

深度学习驱动的可视化

刘灿¹⁾, 赖楚凡¹⁾, 蒋瑞珂¹⁾, 李彦达¹⁾, 杨昌和¹⁾, 林志贤¹⁾, 魏大同¹⁾, 袁晓如^{1,2)*}

¹⁾(北京大学机器感知与智能教育部重点实验室 北京 100871)

²⁾(北京大学大数据分析与应用技术国家工程实验室 北京 100871)

(xiaoru.yaun@pku.edu.cn)

摘要:近年来,深度学习技术在充足的计算能力之下得到飞速的发展.在可视化与可视分析流程中,部分需要人为参与的环节和问题,已然能够借用数据驱动的方式来替代和解决.该综述基于经典的可视化与可视分析流程,即可视化的压缩、构建、交互、评估等各个方面,审视了其中能够借助深度学习技术的部分,并对相关研究进行了详细而系统的论述,探讨深度学习技术与可视化结合带来的技术红利,深刻分析深度学习驱动的可视化未来发展的前景.

关键词:机器学习;可视化;深度学习

中图法分类号: TP391.41 DOI: 10.3724/SP.J.1089.2020.18492

Visualization Driven by Deep Learning

Liu Can¹⁾, Lai Chufan¹⁾, Jiang Ruike¹⁾, Li Yanda¹⁾, Yang Changhe¹⁾, Lin Zhixian¹⁾, Wei Datong¹⁾, and Yuan Xiaoru^{1,2)*}

¹⁾(Key Laboratory of Machine Perception (Ministry of Education), Peking University, Beijing 100871)

²⁾(National Engineering Laboratory of Big Data Analysis and Application, Peking University, Beijing 100871)

Abstract: In recent years, deep learning technology developed rapidly with sufficient computing ability. In the visualization and visual analysis process, some steps that require human participation can be replaced and solved by data-driven methods. This article is based on the division of classic visualization and visual analysis process, including construction, interaction, evaluation, and other aspects of visualization. This article reviewed the parts that can use deep learning technology, carried out a detailed and systematic discussion of related research, discussed the technical benefit brought by the combination of deep learning technology and visualization, and deeply analyzed the prospects of the development of visualization driven by deep learning.

Key words: machine learning; visualization; deep learning

1 简介

可视化与可视分析是通过图形元素映射数据信息,并提供交互式的可视界面以支持对数据的探索、分析、推理的学科方向.常规的可视化与可

视分析流程从数据出发到获取可视分析结果,通常包含以下环节:(1)数据预处理(包括压缩);(2)可视化设计与构建;(3)交互分析;(4)结果评估.各个环节对于人或机器参与的需求不尽相同.其中数据预处理部分环节则往往需要大量人力资源

收稿日期: 2020-07-14; 修回日期: 2020-08-04. 基金项目: 国家自然科学基金(61872013); 国家数值风洞计划(NNW2018-ZT6B12). 刘灿(1996—), 男, 博士研究生, 主要研究方向为机器学习驱动的可视化; 赖楚凡(1990—), 男, 博士研究生, 主要研究方向为信息可视化; 蒋瑞珂(1994—), 男, 博士研究生, 主要研究方向为可视化数据集构建; 李彦达(1996—), 男, 硕士研究生, 主要研究方向为科学可视化; 杨昌和(1996—), 男, 硕士研究生, 主要研究方向为科学可视化; 林志贤(1995—), 男, 硕士研究生, 主要研究方向为可视化智能交互; 魏大同(1996—), 男, 硕士研究生, 主要研究方向为可视化智能交互; 袁晓如(1975—), 男, 博士, 研究员, 博士生导师, CCF 杰出会员, 论文通讯作者, 主要研究方向为科学可视化、信息可视化、可视分析、人机交互.

或者专家经验以支持分析、设计和决策。

近年来,深度学习技术飞速发展.通过大量数据的训练,深度学习模型能够很好地学习人类的认知与行为模式,从而在各个应用领域部分或完全地取代人类的重复机械的劳动.在可视化与可视分析领域亦是如此.近年来,可视化领域中涌现出一系列的研究,从不同方向探索了深度学习驱动的可视化与可视分析的可能性.在上述环节中,除去部分强烈依赖算法和与人类想象力相关的设计外,深度学习在其余环节中均展现了巨大的研究价值与应用潜力.本文将依照上述流程,分别从可视化的压缩表征、快速构建、智能交互、结果评估等方面,对相关研究工作展开系统而详尽的介绍,如表 1 所示.此外,自然语言在可视化与可视分析流程的人类高级感知中扮演重要的角色,自然语言与可视化结合的部分将会被单独说明.

表 1 可视化流程中的深度学习

可视化流程	研究方向	相关工作
压缩表征	参数空间至结果空间	InSituNet ^[1] , NNVA ^[2] , Berger 等 ^[3]
	结果间插值	TSR-TVD ^[4] , GenerativeMap ^[5] , Kwon 等 ^[6]
	逆向工程生成	DeepOrganNet ^[7] , DNN-VolVis ^[8]
	数据特征压缩	Cheng 等 ^[9] , Xu 等 ^[10] , Hong 等 ^[11] , Han 等 ^[12]
快速构建	数据特征至可视化结果	VizML ^[13] , Data2Vis ^[14]
	信息图	Chen 等 ^[15] , Text-to-Viz ^[16]
智能交互	智能选取	LassoNet ^[17] , FlowNet ^[18] , Porter 等 ^[19]
	自然语言交互	FlowSense ^[20] , Iris ^[21] , Orko ^[22] , Lai 等 ^[23] , AutoCaption ^[24]
	特征检测及增强	Quan 等 ^[25] , Deng 等 ^[26] , Kim 等 ^[27]
结果评估	自动评估	Fu 等 ^[28] , Kwon 等 ^[6,29] , Hammad 等 ^[30] , DeepDrawing ^[31]
	综合考虑用户感知	ScatterNet ^[32] , Yang 等 ^[33] , Shi 等 ^[34]

2 深度学习驱动的可视化压缩表征

可视化结果及其背后的数据所占用的资源随着数据量的增大以及可视化的多样性日趋加大.与此同时,大规模数据生成可视化结果往往需要耗费大量时间与计算资源.一种快速而有效的替代方法是利用深度神经网络的泛化能力,对数据进行压缩表征以支持隐式合成可视化的近似结果.

在隐式构建可视化过程中,深度神经网络具有了表征数据的能力.借助这种能力,可以让模型作为复杂或者大规模数据的低成本替代表达.

