(19)国家知识产权局

(12)发明专利申请

(10)申请公布号 CN 117592576 A
(43)申请公布日 2024.02.23

(21)申请号 202311042214.0
(22)申请日 2023.08.17
(30)优先权数据
22306233.2 2022.08.17 EP
(71)申请人 达索系统公司
地址 法国韦利济—维拉库布莱
(72)发明人 M·梅兹格汉尼 J·布歇
R·萨巴捷
(74)专利代理机构 北京博思佳知识产权代理有限公司 11415
专利代理师 韩果
(51)Int.Cl.
G06N 20/00(2019.01)
G06N 3/0464(2023.01)
G06N 3/0895(2023.01)
G06F 30/27(2020.01)

权利要求书2页 说明书13页 附图8页

(54)发明名称

用于机器学习的方法、神经网络、计算机程序、存储介质

(57)摘要

本公开尤其涉及一种计算机实现的用于机器学习的方法。所述方法包括获得B-rep图的训练数据集。每个B-rep图表示相应B-rep。每个B-rep图包括图节点,每个图节点表示相应B-rep的边、面或共边,并且与一个或多个几何和/或拓扑特征相关联。每个B-rep图包括图边,每个图边在表示相应共边的相应第一图节点和表示与相应共边相关联的面、边、相邻共边或匹配共边的相应第二图节点之间。所述方法还包括基于训练数据集学习深度CAD神经网络。深度CAD神经网络被配置为将B-rep图作为输入,并输出由输入B-rep图表示的B-rep的拓扑签名。

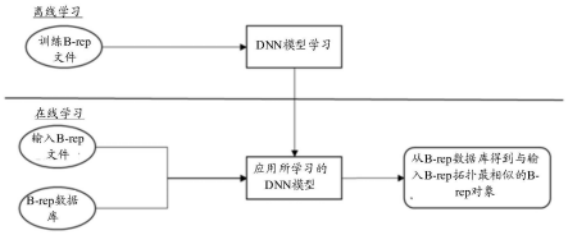

CN 117592576 A

1.一种计算机实现的机器学习的方法,所述方法包括:

获得B-rep图的训练数据集,每个B-rep图表示相应B-rep并且包括:

图节点,每个图节点表示所述相应B-rep的边、面或共边,并且与一个或多个几何和/或拓扑特征相关联;以及

图边,每个图边在表示相应共边的相应第一图节点和表示与所述相应共边相关联的面、边、相邻共边或匹配共边的相应第二图节点之间;以及

基于所述训练数据集学习深度CAD神经网络,所述深度CAD神经元网络被配置为将B-rep图作为输入并且输出由所述输入B-rep图表示的所述B-rep的拓扑签名。

2.根据权利要求1所述的方法,其中,所述深度CAD神经网络包括卷积单元,所述卷积单元被配置为执行内核级联,所述内核级联根据所述神经网络的内核将每个共边的特征向量与其相邻B-rep要素的特征向量级联。

3.根据权利要求2所述的方法,其中,所述卷积单元还被配置为,将由所述内核级联得到的共边的每个级联特征向量作为输入传递到密集神经网络。

4.根据权利要求3所述的方法,其中,所述卷积单元还被配置为,对于由所述密集神经网络针对共边的输入级联特征向量输出的每个向量,计算新边特征向量、新面特征向量和新共边特征向量。

5.根据权利要求4所述的方法,其中,所述密集神经网络对于由所述内核级联得到的共边c的输入级联特征向量$\varphi_c^{(i)}$输出:

$$\psi_c^{(i)} = MLP\left(\phi_c{}^{(i)}\right) = \left[\psi_{CC}^{(i)} \middle| \psi_{CF}^{(i)} \middle| \psi_{CE}^{(i)}\right],$$

