.aminer.cn/pub/58d82fced649053542fd7355/>

引用数：2725

汤晓鸥（Xiaoou Tang）

香港中文大学教授



汤晓鸥于 1997 年获得美国麻省理工学院博士学位。现任香港中文大学信息工程系教授、工程学院杰出学者，兼任中国科学院深圳先进技术研究院副院长、IJCV（计算机视觉国际期刊）首位华人主编。全球人脸识别技术的“开拓者”和“探路者”，商汤科技创始人、董事长，马来西亚国家主权基金国库控股公司董事。曾先后在香港中文大学和微软亚洲研究院工作，从事计算机视觉相关领域的研究。

学术兼职担任多个重要的国际会议的主席，包括计算机视觉最顶尖的国际会议 ICCV 和 CVPR，兼任现任影响因子最高的 IEEE 杂志 IEEE Transactions on Pattern Analysis and Machine Intelligence（PAMI）和整个计算机科学领域影响因子最高的 International Journal of Computer Vision（IJCV）的编委（Associate Editor），IJCV 首位华人主编。

研究兴趣包括计算机视觉、模式识别和视频处理。

2001 年，他建立了香港中文大学多媒体实验室，2016 年该实验室与麻省理工、斯坦福等大学一道入选世界十大人工智能先锋实验室。2014 年 3 月，汤晓鸥团队发布研究成果，基于原创的人脸识别算法，准确率达到 98.52%，首次超越人眼识别能力（97.53%）。2016 年，汤晓鸥领军的中国人工智能团队，入选世界十大人工智能先锋实验室，成为亚洲区唯一入选的实验室。为促进深港两地的研究人员交流互通和协同创新，汤晓鸥牵头组建了香港中文大学和中国科学院深圳先进技术研究院的联合实验室，并积极招募了一批海外优秀科研人才加入团队。

所获奖项荣誉包括：2009 年，汤晓鸥教授及其博士研究生何恺明，联同微软亚洲研究院的孙剑博士，凭论文“基于暗原色的单一图像去雾技术”夺得 IEEE 电脑视觉与模式识别大会（CVPR）该年度的“最佳论文奖”，是 CVPR 25 年历史上唯一获奖的亚洲论文。同年，汤晓鸥教授被电机及电子工程师学会（IEEE）推选为院士；2019 年 7 月，马来西亚总理马哈蒂尔任命汤晓鸥担任马来西亚国家主权基金国库控股公司董事。2019 年 10 月 10 日，《2019 年胡润百富榜》汤晓鸥以 50 亿元人民币财富位列第 828 名；2020 年 5 月 12 日，以 78.5 亿元财富位列《2020 新财富 500 富人榜》第 402 位。

表示学习领域论文发布量 29 篇，引用量 5941 次。

领域代表作

论文标题：*Deep Learning Face Representation by Joint Identification-Verification*

发表期刊/会议：NIPS


发表年份：2014

URL：<https://www.aminer.cn/pub/5550414245ce0a409eb39c3e/>

引用数：1622

周志华（Zhi-Hua Zhou）

南京大学教授、博士生导师



周志华于 2000 年获得南京大学计算机科学与技术系博士学位。2001 年 1 月起留校任教，2002 年 3 月被破格聘任为副教授，2003 年获得国家杰出青年科学基金，随后被聘为教授。现任南京大学教授和博士生导师、教育部长江学者特聘教授、南京大学计算机科学与技术系副主任、软件新技术国家重点实验室常务副主任、国家杰出青年基金获得者、校学术委员会委员、南京大学人工智能学院院长（兼）、IJCAI 程序委员会主席，2007 年创建南京大学机器学习与数据挖掘研究所（LAMDA）并任所长。