生成可视化的过程往往是从参数空间出发,映射到可视化的结果空间中.这个过程中可能面临巨大的数据量和巨大的参数空间^[1],从而需要大量的时间.采用传统的体渲染方法由于其效率无法在不同参数间快速切换,导致用户探索比较集合模拟数据的效率降低.利用深度神经网络的生成能力直接从参数生成可视化,经过训练的模型可以作为原始数据及可视化的压缩表征. InSituNet^[1]使用卷积回归模型(convolutional regression model)学习集合模拟数据可视化中参数与体渲染结果之间的映射关系.当用户在调整集合模拟参数及视角、等值面参数后,该系统可快速合成出该参数组合下的渲染结果,该模型训练及使用流程如图 1 所示.该模型由回归器、特征比较器和鉴别器 3 部分组成.在训练时,输入参数通过回归器生成预测渲染结果.预测结果与真实渲染结果通过特征比较器和鉴别器计算损失函数,其中特征比较器计算如边缘、形状等的图像特征差别,鉴别器计算图像分布差别.类似的端到端直接合成的思路同样在适用于不同的数据和问题.针对酵母细胞极化模拟数据, Hazarika 等^[2]将参数和模拟结果作为数据,训练神经网络预测模拟结果,以支持快速的模型参数探索.该方法首先采样输入参数,执行模拟过程,获得训练数据,其中网络采用多层全连接结构,对各区域的蛋白质浓度进行回归.训练完成后, NNVA 固定网络权重,优化输入参数以最大化输出,寻找符合用户指定条件下的最优输入参数. NNVA 还在模型中随机丢弃部分参数,对相同输入产生不同的输出,以使研究者注意到模型的不确定性.同样针对输入参数直接生成结果, Berger 等^[3]使用深度神经网络生成体渲染结果.该网络采用生成对抗网络(generative adversarial networks, GAN)^[35]框架,生成器 G 以视角参数向量和离散化的传递函数向量作为输入,传递函数向量经过若干一维卷积层生成特征向量后,与视角参数向量分别经过全连接层拼接成一个向量,再经过二维卷积生成三通道 256×256 分辨率的图像;判别器以参数向量、传递函数向量与图像为输入,判断该图像是否为生成器的生成结果.针对训练后的体数据,用户在设置视角与一维传递函数后可快速得到渲染图像.为更好地理解传递函数之间的关系,该工作对传递函数向量的特征向量进

行降维投影至二维平面上, 用户可在该平面上直接选取传递函数. 此时, 此二维平面中的位置是不同传递函数下的渲染结果的特征.




图 1 InSituNet^[1]的训练及使用流程图

除了根据参数直接合成可视分析结果, 通过可视化结果之间插值生成可视化也可以作为部分可视化结果的表征. Han 等^[4]使用深度学习提升时变体数据的时间分辨率. 该工作使用递归神经网络(recurrent neural networks, RNN)与 GAN 相结合的网络模型, 以 2 个时间步的体数据作为输入, 输出中间时间步的体数据序列, 网络结构如图 2 所示. 生成器 G 由 2 个 RNN 组成, 分别对输入的前一个时间步进行前向预测, 对后一个时间步进行后向预测. 双向预测结果及原数据经过混合模块混合后即可得到合成结果. 将合成结果与真实值输入判别器 D 进行训练. 该方法也可处理多变量体数据, 一个变量训练的网络可用于另一变量生成时间高分辨率结果. Chen 等^[5]提出基于深度生成模型的方法 GenerativeMap, 用以推测离散密

度图的中间变化过程. 在训练数据收集阶段, 他们使用柏林噪声生成训练数据, 并使用高斯模糊减少噪声. GenerativeMap 采用基于 BiGAN^[36]的框架, 使用编码器将真实的密度图图片转换为分布向量, 使用生成器将分布向量转换为图片, 使用判别器判读图片-向量对的真实性. 为解决原始模型输入精度低, 细节存在缺陷的问题, GenerativeMap 设计与 ResNet^[37]相似的块, 并采用了更大的卷积核. 为生成动态密度图, GenerativeMap 将起始和终止时间步的密度图转换为向量, 对向量采取线性插值获得中间时间步的分布向量, 最后将向量转换为各时间步的密度图图片. GenerativeMap 还使用蓝噪声采样来使变化更为平滑. 结果显示该方法可以学习密度图的平滑过渡, 且插值时间步增加时, 计算效率优于传统方法. 除科学数据或渲染图像的生成外, 也有一些工作以针对其他形式的可视化结果生成的方式来让模型具有表征可视化的能力. Kwon 等^[6]使用深度生成模型, 以部分图布局为输入, 寻找图布局的隐式空间, 帮助用户快速探索可能的图布局. 该模型的输入为一个图数据以及该图数据在不同参数条件下的布局结果. 模型采用变分自编码器架构. 编码器部分采用 3 层图神经网络(graph neural networks, GNN)学习节点表示 1 个 readout 层学习图层次的表示, 最后为多层感知机学习图布局的二维表示.




图 2 使用 RNN 与 GAN 生成中间时间步的体数据^[4]

Wang 等^[7]提出深度学习网络 DeepOrganNet, 用于重建具有高保真度三维或四维网格数据的基于单幅肺部投影图像. 该方法首先基于经典深度卷积神经网络(convolutional neural networks, CNN)—MobileNets^[38]生成对于肺部投影图像的特征编码向量, 并基于该特征针对肺部模型的左部和右部

分别独立分支处理. 不同的分支网络均针对各候选肺部网格模型模板训练选择权重和对应的变形参数. 该方法针对施加变换后的具有最高选择权重的肺部网格模型, 进一步训练空间变换参数来调整左右肺部分支的相对位置, 最终生成组合后的网格模型. 该方法在上述过程采用端对端训练

方式, 针对网络流程设计了包含变形损失、空间变换损失和正则化的优化函数. 与已有其他方法相比, 该方法能够生成更高质量的模型结果. Hong 等^[8]提出一种采用深度学习方法的体数据可视化方法. 该工作提出了多判别器 GAN. 对于一个体数据, 在传递函数未知的情况下, 模型可以接收视角参数和目标效果图像作为输入隐式地学习传递函数并且直接生成目标效果在目标视角参数下的图像. 因此, 用户可以通过一幅静态渲染结果交互式探索体数据, 该模型可以直接合成在新视角下相同渲染结果的结果. 此渲染结果和真实的结果仅具有细小的差异. 深度学习的技术同样可以应用于科学可视化体绘制流程中的特征选择. 由于仅仅依靠传统方法中基于强度值、梯度值等进行手动设计的方式难以针对结构复杂的体数据构建详尽的可视化结果, Cheng 等^[9]提出了一种基于机器学习辅助的体数据可视化流程, 该方法采用 CNN 计算得到的高层次深度特征辅助用户进行搜索和选择. 为了生成深度特征, 该方法在训练阶段针对每个体素构建一个分类任务, 使用 CNN 中来分类渲染过程中属于各种不同复杂结构的体素. 进一步地, 该方法采用矢量量化压缩和特征重排的方法使得构建出的深度特征空间得以高效帮助用户构建可视化结果. Xu 等^[10]提出了一种针对三维的几何网格类型牙齿模型数据, 采用 CNN 进行数据切分和标注分类, 以生成边界清晰特征鲜明的可视化效果的新方法. 该方法对于原始的牙齿模型数据进行网格简化, 并针对简化后的网格数据中的三角面片多种几何特征, 构建特征向量. 该方法进一步采用一个两级的深度 CNN, 分别执行不同的分类任务并进行特征标注, 其网络结构基于传统的卷积层与全连接层相连的分类任务范式. 其中, 网络第 1 级针对进行牙齿牙龈的分离, 第 2 级着重于分别标注各个不同牙齿. 实验证明基于深度网络的特征标注和多样的后处理技术得到的结果对于模型表面上的任何可能异物都具有很强的稳定性.