其中,$\psi_{CC}^{(i)}$, $\psi_{CF}^{(i)}$, $\psi_{CE}^{(i)}$具有相同的维度h,使得$\psi_c^{(i)}$的维度为3*h,以及对于每个共边c、每个面F和每个边E,所述新特征向量是,

$$\begin{cases} X_c^{(i+1)} = \psi_{CC}^{(i)} \\ X_E^{(i+1)} = MaxPool(\psi_{CE1}^{(i)}, \psi_{CE2}^{(i)}) \\ X_F^{(i+1)} = MaxPool(\psi_{CF1}^{(i)}, \ldots, \psi_{CFk}^{(i)}) \end{cases}$$

其中:

- $X_c^{(i+1)}$是所述密集神经网络对于共边c的输出$\psi_c^{(i)}$计算得到的新共边特征;
- $X_E^{(i+1)}$是对于边E计算得到的新边特征,其中,$\psi_{CE1}^{(i)}$和$\psi_{CE2}^{(i)}$对应于其两个相关联的共边的特征向量;
- $X_F^{(i+1)}$是对于面F计算得到的新面特征,其中,$\psi_{CF1}^{(i)}, \ldots, \psi_{CFk}^{(i)}$对应于其k相关联的共边的特征。

6.根据权利要求2或5所述的方法,其中,所述深度CAD神经网络被配置为重复应用所述卷积单元预定次数。

7.根据权利要求2至6中任一项所述的方法,其中,所述深度CAD神经网络还被配置为通过执行面特征向量的聚合来计算全局特征向量,所述聚合基于最大池化方法或注意力机制方法。

8.根据权利要求7所述的方法,其中,所述深度CAD神经网络的学习包括执行对比学习以训练所述深度CAD神经网络来计算全局特征向量的拓扑签名。

9.根据权利要求8所述的方法,其中,所述对比学习基于正变换,所述正变换包括:

-身份转换,

-将随机几何体分配给具有概率的边,

-将随机几何体分配给具有概率的面,

-将具有零的面的特征向量替换为概率p,以及

-删除具有概率p的边,如果该删除将使得面与所述输入B-rep图断开连接,则不进行此删除。

10.根据权利要求8或9所述的方法,其中,所述对比学习包括最小化基于余弦相似性的归一化温度标度交叉熵损失,所述损失为以下类型:

$$L(i,j) = -\log \frac{e^{sim(Z_i,Z_j)}}{\sum_{k=1}^{2N} 1_{[k\neq i]}\, e^{sim(Z_i,Z_k)}},$$

其中,(i,j)表示正对,(Z_i,Z_j)表示所述深度CAD神经网络对所述正对的嵌入,其中,sim是由以下公式定义的余弦相似性:

$$sim(x,y) = \frac{x.y}{\|x\|\|y\|} = \frac{\sum_{i=1}^{h} x_i y_i}{\sqrt{\sum_{i=1}^{h} x_i^2}\sqrt{\sum_{i=1}^{h} y_i^2}},$$

对于$x, y \in \mathbb{R}^h$。

11.一种能够根据权利要求1至10中任一项所述方法学习的神经网络。

12.一种根据权利要求11所述的神经网络的使用方法,所述使用方法包括:

获得表示B-rep的B-rep图;