研究方向主要包括人工智能、机器学习、数据挖掘等。

他著有机器学习入门书籍《机器学习》。

所获奖项荣誉：2012 年当选 IEEE Fellow 和 IAPR Fellow（国际模式识别学会会士）；2013 年当选 ACM Distinguished Scientist（ACM 杰出科学家）和中国计算机学会（CCF）会士，成为大陆高校首位当选 ACM 杰出科学家的学者；2016 年，当选 AAAI Fellow（国际人工智能学会）、美国科学促进会会士（AAAS Fellow），当选 ACM Fellow；2017 年 2 月，当选人工智能领域顶级学术会议 AAAI 2019 程序委员会主席。

表示学习领域论文发布量 19 篇，引用量 965 次。

领域代表作

论文标题：*Multi-Instance Multi-Label Learning with Application to Scene Classification*

发表期刊/会议：Advances in Neural Information Processing Systems


发表年份：2007

URL: <https://www.aminer.cn/pub/53e9ba6ab7602d970468ce75>

引用数: 535

杨强 (Qiang Yang)

香港科技大学教授



杨强于 1989 年获得马里兰大学计算机科学博士学位。现任香港科技大学新明工程学讲席教授、计算机科学和工程学系主任、大数据研究所所长。他是 IEEE Fellow, IAPR Fellow, AAAS Fellow, ACM 杰出科学家, KDD 中国主席。1989 至 1995 年曾任加拿大滑铁卢大学计算机系助理教授及副教授; 2012 年至 2015 年出任华为诺亚方舟实验室创始主任; 2015 年, 任香港科技大学计算机与工程学系主任; 2016 年, 在香港科技大学创建大数据研究所。

他的社会兼职有: 2009 年, 他创建了 ACM 刊物 Transactions on Intelligent Systems and Technology (TIST) 并任首届主编; 2013 年 7 月当选为国际人工智能协会 (AAAI) 院士; 2016 年 5 月当选为 AAAI 执行委员会委员, 同年, 任 ACM 数据挖掘中国分会 (KDD China) 主席; 2017 年 8 月他当选为国际人工智能联合会 (IJCAI, 国际人工智能领域创立最早的顶级国际会议) 理事会主席。

研究领域为机器学习、数据挖掘和自动规划。

他是人工智能研究的国际专家和领军人物, 在学术界和工业界做出了杰出的服务和贡献, 尤其近些年为中国人工智能 (AI) 和数据挖掘 (KDD) 的发展起了

重要引导和推动作用。迄今为止，杨强已发表逾 400 篇关于人工智能和数据挖掘方面的论文，引用超过 20000 次。

所获奖项荣誉：PAKDD 2019 最佳论文奖、2018 年 AAAI 人工智能创新应用奖、2018 年 ACM 智能互动系统交易最佳论文奖（ACM TiS）、2017 年 ACM SIGKDD 杰出服务奖等。

表示学习领域论文发布量 27 篇，引用量 4046 次。

领域代表作

论文标题：Domain Adaptation via Transfer Component Analysis

发表期刊/会议：IEEE Transactions on Neural Networks / A Publication of the IEEE Neural Networks Council


发表年份：2010

URL：https://www.aminer.cn/pub/53e9b029b7602d9703a8594b

引用数：1795

俞勇 (Yong Yu)

上海交通大学教授



俞勇于 1986 年获得华东师范大学计算机科学系硕士学位。现为上海交通大学教授、博士生导师，享受国务院特殊津贴。曾于 1999 至 2009 年担任上海交通大学计算机系副主任。

研究方向是 Web 搜索及挖掘、语义搜索、P2P 搜索、语义 Web、本体工程（Ontology Engineering）和无线应用。

在 WWW、SIGIR 等重要国际会议和 IEEE Transaction 等期刊上发表了 60 余篇论文。他推出了“人机接口与图形学”课程设计，成为上海交通大学颇具特色的三大课程设计之一。曾多次带队在 ACM 国际大学生程序设计竞赛亚洲区预赛中取得第一、二名闯入决赛，在 2000 年的决赛中名列第七，获得铜牌。在 2002 年的决赛中，一举夺魁，捧回世界冠军杯。在 2005 年的决赛中，又一次率队夺得世界冠军，成为全球第 5 个两次夺冠的高校。2010 年 2 月 5 日，率队第三次夺得世界冠军，让上海交大成为世界上第三所该项赛事的“三冠王”。