在大规模数据的可视化计算过程中, 深度学习网络也可用于表征数据特征. 这种需求在流场可视化中尤为常见. 通过并行粒子追踪绘制流线是流场可视化的常用手段, 数据预取(data prefetching)则是大规模流场粒子追踪应用中用以解决大量数据 I/O 等待的一种行之有效的策略. Hong 等^[11]首次在这一问题的研究中引入了深度学习模型, 通过长短时记忆网络(long short term memory networks,

LSTM)^[39]对粒子轨迹进行建模, 能更为准确地预测粒子对数据块的访问, 从而提高大规模粒子追踪算法的效率. 在该方法中, 粒子轨迹的坐标序列被转化为粒子所访问数据块的序列, 历史的访问记录作为 LSTM 的数据输入, 输出并行粒子追踪过程中对于粒子移动的数据块预测. 该方法相较于 Zhang 等^[40]提出的基于高阶访问依赖的数据预取方法, 能够获得同样准确率的预测结果, 同时显著地减少了存储代价. Han 等^[12]提出了一种应用深度学习技术, 根据流场粒子追踪完成后的迹线数据恢复原始的向量场数据, 达到对于流场数据约减化的数据管理方法. 该方法共分为 2 个不同的阶段, 第 1 阶段采用反向传播方法由初始的采样轨迹点快速恢复一个低分辨率的向量场, 该方法首先初始化一个随机的向量场, 通过插值产生不同位置的预测速度, 计算误差并反向传播. 第 2 阶段将低分辨率的向量场输入 CNN, 生成精细粒度的向量场, 同样采用插值, 反向传播, 逐步优化. 该方法采用的 CNN 包含多个反卷积层, 并采用残差结构有效地提升效果.

综上所述, 深度学习方法可以隐式表达可视化中的特征和规律, 实现通过模型来压缩大规模数据及其可视化表达.

3 深度学习驱动的可视化快速构建

可视化的设计、实现过程通常需要大量的人力劳动和陡峭的学习曲线. 针对给定的数据, 开发人员需要先探索理解数据、确定需求, 进而选择合适的设计方案, 并实现相应代码, 最后根据实现的结果迭代改善设计. 这种方式需要开发者对数据、代码实现、可视化结果都具有深入的理解. 针对非可视化专业群体的可视化构建方法将为领域专家和大众提供高效便捷的数据分析手段. 然而, 在可视化生成与构建的过程中涉及许多人类知识和规律, 难以通过简单的规则进行覆盖. 有赖于深度学习网络在决策、用户知识学习的强大能力, 近年来, 深度学习被引入以实现可视化的自动化快速构建.

研究者通过分析数据特征并结合可视化知识向分析者推荐数据选择和可视化映射方式选择. 快速可视化构建可以支持数据的快速探索, 压缩迭代时间. 在此过程中, 深度学习被应用于从已有的数据可视化中学习数据特征与可视映射间的关系. 常见的基于深度神经网络的可视化构建有 2

类, 一类是显式地表征数据特征和可视化设计的输入和输出, 通过可解释的方法在其中的某一步中进行决策; 另一类是通过隐式方法端到端地构建, 如从数据出发直接生成可视化代码。

VizML^[13]是第 1 类方法的代表, 将可视化生成视为根据数据特征进行设计选择的过程. VizML 设计并计算了单属性、属性对和数据集层次的数据特征, 将可视化分解为可视编码和可视化 2 个层级. 可视编码包括图元类型、属性对应的坐标轴、坐标轴是否映射多个属性; 可视化设计包括可视化类型和是否存在共用的坐标轴. VizML 采用全连接神经网络模型, 分别使用单属性特征预测可视编码设计和数据集特征预测可视化设计. 该方法在可视化平台 Plotly 的可视化数据集上, 预测性能超过了其他基准模型. 与上述方法具有一定的可解释性不同, Data2Vis^[14]将可视化生成过程看做将原始数据转换为可视化代码的端到端转化过程. Data2Vis 使用端到端的神经网络自动生成可视化, 神经网络的输入是表格数据中采样的一个数据项, 以 JSON 格式存储, 记录该数据项属性名称与属性值的对应关系, 输出为符合 Vega-Lite 语法^[41]的代码. 模型采用编码器-解码器架构, 编码器采用双向循环神经网络, 将输入的字符转化为隐状态, 解码器为基于注意机制的循环神经网络, 将隐状态转化为代码序列的概率分布. 编解码器均使用字符作为基本的单元, 其中属性名称以其属性类型代替. 在输出过程中, 采用束搜索 (beam search) 方法, 输出概率最大的前 k 个代码序列. 这类方法节省了分析者尝试各种数据组合和可视化设计的时间, 有效提升可视探索的效率.

为传递数据探索过程发现的重要信息, 有时需要借助于信息图的形式. 信息图能让信息更易引起关注和增强记忆, 提高信息传达的效果. 信息图的设计空间复杂, 对美观性的要求高, 往往需要专业设计者来完成. 设计者已经公开了很多信息图设计, 用户可以借助这些信息图的设计来展示自己的数据. 然而由于公开信息图大多是位图格式的图片, 制作这些信息图需要掌握构建工具的复杂功能, 对普通用户来说难度大, 且会耗费大量精力. 深度学习被用于快速构建信息图, 减轻用户负担. Chen 等^[15]提出自动解析时间线相关的信息图, 构建信息图模板的方法. 对位图格式的时间线, 该方法使用 ResNeXt^[42]模型提取图片特征, 使用全连接网络对信息图的类型、方向等全局信息进行分类. 将 ResNeXt 模型输出的特征图, 输入区域

候选网络等物体检测常用模型, 进行元素类型、位置、掩膜等局部信息的预测. 构建信息图模板时, 使用非最大合并策略处理预测元素位置重叠的问题, 通过聚类来恢复未检测元素的类型和位置, 并通过 DL GrabCut 算法^[43]提升掩膜的精度. 根据用户提供的新数据, 该方法即可从模板生成新的时间线信息图. Cui 等^[16]提出另一种创建信息图的新方法 Text-to-Viz, 根据用户提供的与占比相关的自然语言, 自动生成信息图. 该工作的作者通过收集和分析占比相关的文本, 将文本中的符号分为数字、修饰词、整体、部分、其他等类别. 该方法设计文字分析器, 对用户的输入进行分词, 计算各字符初始的特征矩阵, 输入一维 CNN 获取特征表征, 最后使用条件随机场进行符号分类. 对于文本分类结果, 该方法设计信息图生成器接收文本分类信息, 通过对存储的信息图布局模板和其他设计空间维度进行枚举, 生成最终的信息图. 这类方法帮助用户生成丰富、专业的信息图. 然而, 这类方法提供了基于模板或基于样例的可视化形式, 无法实现形式上的创新设计.

从以上工作可以看出, 深度学习方法可以学习人类可视探索经验, 分析数据特征, 选择合理的可视化设计, 加速数据探索过程; 也可以解析已有设计, 提供快速的复用, 帮助用户展示探索结果.