将所述神经网络应用于所述B-rep图,从而获得所述B-rep的拓扑签名。

13.一种包括指令的计算机程序,所述指令当在计算机上执行时使所述计算机执行权利要求1至10中任一项的方法和/或权利要求12的方法。

14.一种计算机可读数据存储介质,其上记录有权利要求13的计算机程序和/或权利要求11的神经网络。

15.一种计算机系统,包括耦合到存储器的处理器,所述存储器上记录有权利要求13的计算机程序和/或权利要求11的神经网络。

用于机器学习的方法、神经网络、计算机程序、存储介质

技术领域

[0001] 本公开涉及计算机程序和系统领域,更具体地涉及机器学习的方法、系统和程序。

背景技术

[0002] 市场上提供了许多用于对象的设计、工程化和制造的系统和程序。CAD是计算机辅助设计的缩写,例如,其涉及用于设计对象的软件解决方案。CAE是计算机辅助工程化的缩写,例如,其涉及模拟未来产品的物理行为的软件解决方案。CAM是计算机辅助制造的缩写,例如,其涉及用于定义制造工艺和操作的软件解决方案。在这种计算机辅助设计系统中,图形用户界面在技术效率方面起着重要作用。这些技术可嵌入到产品生命周期管理(PLM)系统中。PLM指的是一种商业战略,其帮助公司共享产品数据,应用通用流程,并利用公司知识开发产品,从概念到其生命周期结束,跨越扩展企业的概念。Dassault Systèmes提供的PLM解决方案(商标为CATIA、ENOVIA和DELMIA)提供了:工程中心,用于组织产品工程化知识;制造中心,用于管理制造工程化知识;以及企业中心,用于实现企业整合并连接到工程和制造中心。总之,该系统提供了连接产品、工艺和资源的开放对象模型,以实现动态的、基于知识的产品创建和决策支持,从而推动优化的产品定义、制造准备、生产和服务。

[0003] 在这种情况和其他情况下,需要改进CAD对象检索和CAD对象之间相似性评估的解决方案。

发明内容

[0004] 因此,提供了一种计算机实现的用于机器学习的方法。所述方法包括:获得B-rep图的训练数据集。每个B-rep图表示相应B-rep。每个B-rep图包括图节点,每个图节点表示所述相应B-rep的边、面或共边并且与一个或多个几何和/或拓扑特征相关联。每个B-rep图包括图边,每个图边在表示相应共边的相应第一图节点和表示与相应共边相关联的面、边、相邻共边或匹配共边的相应第二图节点之间。所述方法还包括:基于所述训练数据集学习深度CAD神经网络。所述深度CAD神经元网络被配置为将B-rep图作为输入并且输出由所述输入B-rep图表示的所述B-rep的拓扑签名。

[0005] 所述方法可包括以下中的一个或多个:

[0006] -所述深度CAD神经网络包括卷积单元,所述卷积单元被配置为执行内核级联,所述内核级联根据所述神经网络的内核将每个共边的特征向量与其相邻B-rep要素的特征向量级联;

[0007] -所述卷积单元还被配置为将由所述内核级联得到的共边的每个级联特征向量作为输入传递到密集神经网络;

[0008] -所述卷积单元还被配置为,对于由所述密集神经网络针对共边的输入级联特征向量输出的每个向量,计算新边特征向量、新面特征向量和新共边特征向量;

[0009] -所述密集神经网络对于由所述内核级联得到的共边c的输入级联特征向量 $\varphi_c^{(i)}$ 输出:

[0010] $$\psi_c^{(i)} = MLP\left(\phi_c{}^{(i)}\right) = \left[\psi_{CC}^{(i)} \middle| \psi_{CF}^{(i)} \middle| \psi_{CE}^{(i)}\right],$$

[0011] 其中,$\psi_{CC}^{(i)}$, $\psi_{CF}^{(i)}$, $\psi_{CE}^{(i)}$具有相同的维度h,使得$\psi_c^{(i)}$的维度为3*h,

[0012] 以及对于每个共边c、每个面F和每个边E,所述新特征向量是,

[0013] $$\begin{cases} X_c^{(i+1)} = \psi_{CC}^{(i)} \\ X_E^{(i+1)} = MaxPool\left(\psi_{CE1}^{(i)}, \psi_{CE2}^{(i)}\right) \\ X_F^{(i+1)} = MaxPool\left(\psi_{CF1}^{(i)}, \ldots, \psi_{CFk}^{(i)}\right) \end{cases}$$

[0014] 其中:

[0015] o$X_c^{(i+1)}$是密集神经网络对于共边c的输出$\psi_c^{(i)}$计算得到的新共边特征;

[0016] o$X_E^{(i+1)}$是对于边E计算得到的新边特征,其中,$\psi_{CE1}^{(i)}$和$\psi_{CE2}^{(i)}$对应于其两个相关联的共边的特征向量;