所获奖项荣誉：曾获得国家级和上海市教学成果奖 6 项，获得“上海市五一劳动奖章”“宝钢优秀教师特等奖”“全国师德先进个人”“上海市师德标兵”和“上海交通大学校长奖”等多项荣誉，并在央视新闻联播、上海教育台专题节目、《光明日报》《解放日报》等十多家媒体均有报道。

表示学习领域论文发布量 15 篇，引用量 1605 次。

领域代表作

论文标题：*Robust Subspace Segmentation by Low-Rank Representation*

发表期刊/会议：ICML


发表年份：2010

URL: <https://www.aminer.cn/pub/53e99ceeb7602d97025a6058>

引用数：1330

张潼（Tong Zhang）

香港科技大学教授



张潼于 1994 年获得美国康奈尔大学数学系和计算机系学士，1996 年获得斯坦福大学计算机系硕士学位，1999 年获得斯坦福大学计算机博士学位。现任香港科技大学计算机和数学系教授，美国统计学会和国际数理统计学会 Fellow。他是一名机器学习、大数据分析领域的国际知名学者。曾任美国新泽西州立大学统计系教授、IBM 研究院研究员、雅虎研究院主任研究员、百度研究院副院长和大数据实验室负责人；2017 年 3 月加盟腾讯任 AILab 主任；2019 年 3 月加盟创新工场兼任科研合伙人，并出任港科大和创新工场联合实验室主任。

主要学术兼职包括担任 NIPS（神经信息处理系统进展大会）、ICML（国际机器学习大会）、COLT（学习理论大会）等国际顶级机器学习会议主席或领域主席，以及 JMLR（机器学习研究期刊）和 Machine Learning Journal（机器学习期刊）等国际一流人工智能期刊编委。

研究兴趣包括机器学习算法和理论、大数据统计方法及其应用等。

他是中央组织部“千人计划”特聘专家。曾参加美国国家科学院大数据专家委员会，并负责过多个美国国家科学基金（National Science Foundation）资助的大数据研究项目。

表示学习领域论文发布量 7 篇，引用量 1047 次。

领域代表作

论文标题: *Learning With Structured Sparsity*

发表期刊/会议: Journal of Machine Learning Research


发表年份: 2009

URL: <https://www.aminer.cn/pub/53e99a85b7602d97022f9ef4>

引用数: 569

蔡登 (Deng Cai)

浙江大学教授



蔡登获得美国 UIUC 大学博士学位，现任浙江大学计算机学院教授和博导、IEEE TKDE 编委、AAAI 2017 和 IJCAI 2017 资深程序委员会委员等。

研究兴趣包括机器学习、数据挖掘、计算机视觉等。

参与项目包括 2013 至 2017 年科技部 973 计划青年项目 2013CB336500 “社交网络信息传播分析与挖掘”、2013 至 2015 年国家自然科学基金优秀青年科学基金项目 61222207 “智能媒体计算”、2012 至 2015 年国家自然科学基金重大研究计划重点支持项目 91120302 “支持无人驾驶车辆的交通标识图文识别与理解”、2010 至 2012 年国家自然科学基金青年项目 60905001 “基于流形理论的人脸识别方法研究” 等。