4 深度学习驱动的可视化智能交互

在用户与可视化交互的过程中, 深度学习方法同样能够发挥重要作用. 用户与可视化的交互形式多样, 包括键盘、鼠标、触摸、手势、语音、眼动等多种方式的输入. 越来越多的工作致力于利用深度学习网络来理解藏匿于用户操作背后的真实交互意图, 从而实现可视化的智能交互. 实现这一目标需要结合人工智能技术和可视化专业知识, 对可视化内容及其背后数据有更深层的理解, 从而更好地解析用户操作, 智能地辅助用户交互. Chen 等^[17]针对三维空间上点的选择这一难以精确表示三维空间中点集的这一挑战, 通过训练深度模型以拟合二维空间选择到三维空间选择的映射, 使得用户能够在二维空间中使用套索来更加精准地选择三维点阵云中的点集. 用户在屏幕上圈选范围后, 系统首先将所有点的世界坐标通过矩阵变换为当前视角的相机坐标, 然后由相机参数确定每个点是否落在视锥范围内. 根据套索位置选出用户关注区域, 并将其内点进行采样后输入

PointNet^[44]结构的神经网络中计算每个点的特征向量, 最终输出每个点被选中的概率. 由于 PointNet 中的池化层仅能保留全局特征, 该工作采用多层级的网络结构生成点云的局部和全局特征. 不同数据集上的用户实验表明, LassoNet 更能理解用户需要选择哪些点.

在流场可视化中的选取交互同样具有挑战性, Han 等^[18]使用一个深度学习框架来支持对流场可视化中的代表性流线和表面的选取. FlowNet 使用深度神经网络将流场中的流线和流面进行聚类, 使得用户能够在降维投影的平面上快捷直观地选择流线或流面. 该网络使用自动编码-解码模型, 编码器将体素化的流线或流面输入三维 CNN, 生成 1024 维特征向量; 解码器将特征向量恢复为流线或流面体数据. 经试验不同方法后, 该工作使用 *t*-SNE^[45]对特征向量降维至二维空间, 并用 DBSCAN^[46]算法对每个流线或流面聚类.

在数据量很大的时候, 如何从众多可视化中选取代表性的结果, 是用户交互探索发现中面临的一个难题. Porter 等^[19]提出了一种基于深度学习技术对时变的多变量数据进行代表性时间步选取的方法. 该方法首先将不同时间步的降采样后的体数据输入自编码器, 获得压缩化的特征向量表达, 其中每个变量对应一个通道; 然后针对不同时间步数据的特征向量进行维度约减, 最终在降维投影空间中选择代表性时间步. 该方法中采用的自编码器的编码和解码部分对偶的采用了卷积和反卷积模块. 与基于信息论的传统方法相比, 深度学习模型对原始数据获得更加深刻的理解和表达, 基于该方法选取的时间步揭示了原始数据中更多的内涵.

自然语言是一种低门槛符合人类认知的信息, 利用自然语言可以辅助可视理解、提供新型的交互方式. 近年来一些工作采用深度学习方法降低可视化与自然语言间的隔阂. 在可视化与自然语言结合的新型方法下, 可视化结果的快速构建、可视化结果的和自然语言的新型高效交互可以实现.

对自然语言的处理可以实现可视化的快速构建. Yu 等^[20]允许用户使用自然语言进行可视化构建. 基于数据流的可视化构建系统包含数据处理、可视化、交互等函数节点. 通过生成、连接这些节点, 用户可以可视探索数据. 然而这类系统需要用户进行学习和理解, 使其难以广泛应用. FlowSense 是一种基于自然语言, 同数据流式可视化构建系

统进行交互的技术. FlowSense 定义了语法规则, 以对用户的语言进行语义解析. 其中, 函数名称、类型、数据名称相关的语言被定义为特殊语句占位符(special utterance placeholder), 从而适应不同的数据. 在解析时, FlowSense 使用 CoreNLP^[47]进行词性标注, 基于关键词对函数进行分类, 基于模板对用户查询进行补全, 使用线性分类器预测消歧方式. 执行查询时, 根据鼠标位置和节点上次交互时间预测用户未指明对节点. FlowSense 可以帮助用户简化和加快可视化构建流程. Fast 等^[21]支持自然语言探索表格数据并构建可视化. 会话智能体一般只能处理简单处理, 若需解析复杂指令, 需要用先进方法在大规模数据集中训练. 语言学理论认为, 人们可以通过原子会话行为进行意义构建, 即一个复杂的语句可以由若干简单语句嵌套而成. Fast 等基于该理论, 提出会话智能体 Iris, 可以帮助用户进行复杂数据的分析和可视化任务. 用户可以给 Iris 输入指令, 并通过对话增加和修改指令输入参数. Iris 为指令定义了自动机, 判断当前对话是否为用户输入新指令, 输入指令的缺失参数, 或者可以进行指令的执行. 相较于使用 Jupyter Notebook 进行数据分析和可视化, Iris 的交互速度更快. 在其他类型的数据上也有相关工作, Srinivasan 等^[22]则允许用户通过自然语言进行图数据的可视化. Orko^[22]是针对图可视化的多模式交互方法, 该方法支持多种图可视化任务, 允许用户使用直接交互和自然语言进行交互, 并考虑不同交互模式的协同. Orko 结合文法模式匹配和关键词匹配以解析用户输入, 转换为系统的交互行为. 对于用户不同模式的输入, Orko 使用用户界面状态和用户输入时间间隔来对交互模式进行分类, 以决定是否需要在不同交互间共享状态信息.

在加速可视化结果的理解方面, 一些新型交互方式以及机器生成方式也开始提出. Lai 等^[23]提出了一种基于文本描述的可视化自动高亮和注释的方法. 如图 3 所示, 该方法采用神经网络模型结合图像处理技术提取识别可视化图表中的各个实体标记及其视觉属性, 然后将这些可视化图表的信息和用户的文本描述结合起来, 通过自然语言处理, 得到可视化对象与语义信息的匹配. 用户给定可视化图表及其对应描述后, 该方法能够自动生成可视化标注和高亮结果的一系列动画. Liu 等^[24]对可视化图表生成描述的自然语言以辅助交互, 对可视化图表的描述的自动生成可以进一步提高理解可视化图表的效率, 并且可以提供

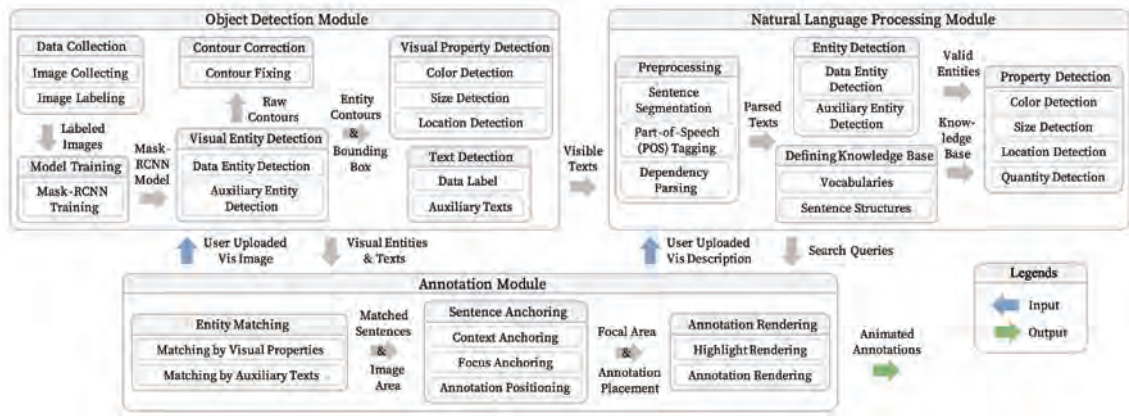


图 3 用户上传可视化图片和描述文本, 系统自动生成高亮和注释结果并允许用户修改样式^[23]