[0017] o$X_F^{(i+1)}$是对于面F计算得到的新面特征,其中,$\psi_{CF1}^{(i)}, \ldots, \psi_{CFk}^{(i)}$

[0018] 对应于其k相关联的共边的特征;

[0019] -所述深度CAD神经网络被配置为重复应用所述卷积单元预定次数;

[0020] -所述深度CAD神经网络还被配置为通过执行面特征向量的聚合来计算全局特征向量,所述聚合基于最大池化方法或注意力机制方法;

[0021] -所述深度CAD神经网络的学习包括执行对比学习以训练所述深度CAD神经网络来计算全局特征向量的拓扑签名;

[0022] -所述对比学习基于正变换,所述正变换包括:

[0023] o身份转换,

[0024] o将随机几何体分配给具有概率的边,

[0025] o将随机几何体分配给具有概率的面,

[0026] o将具有零的面的特征向量替换为概率p,以及

[0027] o删除具有概率p的边,如果该删除将使得面与所述输入B-rep图断开连接,则不进行此删除;和/或

[0028] -所述对比学习包括最小化基于余弦相似性的归一化温度标度交叉熵损失,所述损失为以下类型:

[0029] $$L(i,j) = -\log \frac{e^{sim(Z_i,Z_j)}}{\sum_{k=1}^{2N} 1_{[k\neq i]}\, e^{sim(Z_i,Z_k)}},$$

[0030] 其中,(i,j)表示正对,(Z_i,Z_j)表示所述深度CAD神经网络对所述正对的嵌入,其中,sim是由以下公式定义的余弦相似性:

[0031] $$sim(x,y) = \frac{x.y}{\|x\|\|y\|} = \frac{\sum_{i=1}^{h} x_i y_i}{\sqrt{\sum_{i=1}^{h} x_i^2}\sqrt{\sum_{i=1}^{h} y_i^2}},$$

[0032] 对于$x, y \in \mathbb{R}^h$。

[0033] 还提供了一种可根据所述方法学习的神经网络,即具有通过所述方法学习到的神经网络的权重的计算机实现的神经网络数据结构。所提供的神经网络例如可通过所述方法直接学习,其权重已经通过所述方法的学习步骤固定。

[0034] 还提供了一种神经网络的使用方法。所述使用方法包括获得表示B-rep的B-rep图。所述使用方法还包括将神经网络应用于B-rep图,从而获得B-rep的拓扑签名。

[0035] 还提供了一种包括用于执行所述方法和/或所述使用方法的指令的计算机程序。

[0036] 还提供了一种计算机可读存储介质,其上记录有计算机程序和/或神经网络。

[0037] 还提供了一种计算机系统,包括耦合到存储器的处理器,所述存储器上记录有计算机程序和/或神经网络。

附图说明

[0038] 现在将参考附图来描述非限制性示例,其中:

[0039] -图1至图13示出了这些方法;

[0040] -图14示出了该系统的示例。

具体实施方式

[0041] 提出了一种计算机实现的机器学习方法。该方法包括获得边界表示(B-rep)图的训练数据集。每个B-rep图表示各自的B-rep。每个B-rep图包括图节点,每个图节点表示相应B-rep的边、面或共边,并且与一个或多个几何和/或拓扑特征相关联。每个B-rep图包括图边,每个图边处于表示相应共边的相应第一图节点与表示与相应共边相关联的面、边、相邻共边或匹配共边的相应第二图节点之间。该方法还包括:基于训练数据集,学习深度CAD神经网络。深度CAD神经网络被配置为将B-rep图作为输入,并输出由输入的B-rep图表示的B-rep的拓扑签名。这种方法可称为“学习方法”。