所获奖项荣誉包括 2012 年国际人工智能年会最佳论文奖、国家优秀青年基金获得者、万人计划青年拔尖人才、青年 973 首席科学家等。

表示学习领域论文发布量 **19** 篇，引用量 **3229** 次。

领域代表作

论文标题: *Laplacian Score for Feature Selection*

发表期刊/会议: NIPS

发表年份: 2005

URL: <https://www.aminer.cn/pub/53e9af87b7602d97039cfee0>

引用数: 1430



4. 趋势篇

4. 趋势篇

作为一项新兴技术，知识表示学习未来技术发展和应用具有巨大潜力。本部分借助领域技术分析系统（<http://trend.aminer.cn>），对所选期刊和会议中的科技论文情报进行深入挖掘，对表示学习的技术趋势及国际研究趋势等方面进行展示和分析。

4.1 技术研究发展趋势

我们根据“表示学习”领域关键词，从 AMiner 数据库中查找出指定期刊会议发表的论文，其中包含论文所在领域的分支术语和年份，统计含有这些术语论文数量，给出论文数量排名前 10 的技术术语，再统计这些术语的起止年份，划分时间窗格，生成大数据智能的发展趋势图，如图 16 所示。




图 16 表示学习领域热点技术趋势图

上图中的每个颜色表示一个领域分支术语，其宽度表示该术语在当年的热度，与当年该分支领域的论文数量呈正相关；各分支在每一年份中按照其热度进行排序，越热的在越上方。对目前热度靠前的 10 个分支领域进行历史热度展示，从趋势图中可以看出，“强化学习”“无监督学习”“迁徙学习”“自然语言处理”的研究热度近年来提升且处于“表示学习”热点技术的前列；“语义表示”“稀

疏表示”“图像分类”“特征提取”“网络表示学习”“信息检索”等分支的研究热度近年来有些下降但也是“表示学习”领域的重要热点研究分支。

4.2 国家研究发展趋势

根据 AMiner 平台分析不同国家在“表示学习”领域的研究趋势（如图 17 所示），图中每条色带表示一个国家，其宽度表示该国家在当年的研究热度，与当年该国论文数量呈正相关，每一年份中按照其热度由高到低进行排序。通过国家趋势分析可以发现当前“表示学习”领域研究热度 Top10 的国家分别是：中国、美国、英国、加拿大、澳大利亚、新加坡、法国、德国、印度和日本。




图 17 表示学习领域国家的研究发展趋势

根据国家趋势分析我们可以发现，“表示学习”领域当前研究热度最高的国家是中国，从全局热度来看，中国、美国、英国等国家在该领域的整体研究热度基本变化不大。

4.3 技术发展面临的挑战

表示学习的一大挑战是很难建立清晰的训练目标。Bengio 等人已经提出，一个好的表征可以解开变异的潜在因素，但如何将其转化为适当的训练标准？在一个好的模型下，除了最大化可能性之外，还有必要做其他事情吗？或者是否可以

引入如先验（可能是依赖数据的先验），以帮助表示法更好地解开变异的潜在因素等等许多问题需要解决。

表示学习中的概率模型经常遇到的挑战是在训练过程中，取样变得非常低效或不可靠。这是因为学习分布的模式变得更敏捷，使模式之间的混合变得非常慢。

对人工神经网络和深度学习算法的批评之一是它们有许多超参数和变量，而探索它们的配置和架构是一门艺术。另外，虽然正则化效果在小数据集上很重要，但在非常大的数据集上持续存在的效果表明存在一些优化问题。它们更多地是由于局部极小值和训练过程的动态性产生的吗？或者它们主要是由于不良条件作用，可以用近似的二阶方法来处理？这些问题目前仍然没有答案，值得更多研究。

网络表示学习主要面临着以下三方面挑战^[3]。

（1）知识驱动的网络表示学习。目前已有的网络表示学习模型没有考虑知识图谱等外部知识信息，而外部丰富的知识信息能够为网络表示学习及其后续应用提供推理能力。

（2）大规模网络表示学习。已有的网络表示学习模型仅仅能够针对小规模的网络进行有效的训练，而实际场景中的社交网络动辄存在上亿节点。因此，如何克服真正大规模社交网络表示学习过程中面临的表示存储、训练效率、异构信息的融合等问题，是网络表示学习迈向实际应用场景的亟待解决的关键挑战。