对可视化图表的检索、复用的信息。但传统的可视化研究很少关注可视化的自然语言自动生成过程。该工作提供了一个可视化图表的自动生成方法, 通过借助深度学习网络自动生成自然语言。该方法提出的深度一维 CNN, 将视觉信息和数据信息映射成相应的向量作为模型的输入。其主要过程如下:

Step1. 从可视化图表中提取可视化元素的视觉信息和数据信息, 其中视觉信息包括颜色、形状等, 而数据信息是由可视化元素背后的数据决定。

Step2. 利用深度模型将元素划分至不同类型可视化描述的元素组。

Step3. 组合不同描述类型的各类元素, 并通过生成自然语言的模板将其转化成为自然语言。

在直接体渲染中, 获得理想的效果往往需要大量的用户交互, 基于体素分类的体渲染能够优化这一过程, 为了取得更好的分类性能, Quan 等^[25]的工作使用卷积稀疏编码与随机森林, 根据用户的输入将体数据中的体素自动分类, 并使用基于概率的传递函数进行体渲染。作者首先将二维图像的卷积稀疏编码拓展到三维空间中, 并在求解能量方程最小值过程中使用 blackout 策略去除随机或能量最高的部分卷积过滤器(原子)避免陷入局部最值。进一步地, 该工作使用多尺度卷积稀疏编码提升分类准确性, 使用较小的卷积过滤器近似原数据, 得到原子字典、稀疏图及对应的响应图, 再用中等大小的卷积过滤器近似小尺度响应图之和(近似结果), 最后用较大的卷积过滤器近似中尺度响应图之和。综合每个体素的三维坐标及在各个稀疏图中的取值可得到该体素的 75 维特征向量。在用户使用笔刷将切片中少量体素分类后, 该系统使用随机森林算法根据体素的 75 维特征向量对所有体素进行分类, 并根据体素属于每

个类别的概率及各个类别的传递函数加权, 得到最终颜色。该方法可有效地避免数据中的噪声, 并取得了很好的分类效果。

在流场数据中, 针对涡旋的检测和分析是帮助用户高效理解数据的一种重要手段。Deng 等^[26]借助深度神经网络提出了一种新解决方案, 该方案能够结合全局和局部方法的优势, 从而获得更高的准确度和召回率。该方法首先将流场数据网格标准化, 并将流场中的涡旋检测问题建模为一个标准化网格阵列中的格点二分类问题, 即判断每一个数据格点是否属于漩涡结构。该方法提出了一个 CNN Vortex-Net 执行该分类任务, 网络的输入是待检测点周围的采样数据块, 输出为该点的涡旋标注, 整体结构上采用了常见的多层卷积与全连接相结合的范式。Kim 等^[27]提出了一种应用 CNN 提出了一种针对非定常二维向量场提取稳态参考系以进行涡旋检测的新方法。该方法通过将不同时间步的向量场数据输入 CNN, 最终回归生成一个 6 维度的向量, 各维度分别代表参考系变换的一阶和二阶导数。该方法同时提出了一个基于数值计算示例矢量场进行参数化的矢量场模型, 以支持监督训练下的大量数据需求。与现有的线性参考系优化方法相比, 深度学习的引入使得该方法针对数据中的噪声和人工痕迹具有较强的抗性。

从上述工作中可以看出, 将深度学习引入可视化交互的流程中, 通过对用户意图进行解析以及辅助用户操作, 能够提高交互的效率, 有助于构建更为智能的交互系统。

5 深度学习驱动的可视化结果评估

针对可视化结果的评估方法一直以来是可视

化研究领域十分重要的组成部分, 该问题一直以来具有很强的挑战性. 究其原因在于, 针对可视化的评估方法需要统筹兼顾主、客观, 综合考虑多样的结果评价方式. 一方面, 由于可视化最终面向的受众是广大的用户, 不同用户由于其学习经验、审美方式、使用场景和可视化任务有所不同, 因而可视化结果评估本身即具有一定的主观成分. 另一方面, 产生可视化的算法流程具有其固有的特性和弱点, 使得其在结果表达时对于特定的数据、场景应用具有天生的适应性和不足, 依据深度学习方法即可在一定程度上产生较为公认的结果初步度量, 因而客观上可视化结果评估同时具有较为统一的评价准则. 良好的可视化结果评估方法能够综合考虑并平衡上述 2 个不同方面, 得到符合可视化结果特征且在一定程度上不偏离主观意见的评估结果.

传统的针对可视化结果的常见评估方式大多基于已有的、强先验的指导性、经验化的理论体系, 并采用公式化的计算方法进行指标化的评估. 由于不同方法采用的评估指标有所不同, 往往各自倾向于一个不同的独立方向, 因而多种指标下得到的评估结果也难以达成统一, 或者需要用户进行进一步地筛选和分辨, 这为针对可视化结果的合理评估带了巨大的困难. 随着大数据和深度学习领域研究的不断深入, 基于深度学习和数据驱动的可视化结果评估方法开始被提出, 并逐渐成为可视化评估问题的主流方法.

基于深度学习驱动的可视化结果评估方法能够有效地针对可视化方法本身的特性和数据编码方式, 生成足够细致而可靠的建模, 从而引出针对可视化结果科学而合理的评估. 不同于研究者对可视化的不同方面进行评价时往往需要进行的用户实验, Fu 等^[28]提出使用机器学习方法, 自动评价可视化, 其基本工作流程如图 4 所示. 该方法使用变分自编码器, 编码器将可视化图片编码为隐向量, 解码器根据向量进行重构, 使得重构结果与原图片尽可能一致. 该方法获得的隐向量为可视化图片的高层次表示, 可以用于预测可视化的指标和不同指标下的排序. 实验结果表明较之传统方法或者其他神经网络提取的特征, 该方法提取的特征能提供更准确的预测结果. 基于深度学习驱动的可视化同样能够较好地应用于图可视化布局算法的评估. 图布局影响用户对图的理解, 用户需要寻找可以有效地描述图结构的布局算法和参数.