[0042] 该学习方法形成了用于CAD对象检索的改进解决方案。

[0043] 值得注意的是,该学习方法学习深度CAD神经网络,该神经网络被配置为将B-rep图作为输入,该B-rep图是捕获产品的B-rep模型(即边界表示模型)的拓扑的图,并且计算B-rep的拓扑签名。B-rep的拓扑签名是由深度CAD神经网络输出的向量,以进一步通过神经网络的层处理输入的B-rep图,并由此形成输入的B-rep图的向量表示。现在,这样的向量是通过深度CAD神经网络的层处理输入的B-rep图来获得的。这样的图表示B-rep的几何形状和拓扑,因为其包括表示B-rep的要素(边、面、共边)的图节点和表示由边连接的节点表示的要素之间的拓扑关系的图边。该图还包括底层B-rep的拓扑和/或几何特征,即封装拓扑和/或者几何信息的特征向量。换句话说,输入的B-rep图是描述B-rep的几何形状和拓扑的数据结构,并且通过该方法学习的神经网络将该图作为输入并从中提取B-rep拓扑签名(因为网络被训练/学习这样做)。换句话说,该学习方法学习被配置为将B-rep图编码为捕获其拓扑的B-rep的紧凑拓扑特征向量的神经网络。

[0044] 该学习方法由此可被用于CAD对象检索或CAD对象之间的相似性评估,或者更一般地用于通过使用CAD对象的拓扑签名来操纵CAD对象。换句话说,所学习的深度CAD神经网络可被用于此类任务。实际上,CAD模型或对象是由特征树表示的基于特征的对象,可从该特征树生成模型的B-rep表示(即,通过执行特征树)。训练神经网络以找到这种CAD模型的拓

扑签名(即,特别是其B-rep图),因此允许通过使用其签名来操纵CAD模型。神经网络例如可被用于找到两个CAD模型的签名,以便对它们进行比较并评估它们之间的拓扑相似性。例如,这可被用于在已经包括数据库的CAD模型的拓扑签名的CAD模型数据库中搜索CAD模型:对于给定的感兴趣的CAD模型,所学习的神经网络可被用于提取CAD模型的拓扑签名并基于该签名查询数据库。这允许检索具有与给定CAD模型的拓扑签名最接近的拓扑签名的数据库的CAD模型。这种检索可在CAD模型设计(即,代表制造产品的CAD模型的设计,其可在该方法的下游制造)期间使用,以将一个CAD模型快速替换为拓扑相似的CAD模型,因为使用签名允许数据库的快速查询,因此允许相似CAD模型的快速高效检索。拓扑签名实际上是CAD模型的表示,在使用/操作期间,在内存需求(存储、内存占用)和CPU资源方面,其成本低于相应的B-rep模型或图,这使得拓扑签名成为允许对CAD模型进行CPU高效和内存高效操作的计算机对象。例如,签名可以是相对较小维度(例如,64)的向量,同时由于输入B-rep图在拓扑上是准确的,因此仍然提供良好的性能。换句话说,该方法是一种用于找到给定B-rep的紧凑拓扑向量表示的机器学习方法,其在内存和CPU方面比B-rep本身更高效地操纵。

[0045] 因此,该学习方法提供了一种用于执行B-rep的高效和通用拓扑对象检索的框架。对象检索是指目标为找到有效和高效的相似性函数以对3D对象数据进行搜索、排序和聚类来获得相似性的任务。这是具有挑战性的,因为物体通常包括许多不同的几何形状、结构、拓扑和视觉外观特性以及不同的材料和功能特性。此外,根据目标任务,相似性的概念可以是领域特定的,其可以是局部的、全局的、拓扑的、几何的和/或函数的。拓扑检索是指基于拓扑信息相似性的对象检索。拓扑信息提供了顶点、边和面之间的关系。除了所述关系,拓扑信息还包括边和面的方向。

[0046] 此外,该方法基于深度学习模型,该模型处理B-rep模型,而不必将其转换为近似格式(例如,点云、网格)。该方法使用神经网络以从任何给定的B-rep模型中计算签名。该签名对输入B-rep模型的拓扑敏感,因此具有紧密拓扑的两个B-rep模块将具有紧密签名。