（3）结合具体应用的网络表示学习。已有的网络表示学习模型的训练过程一般使得节点表示尽可能拟合网络的真实结构，而忽略这些节点表示后续的应用，因此，网络表示学习在应用方面面临着如何发掘更多场景和后续场景的挑战。

此外，以 TransE 为代表的知识表示学习模型，虽然在知识图谱补全、关系抽取等任务中表现较好，但面临着如何处理复杂关系建模、如何实现多源信息融合、关系路径建模等几方面挑战^[2]。

参考文献

- [1] Bengio, Yoshua, Aaron Courville, Pascal Vincent. "Representation learning: A review and new perspectives." *IEEE transactions on pattern analysis and machine intelligence* 35, no. 8 (2013): 1798-1828. <https://arxiv.org/abs/1206.5538>
- [2] 刘知远, 孙茂松, 林衍凯,等. 知识表示学习研究进展[J]. 计算机研究与发展, 2016, 53(2):247-261.
- [3] 涂存超, 杨成, 刘知远, 孙茂松. (2017). 网络表示学习综述. 中国科学: 信息科学, 47(8), 980-996.
- [4] 李志义, 黄子风, 许晓绵. 基于表示学习的跨模态检索模型与特征抽取研究综述[J]. 情报学报,2018, 37(4): 422-435, DOI: 10.3772/j.issn.1000-0135.2018.04.008
- [5] 孙晓玲,丁堃.深度学习中的表示学习研究及其对知识计量的影响[J].情报理论与实践,2018,41(09):118-122.
- [6] McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4), 115-133.
- [7] Hebb D O. *The Organization of Behavior, A Neuropsychological Theory*. Hoboken: John Wiley, Chapman Hall, 1949
- [8] Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*,65(6), 386.
- [9] Minsky, M.L. and Papert, S. (1969) *Perceptrons: An Introduction to Computational Geometry*. The MIT Press, Cambridge, 3356-3362.
- [10] Werbos, P. (1974) *Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Science*. Ph.D. Dissertation, Harvard University, Cambridge, 29(18): 65-78.
- [11] Rumelhart, D.E., Hinton, G.E. and Williams, R.J. (1986) Learning Representations by Back-Propagating Errors. *Nature*, 323, 533-536. <https://doi.org/10.1038/323533a0>

- [12] Hinton, G.E., Osindero, S. and The, Y.W. (2006) A Fast Learning Algorithm for Deep Belief Nets. *Neural Computation*, 18, 1527-1554.
<https://doi.org/10.1162/neco.2006.18.7.1527>
- [13] Guoqiang Zhong, Li-Na Wang, Xiao Ling, Junyu Dong (2016). An overview on data representation learning: From traditional feature learning to recent deep learning.
- [14] Cortes, C., & Vapnik, V. (1995). Support vector machine. *Machine learning*, 20(3), 273-297.
- [15] Greene W H. Marginal effects in the bivariate probit model[J]. *Social Science Electronic Publishing*[OL]. [2017-07-25].
<http://archive.nyu.edu/bitstream/2451/26254/2/EC-96-11.pdf>.
- [16] Hinton, G. E. (2009). Deep belief networks. *Scholarpedia*, 4(5), 5947.
- [17] Ngiam J, Khosla A, Kim M, et al. Multimodal deep learning[C]//*Proceedings of the International Conference on Machine Learning*. Washington, USA, 2011: 689-696
- [18] Yoshua Bengio, Jérôme Louradour, Ronan Collobert, Jason Weston. Curriculum learning. *ICML*:6-48.2009
- [19] Xavier Glorot, Antoine Bordes, Yoshua Bengio. Deep sparse rectifier neural networks. *AISTATS*:315-323,2011
- [20] Yoshua Bengio, James Bergstra. Random search for hyper-parameter optimization. *Journal of machine learning research*:281-305.2012
- [21] 吴海燕.基于自动编码器的半监督表示学习与分类学习研究[D]重庆大学. 2015
- [22] Jacob Andreas, Marcus Rohrbach, Trevor Darrell. Neural Module Networks. *CVPR*:39-48.2016
- [23] 朱陶, 任海军, 洪卫军.一种基于前向无监督卷积神经网络的人脸表示学习方法[J].*计算机科学*,2016,43(6):303-307.
- [24] 李志宇, 梁循, 徐志明, 齐金山, 陈燕方.DNPS:基于阻尼采样的大规模动态社会神经网络特征表示学习[J].*计算机学报*, 2017 (4) : 805-823
- [25] 李志义, 王冕, 赵鹏武.基于条件随机场模型的“评价特征-评价词”对抽取研究[J]*情报学报*, 2017.4:411-421