然而大规模图数据的布局计算时间漫长, 用户需要有方法快速地预测布局结果. 图布局存在多种可读性度量指标, 通常这些指标的计算复杂度较高, 且需要布局中各节点的坐标信息. Kwon 等^[29]探索性地通过传统机器学习方法使用图核计算图相似性, 展示图在不同布局中的外观及评估结果. Haleem 等^[30]则提出借助深度学习方法, 根据图布局的图片计算各项指标. 模型采用 6 个卷积层, 2 个全连接层的结构. 训练数据中, 部分图数据由图数据生成方法进行生成, 其他图数据则从真实的大规模数据中随机游走采样获取. 对每个图数据, 需根据不同参数计算 9 种图布局. 针对点特征、边特征和全局特征这 3 组指标, 该工作训练 3 个模型分别进行预测. 实验结果显示, 除节点遮挡和团体重叠 2 项指标外, 均达到 85% 以上的精确度. 进一步地, Kwon 等^[6]利用深度网络分解并生成好的图布局. 类似地, Wang 等^[31]提出的 DeepDrawing 方法, 使用基于 LSTM 的深度神经网络学习样例图布局, 对给定的图数据直接生成图布局. 该方法基于双向图 LSTM 模型. 该工作采用宽度优先的顺序将节点转换为序列. 图节点对应 LSTM 单元, 单元之间的连线对应节点的连接关系, 节点的特征为当前节点与前 k 个节点的相邻关系向量. DeepDrawing 采用基于普鲁克分析(Procrustes analysis)^[48]的损失函数, 计算经过平移、旋转、缩放等操作后, 模型输出的布局与基准布局之间的最大相似性. 作者们在一般图布局、基于格点的图布局和星形图布局的数据上进行实验, 发现 DeepDrawing 可以预测和基准相似的布局. 在这一系列的已有工作中, 深度学习技术有效地对于图可视化技术进行了更加精细可靠的特征编码, 获得了可靠的评估结果, 并进一步据此生成更加具体的可视化应用.

基于深度学习的可视化结果评估方法能够发挥当下数据驱动的模式优势, 有效地拆解并整合不同用户评价数据中的蕴藏的评价和偏好规则, 隐式地训练出一套符合感知的评价模型. 例如, 散点图的相似性计算在散点图查询、子空间选择等方面具有重要作用. 传统方法依靠手动定义相似性的各类特征, 其结果有时不符合人的感知. Ma 等^[32]提出深度度量模型 ScatterNet, 学习用户的主观感知, 其任务生成流程如图 5 所示. 在训练数据收集方面, 该方法使用真实数据生成散点图, 在不同特征空间对其进行采样, 生成待标注的散点图集合. 对每个散点图集合, 标注者分别选取与锚点散点

图最相似和最不相似的 5 张散点图. 模型使用 CNN 提取图片特征向量, 训练时最大化锚点散点图与相似散点图、相异散点图在特征空间的距离. 散点图经过卷积模型后在特征空间的欧几里得度量, 即为散点图的相似性. 该方法计算效率高, 用户实验结果显著好于传统方法. 基于用户数据的深度学习评估方法同样可以应用于科学数据可视化中的体绘制参数选择问题. Yang 等^[33]提出了一种针对真实用户的视角的偏好数据, 训练深度学习模型对于不同视角下可视化结果的评估, 进而进行体数据可视化视角推荐方法. 视角对于指导用户理解体数据至关重要, 该工作能够灵活地实现基于用户偏好进行定制化的体数据可视化最佳视角推荐. 该工作采用的模型基于 CNN, 采用残差和多尺度层次结构来缓解过拟合和精度的问题, 模拟人类的感知方式. 该工作在球面均匀采样观察点, 并指向体数据中心得到一系列视角. 将不同视角下的体渲染结果输入神经网络得到视角优劣评估, 并选择前若干个局部最优值作为推荐视角. 经

过大量精细设计的实验和基于一个真实用户数据案例的验证, 该工作提出的方法十分有效. 类似地, Shi 等^[34]同样采用深度学习技术分析领域专家在其发表的文献中如何进行体数据可视化视角选择. 深度学习对于这一类用户的评估或偏好数据具有更强的适应性, 更加容易获得启发性的见解, 进而提炼出评估的准则.

综上, 基于深度学习驱动的可视化结果评估方法具有两方面巨大的优越性, 数量丰富的已有工作验证了引入深度学习的有效性和可靠性, 深度学习已经成为该可视化数据研究环节中的有力的技术支持.




图 4 可视化自动评估工作流程^[28]

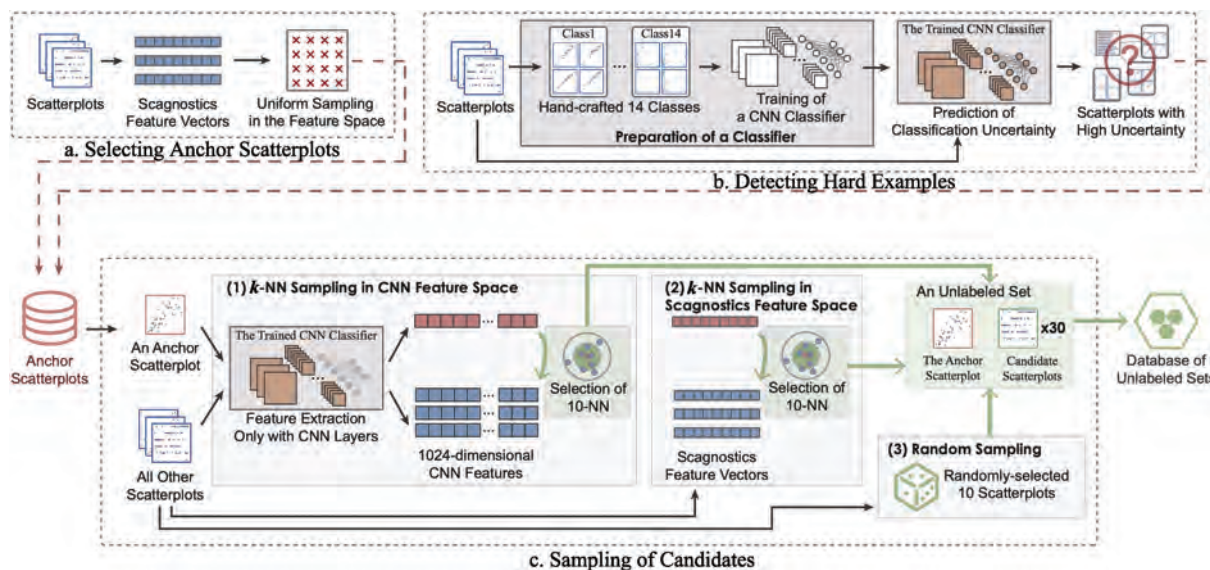


图 5 散点图相似性度量方法任务生成流程^[32]

6 深度学习驱动的可视化的分析与探讨

本文收集归纳了近年来相关的文章, 以可视化的流程为脉络进行归纳整理. 除了以可视化的流程为依据进行讨论, 本文也对收集的在工作中使用的深度学习网络、深度学习框架进行了整理. 表 2 所示是可视化流程中使用的网络类型. 大部分工作集中在 CNN 中. 这是由于 CNN 适用面广, 适合二维、三维数据, 包含了可视化中常见的二维图像等数据格式. 而在涉及时序数据^[4]或者数据格式为序列^[14], 循环

神经网络也会被使用. 此外, 随着近年来人们对 GNN 的研究兴趣提升, 图可视化中的研究热点如图布局的研究等方向也得到了新技术的支持^[31].