[0047] 此外,该方法提供:

[0048] -时间效率:该方法允许快速查询,

[0049] -内存空间效率:该方法允许通过计算B-rep模型的签名来进行CAD检索,并且签名对于内存空间要求是轻微的;

[0050] -数据驱动方法:该方法允许利用未标记的B-rep数据集进行学

[0051] 习;以及

[0052] -一种用于自动拓扑感知检索的B-rep图的深度学习方法。直接处理这种格式的优点是避免几何信息的任何损失(由于近似)或拓扑信息的丢弃。

[0053] 这种学习方法适用于机器学习。

[0054] 正如机器学习领域本身所知,神经网络对输入的处理包括对输入应用运算,所述运算由包括权重值在内的数据定义。因此,学习神经网络包括基于为这种学习配置的数据集来确定权重的值,这种数据集可被称为学习数据集或训练数据集。为此,数据集包括数据片段,每个数据片段形成各自的训练样本。训练样本表示学习后要使用神经网络的情况的多样性。本文中的任何训练数据集可包括高于1000、10000、100000或1000000的多个训练样本。在本公开的上下文中,通过“基于数据集学习神经网络”,意味着该数据集是神经网络的学习/训练数据集,基于该数据集设置权重的值(也称为“参数”)。

[0055] 在学习方法的上下文中,训练数据集是提供的B-rep图的数据集,现在对其进行讨论。在讨论提供数据集之前,现在讨论其中涉及的数据结构。

[0056] “B-rep”,也称为“BRep”,代表“边界表示”。在CAD应用中,B-rep是最常见的建模类型。B-rep是三维对象的数学精确表示。这种表达将实体定义为连接的表面要素的集合,这些要素定义内部点和外部点之间的边界。B-rep中有两种类型的信息:拓扑组件和这些组件的几何定义。拓扑组件包括定义三维对象表面的顶点、边和面以及它们之的连接。除了连接性,拓扑信息还包括边和面的取向,而几何信息通常由描述顶点、边和面(分别为点、曲线和曲面)的数学方程组成。

[0057] B-rep(即,边界表示)是机械部件的3D表示。具体而言,B-rep是描述表示机械部件的3D建模对象的持久数据表示。B-rep可以是在表示机械部件的3D建模对象的设计阶段期间执行的计算和/或一系列运算的结果。当表示建模对象时,显示在计算机屏幕上的机械部件的形状是(例如,镶嵌)B-rep。在示例中,B-rep表示模型对象的一部分。

[0058] B-Rep包括拓扑实体和几何实体。拓扑实体为:面、边和顶点。几何实体是三维对象:曲面、平面、曲线、直线、点。根据定义,面是曲面的有界部分,称为支撑曲面。边是曲线的有界部分,称为支撑曲线。顶点是三维空间中的一个点。它们之间的关系如下。曲线的有界部分由位于曲线上的两个点(顶点)定义。曲面的有界部分由其边界定义,该边界是位于曲面上的一组边。面的边的边界通过共享顶点来连接。面通过共享边连接。如果两个面共享一条边,则它们是相邻的。类似地,如果两条边共享一个顶点,则它们是相邻的。在CAD系统中,B-Rep在适当的数据结构中收集“约束”关系、拓扑实体和支撑几何形状之间的关系以及支撑几何形状的数学描述。B-Rep的内部边是正好由两个面共享的边。根据定义,边界边不是共享的,它只界定一个面。根据定义,边界面由至少一条边界边界定。如果B-Rep的所有边都是内部边,则称其为闭合的。如果B-Rep包括至少一个边界边,则称其为开放的。闭合B-Rep被用于对厚三维体积进行建模,因为其定义了空间(虚拟)包围材料的内部。开放B-Rep被用于对3D皮肤进行建模,其表示厚度足够小而可忽略的3D对象。