- [26] Siddique Latif and Rajib Rana and Sara Khalifa and Raja Jurdak and Junaid Qadir and Björn W. Schuller, “Deep Representation Learning in Speech Processing: Challenges, Recent Advances, and Future Trends,” arXiv preprint arXiv: 2001.00378, 2020
- [27] Frank Seide, Gang Li, Dong Yu. Conversational speech transcription using context-dependent deep neural networks. ICML: 437-440. 2011
- [28] G.E. Dahl, Dong Yu, Li Deng. Context-dependent Pre-Trained deep neural networks for large-vocabulary speech recognition. IEEE Transactions on Audio, speech & language processing: 30-42. 2012
- [29] Nicolas Boulanger-Lewandowski, Yoshua Bengio, Pascal Vincent. modeling temporal dependencies in high-dimensional sequences: application to polyphonic music generation and transcription. ICML: 1881-1888. 2012
- [30] G.E. Hinton, J.L. McClelland, D.E. Rumelhart. Distributed representations. Parallel distributed processing: explorations in the microstructure of cognition: 77-109. 1986
- [31] Yoshua Bengio, Jean-Sebastien Senecal. Quick training of probabilistic neural nets by importance sampling. AISTATS. 2003
- [32] Yoshua Bengio, J S Senecal. Adaptive importance sampling to accelerate training of a neural probabilistic language model. IEEE Transactions on neural networks: 713-722. 2008
- [33] Ronan Collober, Jason Weston, Léon Bottou, Michael Karlen, Koray Kavukcuoglu, Pavel Kuksa. Natural Language Processing (Almost) from Scratch. Journal of Machine Learning Research: 2493-2537. 2011
- [34] Jason Weston, Gustavo Camps-Valls, Frédéric Ratle, Semisupervised Neural Networks for Efficient Hyperspectral Image Classification, IEEE Transactions on Geoscience and Remote Sensing, Volume 48, Issue 5, 2010, Pages 2271-2282.
- [35] Nitish Srivastava, Ruslan Salakhutdinov. Multimodal Learning with Deep Boltzmann Machines. NIPS: 2231-2239. 2012
- [36] Mikolov, T., Kombrink, S., Burget, L., Cernocky, J.H.. Extensions of recurrent neural network language model. Acoustics, Speech and Signal Processing: 5528-5531. 2011