表 3 归纳了不同流程和模型框架的关系. 单一的神经网络其模式较为固定, 深度学习中往往采用复杂的框架, 以实现性能的提升. 如采用编码-解码(encoder-decoder)框架或者 GAN 以提升其性能. 编码-解码结构往往可以拼合 2 个模型, 以实现输入输出的定制. 其连接 2 个组件的中间向量也可用于降维以展现数据的特征, 而 GAN 相较

表 2 可视化流程中使用的网络类型

可视化流程	传统机器学习	全连接	RNN	CNN	GNN
快速构建		VizML ^[13]	Data2Vis ^[14]	Chen 等 ^[15] , Text-to-Viz ^[16]	
压缩表征		NNVA ^[2]	TSR-TVD ^[4] , Hong 等 ^[11]	InSituNet ^[1] , Berger 等 ^[3] , TSR-TVD ^[4] , GenerativeMap ^[5] , DeepOrganNet ^[7] , DNN-VolVis ^[8] , Cheng 等 ^[9] , Xu 等 ^[10] , Han 等 ^[12]	Kwon 等 ^[6]
智能交互				LassoNet ^[17] , FlowNet ^[18] , Porter 等 ^[19] , Lai 等 ^[23] , Quan 等 ^[25] , AutoCaption ^[24] , Deng 等 ^[26] , Kim 等 ^[27]	
结果评估	Fu 等 ^[28] , Kwon 等 ^[29]		DeepDrawing ^[31]	Hammad 等 ^[30] , ScatterNet ^[32] , Yang 等 ^[33] , Shi 等 ^[34]	Kwon 等 ^[6]

表 3 可视化流程中使用的模型框架

可视化流程	无框架	encoder-decoder	GAN
快速构建	VizML ^[13] , Chen 等 ^[15] , Text-to-Viz ^[16]	Data2Vis ^[14]	
压缩表征	NNVA ^[2] , DeepOrganNet ^[7] , Cheng 等 ^[9] , Xu 等 ^[10] , Hong 等 ^[11] , Han 等 ^[12]	GenerativeMap ^[5] , Kwon 等 ^[6]	InSituNet ^[1] , Berger 等 ^[3] , TSR-TVD ^[4] , GenerativeMap ^[5] , DNN-VolVis ^[8]
智能交互	LassoNet ^[17] , Lai 等 ^[23] , Quan 等 ^[25] , Deng 等 ^[26] , Kim 等 ^[27]	FlowNet ^[18] , Porter 等 ^[19]	AutoCaption ^[24]
结果评估	Kwon 等 ^[29] , Hammad 等 ^[30] , DeepDrawing ^[31] , ScatterNet ^[32] , Yang 等 ^[33] , Shi 等 ^[34]	Kwon 等 ^[6] , Fu 等 ^[28]	

于单一的神经网络可以提升性能。在未来的发展趋势中, 随深度学习支持的可视化流程愈加定制化, 深度模型框架将更多地运用于可视化流程中, 以支持更为复杂的操作。

7 前景与展望

本文主要从深度神经网络在可视化与可视分析的各个流程展开了调研与分析。介绍了深度学习方法在可视化的构建中的研究、深度学习网络模型在可视化的压缩与特征表达的相关应用。

在获取了可视化之后, 本文展开了深度神经网络支持的可视化交互以及可视化结果评估。此外, 自然语言和可视化相关也随着深度网络的能力而开始有一些突破, 因此也对此展开介绍。

从近年的相关工作可以看出, 深度学习驱动了可视化与可视分析流程的高效化与智能化。可视化与可视分析的效率将大大加速。深度学习网络展现了其在可视化与可视分析中的各个阶段的能力与巨大潜力。

在深度神经网络的训练使用过程中, 一些深度模型中固有的问题包括如何收集数据、如何保证

训练模型的准确性, 也同样会出现在深度模型支持的可视化问题中。而可视化中数据集的缺乏及对训练结果的高准确性要求, 使得它们成为更加亟待解决的问题。在深度模型驱动的可视化中构建高质量的数据集和有效的评估方案也是重要的待解决问题。

有赖于深度神经网络的强大的泛化能力, 其在可视化中各个流程均得到了广泛的关注。可视化工作对深度神经网络的理解也在不断加深, 深度神经网络不断地深入融合进可视化方法。而随着深度学习支撑的可视化方向的发展, 更加贴合可视化实际需求、更加能发挥神经网络的优点的新方法将会是未来的发展方向。立足于可视化需求与发展同时, 研发出新型的深度网络而非仅仅将神经网络模型作为模块化的工具, 能够真正推动 2 个领域的进步。

参考文献(References):

- [1] He W B, Wang J P, Guo H Q, *et al.* InSituNet: deep image synthesis for parameter space exploration of ensemble simulations[J]. IEEE Transactions on Visualization and Computer