- [37] Holger Schwenk,Anthony Rousseau,Mohammed Attik. Large, pruned or continuous space language models on a GPU for statistical machine translation.WLM@NAACL-HLT:11-19.2012
- [38] Richard Socher,Cliff Chiung-Yu Lin,Andrew Y. Ng ,Christopher D. Manning.Parsing Natural Scenes and Natural Language with Recursive Neural Networks.ICML:129-136. 2011.
- [39] Antoine Bordes,Xavier Glorot,Jason Weston,Yoshua Bengio.Joint Learning of Words and Meaning Representations for Open-Text Semantic Parsing.AISTATS:127-135. 2012
- [40] Xavier Glorot,Antoine Bordes,Yoshua Bengio.Domain Adaptation for Large-Scale Sentiment Classification: A Deep Learning Approach.ICML:513-520.2011
- [41] Richard Socher,Jeffrey Pennington,Eric H. Huang,Andrew Y. Ng ,Christopher D. Manning.Semi-supervised recursive autoencoders for predicting sentiment distributions.EMNLP:151-161. 2011
- [42] 刘康, 张元哲, 纪国良,等. 基于表示学习的知识库问答研究进展与展望[J]. 自动化学报, 2016.
- [43] 龚静.中文文本聚类研究[M]. 2012:42-46
- [44] 苏新宁. 情报学研究生教材[M]信息检索理论与技术,2004:35-36.
- [45] 黄春梅,王松磊.基于词袋模型和 TF-IDF 的短文本分类研究[J].软件工程,2020,23(3):1-3
- [46] 陈燕, 张金松. 大数据技术及其应用[M]. 2015:190-194
- [47] 刘胜杰,许亮.基于词嵌入技术的文本表示研究现状综述[J].现代计算机,2020(01):40-43.
- [48] Hinton G E, McClelland J L, Rumelhart D E. Distributed representations / / Rumelhart D E, McClell J L, PDP C eds. Research Group. Parallel Distributed Processing: Explorations in the Microstructure of Cognition, V01. 1. Cambridge, USA: MIT Press, 1986: 77 109
- [49] 孙飞,郭嘉丰,兰艳艳,徐君,程学旗.分布式单词表示综述[J].计算机学报,2019,42(7):1607-1608

- [50] Perozzi B, Al-Rfou R, Skiena S. Deepwalk: online learning of social representations. In: Proceedings of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, New York, 2014. 701–710
- [51] Tang J, Qu M, Wang M, et al. Line: large-scale information network embedding. In: Proceedings of the 24th International Conference on World Wide Web, Florence, 2015. 1067–1077
- [52] Yang C, Sun M S, Liu Z Y, et al. Fast network embedding enhancement via high order proximity approximation. In: Proceedings of International Joint Conference on Artificial Intelligence (IJCAI), Melbourne, 2017
- [53] Cao S, Lu W, Xu Q. Grarep: learning graph representations with global structural information. In: Proceedings of the 24th ACM International on Conference on Information and Knowledge Management, Melbourne, 2015. 891–900
- [54] Wang D, Cui P, Zhu W. Structural deep network embedding. In: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, San Francisco, 2016. 1225–1234
- [55] Yang J, Leskovec J. Overlapping community detection at scale: a nonnegative matrix factorization approach. In: Proceedings of the 6th ACM International Conference on Web Search and Data Mining, Rome, 2013. 587–596
- [56] Ou M, Cui P, Pei J, et al. Asymmetric transitivity preserving graph embedding. In: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, San Francisco, 2016. 1105–1114
- [57] Tu C, Wang H, Zeng X, et al. Community-enhanced network representation learning for network analysis. arXiv:1611.06645
- [58] Thomas L G, Mark S. Finding scientific topics. Proc National Acad Sci, 2004, 101: 5228–5235
- [59] Yang C, Liu Z, Zhao D, et al. Network representation learning with rich text information. In: Proceedings of the 24th International Conference on Artificial Intelligence, Buenos Aires, 2015. 2111–2117
- [60] Tu C C, Liu H, Liu Z Y, et al. CANE: context-aware network embedding for relation modeling. In: Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics, Vancouve, 2017. 1722–1731