- Graphics, 2020, 26(1): 23-33
- [2] Hazarika S, Li H Y, Wang K C, *et al.* NNVA: neural network assisted visual analysis of yeast cell polarization simulation[J]. IEEE Transactions on Visualization and Computer Graphics, 2020, 26(1): 34-44
- [3] Berger M, Li J X, Levine J A. A generative model for volume rendering[J]. IEEE Transactions on Visualization and Computer Graphics, 2019, 25(4): 1636-1650
- [4] Han J, Wang C L. TSR-TVD: temporal super-resolution for time-varying data analysis and visualization[J]. IEEE Transactions on Visualization and Computer Graphics, 2020, 26(1): 205-215
- [5] Chen C, Wang C B, Bai X, *et al.* GenerativeMap: visualization and exploration of dynamic density maps via generative learning model[J]. IEEE Transactions on Visualization and Computer Graphics, 2020, 26(1): 216-226
- [6] Kwon O H, Ma K L. A deep generative model for graph layout[J]. IEEE Transactions on Visualization and Computer Graphics, 2020, 26(1): 665-675
- [7] Wang Y F, Zhong Z C, Hua J. DeepOrganNet: on-the-fly reconstruction and visualization of 3D/4D lung models from single-view projections by deep deformation network[J]. IEEE Transactions on Visualization and Computer Graphics, 2020, 26(1): 960-970
- [8] Hong F, Liu C, Yuan X R. DNN-VolVis: interactive volume visualization supported by deep neural network[C] //Proceedings of the IEEE Pacific Visualization Symposium. Los Alamitos: IEEE Computer Society Press, 2019: 282-291
- [9] Cheng H C, Cardone A, Jain S, *et al.* Deep-learning-assisted volume visualization[J]. IEEE Transactions on Visualization and Computer Graphics, 2018, 25(2): 1378-1391
- [10] Xu X J, Liu C, Zheng Y Y. 3D tooth segmentation and labeling using deep convolutional neural networks[J]. IEEE Transactions on Visualization and Computer Graphics, 2019, 25(7): 2336-2348
- [11] Hong F, Zhang J, Yuan X R. Access pattern learning with long short-term memory for parallel particle tracing[C] //Proceedings of the IEEE Pacific Visualization Symposium. Los Alamitos: IEEE Computer Society Press, 2018: 76-85
- [12] Han J, Tao J, Zheng H, *et al.* Flow field reduction via reconstructing vector data from 3-D streamlines using deep learning[J]. IEEE Computer Graphics and Applications, 2019, 39(4): 54-67
- [13] Hu K Z, Bakker M A, Li S, *et al.* VizML: a machine learning approach to visualization recommendation[C] //Proceedings of the CHI Conference on Human Factors in Computing Systems. New York: ACM Press, 2019: Article No.128
- [14] Dibia V, Demiralp C. Data2Vis: automatic generation of data visualizations using sequence-to-sequence recurrent neural networks[J]. IEEE Computer Graphics and Applications, 2019, 39(5): 33-46
- [15] Chen Z T, Wang Y, Wang Q W, *et al.* Towards automated infographic design: deep learning-based auto-generation of extensible timeline[J]. IEEE Transactions on Visualization and Computer Graphics, 2020, 26(1): 917-926
- [16] Cui W W, Zhang X Y, Wang Y, *et al.* Text-to-Viz: automatic generation of infographics from natural language statements[J]. IEEE Transactions on Visualization and Computer Graphics, 2020, 26(1): 906-916
- [17] Chen Z, Zeng W, Yang Z, *et al.* LassoNet: deep Lasso-selection of 3D point clouds[J]. IEEE Transactions on Visualization and Computer Graphics, 2020, 26(1): 195-204
- [18] Han J, Tao J, Wang C L. FlowNet: a deep learning framework for clustering and selection of streamlines and stream surfaces[J]. IEEE Transactions on Visualization and Computer Graphics, 2020, 26(4): 1732-1744
- [19] Porter W P, Xing Y H, von Ohlen B R, *et al.* A deep learning approach to selecting representative time steps for time-varying multivariate data[C] //Proceedings of the IEEE Visualization Conference. Los Alamitos: IEEE Computer Society Press, 2020: 131-135
- [20] Yu B, Silva C T. FlowSense: a natural language interface for visual data exploration within a dataflow system[J]. IEEE Transactions on Visualization and Computer Graphics, 2019, 26(1): 1-11
- [21] Fast E, Chen B B, Mendelsohn J, *et al.* Iris: a conversational agent for complex tasks[C] //Proceedings of ACM Conference on Human Factors in Computing Systems. New York: ACM Press, 2018: Article No.473
- [22] Srinivasan A, Stasko J. Orko: facilitating multimodal interaction for visual exploration and analysis of networks[J]. IEEE Transactions on Visualization and Computer Graphics, 2018, 24(1): 511-521
- [23] Lai C F, Lin Z X, Jiang R K, *et al.* Automatic annotation synchronizing with textual description for visualization[C] //Proceedings of the CHI Conference on Human Factors in Computing Systems. New York: ACM Press, 2020: Article No.316
- [24] Liu C, Xie L, Han Y, *et al.* AutoCaption: an approach to generate natural language description from visualization automatically[C] //Proceedings of the IEEE Pacific Visualization Symposium. Los Alamitos: IEEE Computer Society Press, 2020: 191-195
- [25] Quan T M, Choi J, Jeong H, *et al.* An intelligent system approach for probabilistic volume rendering using hierarchical 3D convolutional sparse coding[J]. IEEE Transactions on Visualization and Computer Graphics, 2018, 24(1): 964-973
- [26] Deng L, Wang Y Q, Liu Y, *et al.* A CNN-based vortex identification method[J]. Journal of Visualization, 2019, 22(1): 65-78
- [27] Kim B, Günther T. Robust reference frame extraction from unsteady 2D vector fields with convolutional neural networks[J]. Computer Graphics Forum, 2019, 38(3): 285-295
- [28] Fu X, Wang Y, Dong H Y, *et al.* Visualization assessment: a machine learning approach[C] //Proceedings of the IEEE Visualization Conference. Los Alamitos: IEEE Computer Society Press, 2019: 126-130
- [29] Kwon O H, Crnovrsanin T, Ma K L. What would a graph look like in this layout? a machine learning approach to large graph visualization[J]. IEEE Transactions on Visualization and Com-

- puter Graphics, 2017, 24(1): 478-488
- [30] Haleem H, Wang Y, Puri A, *et al.* Evaluating the readability of force directed graph layouts: a deep learning approach[J]. IEEE Computer Graphics and Applications, 2019, 39(4): 40-53
- [31] Wang Y, Jin Z H, Wang Q W, *et al.* DeepDrawing: a deep learning approach to graph drawing[J]. IEEE Transactions on Visualization and Computer Graphics, 2020, 26(1): 676-686
- [32] Ma Y X, Tung A K H, Wang W, *et al.* ScatterNet: a deep subjective similarity model for visual analysis of scatterplots[J]. IEEE Transactions on Visualization and Computer Graphics, 2020, 26(3): 1562-1576
- [33] Yang C H, Li Y D, Liu C, *et al.* Deep learning-based viewpoint recommendation in volume visualization[J]. Journal of Visualization, 2019, 22(5): 991-1003
- [34] Shi N, Tao Y B. CNNs based viewpoint estimation for volume visualization[J]. ACM Transactions on Intelligent Systems and Technology, 2019, 10(3): Article No.27
- [35] Goodfellow I J, Pouget-Abadie J, Mirza M, *et al.* Generative adversarial nets[C] //Proceedings of the 27th International Conference on Neural Information Processing Systems. New York: Curran Associates, 2014, 2: 2672-2680
- [36] Donahue J, Krahenbuhl P, Darrell T. Adversarial feature learning[OL]. [2020-07-14]. <https://arxiv.org/abs/1605.09782>
- [37] He K M, Zhang X Y, Ren S Q, *et al.* Sun J. Deep residual learning for image recognition[C] //Proceedings of Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2016: 770-778
- [38] Howard A G, Zhu M L, Chen B, *et al.* MobileNets: efficient convolutional neural networks for mobile vision applications[OL]. [2020-07-14]. <https://arxiv.org/abs/1704.04861>
- [39] Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780
- [40] Zhang J, Guo H Q, Yuan X R. Efficient unsteady flow visualization with high-order access dependencies[C] //Proceedings of the IEEE Pacific Visualization Symposium. Los Alamitos: IEEE Computer Society Press, 2016: 80-87
- [41] Satyanarayan A, Moritz D, Wongsuphasawat K, *et al.* Vega-Lite: a grammar of interactive graphics[J]. IEEE Transactions on Visualization and Computer Graphics, 2017, 23(1): 341-350
- [42] Xie S N, Girshick R, Dollár P, *et al.* Aggregated residual transformations for deep neural networks[C] //Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2017: 5987-5995
- [43] Rother C, Kolmogorov V, Blake A. GrabCut: interactive foreground extraction using iterated graph cuts[J]. ACM Transactions on Graphics, 2004, 23(3): 309-314
- [44] Qi C R, Su H, Mo K, *et al.* PointNet: deep learning on point sets for 3D classification and segmentation[C] //Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2017: 652-660
- [45] van der Maaten L, Hinton G. Visualizing data using *t*-SNE[J]. Journal of Machine Learning Research, 2008, 9(11): 2579-2605
- [46] Ester M, Kriegel H, Sander J, *et al.* A density-based algorithm for discovering clusters in large spatial databases with noise[C] //Proceedings of International Conference on Knowledge Discovery and Data Mining. Palo Alto: AAAI Press, 1996: 226-231
- [47] Manning C D, Surdeanu M, Bauer J, *et al.* The Stanford CoreNLP natural language processing toolkit[C] //Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics: System Demonstrations. Stroudsburg: ACL Press, 2014: 55-60
- [48] Gower J C. Generalized Procrustes analysis[J]. Psychometrika, 1975, 40(1): 33-51