- [61] Tu C C, Zhang W C, Liu Z Y, et al. Max-Margin DeepWalk: discriminative learning of network representation. In: Proceedings of International Joint Conference on Artificial Intelligence (IJCAI), New York, 2016.
- [62] Li J Z, Zhu J, Zhang B. Discriminative deep random walk for network classification. In: Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics, Berlin, 2016. 1004–1013
- [63] Grover A, Leskovec J. Node2vec: scalable feature learning for networks. In: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, San Francisco, 2016. 855–864
- [64] Kipf T N, Welling M. Semi-supervised classification with graph convolutional networks. In: Proceedings of the 5th International Conference on Learning Representations, Toulon, 2017
- [65] Yang Z, Cohen W, Salakhutdinov R. Revisiting semi-supervised learning with graph embeddings. In: Proceedings of the 33rd International Conference on International Conference on Machine Learning, New York, 2016
- [66] Tu C C, Zhang Z Y, Liu Z Y, et al. TransNet: translation-based network representation learning for social relation extraction. In: Proceedings of International Joint Conference on Artificial Intelligence (IJCAI), Melbourne, 2017
- [67] 赵鹏大.定量地学方法及应用[M]. 2004:158-162
- [68] Mikolov T, Chen K, Corrado G, et al. Efficient estimation of word representations in vector space[J]. Proc of ICLR. arXiv:1301.3781.2013
- [69] Nickelm, Rosasco, Poggiot. Holographic embeddings of Knowledge graphs [J]. Arxiv preprint arxiv:1510.04935.2015
- [70] Hinton, Geoffrey E. (1984). Distributed representations. Parallel Distributed Processing: Explorations in the Microstructure of Cognition. Volume 1: Foundations, MIT Press, Cambridge, MA.
- [71] Rumelhart, D. , Hinton, G. , & Williams, R. . (1986). Learning representations by back-propagating errors. 323(6088), 696-699.
- [72] Bengio, Y., Courville, A., & Vincent, P. (2013). Representation learning: A review and new perspectives. IEEE transactions on pattern analysis and machine intelligence, 35(8), 1798-1828.

- [73] Mikolov, Tomas, et al. Distributed representations of words and phrases and their compositionality. Advances in neural information processing systems. 2013.
- [74] Bordes, Antoine, et al. Translating embeddings for modeling multi-relational data. Advances in neural information processing systems (NIPS). 2013.
- [75] Cho, K. , Merrienboer, B. , Gülçehre, Ç. , Bahdanau, D. , Bougares, F. , Schwenk, H. , & Bengio, Y. . (2014). Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation. Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP), 2014.
- [76] Perozzi, Bryan, Rami Al-Rfou, and Steven Skiena. Deepwalk: Online learning of social representations. Proceedings of the 20th ACM SIGKDD international conference on Knowledge discovery and data mining. 2014.
- [77] Radford, a. , Metz, l. , & Chintala, s. . (2015). Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks. [abs/1511.06434](https://arxiv.org/abs/1511.06434)
- [78] Vaswani, Ashish, et al. Attention is all you need. Advances in neural information processing systems. 2017.
- [79] Devlin, Jacob, et al. Bert: Pre-training of deep bidirectional transformers for language understanding. Proceedings of NAACL-HLT 2019.

版权声明

AMiner 研究报告版权为 AMiner 团队独家所有，拥有唯一著作权。AMiner 咨询产品是 AMiner 团队的研究与统计成果，其性质是供用户内部参考的资料。

AMiner 研究报告提供给订阅用户使用，仅限于用户内部使用。未获得 AMiner 团队授权，任何人和单位不得以任何方式在任何媒体上(包括互联网)公开发布、复制，且不得以任何方式将研究报告的内容提供给其他单位或个人使用。如引用、刊发，需注明出处为“AMiner.org”，且不得对本报告进行有悖原意的删节与修改。

AMiner 研究报告是基于 AMiner 团队及其研究员认可的研究资料，所有资料源自 AMiner 后台程序对大数据的自动分析得到，本研究报告仅作为参考，AMiner 团队不保证所分析得到的准确性和完整性，也不承担任何投资者因使用本产品与服务而产生的任何责任。

顾问 刘知远 李涓子 唐杰

编写 张淼 高洁 甄洁玲

数据 赵慧军

扫描二维码

下载报告全文



报告编号 AITR-20-07