[0059] 与CAD建模中使用的任何其他表示类型相比,B-Rep的一个关键优势是其能够准确地表示任意形状。在使用中的所有其他表示,诸如点云、距离场和网格,都会对要通过离散化表示的形状执行近似。另一方面,B-Rep包含表示精确设计的曲面方程,因此构成了用于进一步制造的真正“主模型”,无论是为CNC生成刀具路径(toolpaths),还是离散为给定3D打印机技术的正确样本密度。换句话说,通过使用B-Rep,3D模型可以是制造对象的精确表示。B-Rep对于模拟3D模型的行为也是有利的。在应力、热、电磁或其他分析方面,它支持模拟网格的局部细化以捕捉物理现象,而在运动学方面,它则支持曲面之间的真实接触建模。最后,B-Rep允许占用较小的内存和/或文件空间。首先,因为表示包含仅基于参数的曲面。在网格等其他表示中,等效曲面包含多达数千个三角形。其次,因为B-Rep不包含任何基于历史的信息。

[0060] 除了顶点、面和边之外,本文中的每个B-rep还包括共边。共边是有取向的边,即B-rep的具有附加取向信息的边。共边由此定义了围绕B-rep面的排序和面邻接,即它们定义了B-rep的拓扑。共边将B-rep实体连接在一起。每个共边具有一个父面(即,它为其定义边界的面)、一个父边(即,根据定义,共边是有取向的边,因此具有父边)、一条匹配的共边(其为具有相同父边的共边)、一条下一个共边(对应于该共边所属的循环中的下一条共边)、以

及一个上一个共边(对应于该共边所属的循环中的前一条共边)。每个共边与其父面周围的下一个和上一个共边、相邻面上的配合共边、父面和父边保持邻接关系。图1示出了立方体的两个面(F:面,E:边,C:共边,N:下一个交互,M:配合交互,PF:父面,PE:父边)与其他实体的共边交互的示例。

[0061] 本文中的每个B-rep图是相应B-rep的图表示,并且包括图节点和图边。每个图节点表示相应B-rep的相应边、相应面或相应共边。这意味着,对于B-rep的每一条边,都有一个相应的图节点,对于B-rep的每一面,都有相应的图结点,对于B-rep的每一个共边,都有相应的图结点。每个图节点还包括与图节点相关联(即,附加到图节点)的几何和/或拓扑特征。所述特征是与节点相关联的数据,例如向量(也称为特征向量),并且描述表征由图节点表示的B-rep元素的几何数据和/或拓扑数据。下面的表1示出了根据该方法的示例,对于每个B-rep(边、共边或面),包括在附接到相应图节点的特征向量中的几何和/或拓扑要素的名称列表,并且对于每个几何和/或者拓扑要素,示出了该要素的描述。括号之间的数字表示相应向量的维度。

[0062]

实体	名称	描述
边(15)	几何类型(5)	一个热向量表示边的类型(线、圆、椭圆、B样条,相交曲线)
	闭环(1)	如果边的边界在其自身的面上,则布尔(Boolean)设置为真
	线长度(1)	线的长度(如果不是线,为0)
	圆半径(1)	圆边的半径(如果不是圆,为0)
	椭圆轴(2)	半长轴和半短轴椭圆轴(如果不是椭圆,为0)
	平面至平面凸面(3)	在两个平面之间的边的情况下,表示边为凹的还是凸的
	B样条度&控制点(2)	如果边为B样条,度和控制B样条的控制点的数量
共边(1)	方向标志(1)	表示共边是否具有其父边的相同取向
面(8)	几何的种类(5)	一个热向量表示面的类型(平面、球体、圆柱体、Thore、B样条)
	B样条度&控制点(3)	如果面是B样条,则度(在参数维度u和v)和控制点的数量

[0063]

[0064] 表1:几何和/或拓扑特征向量的示例

[0065] 表1所示的上述示例中的特征对于CAD模型的旋转和平移是不变的。图2示出了几何和拓扑特征的解纠缠,示出了在几何上非常相似,而在拓扑上非常不同的两个B-rep模型。

[0066] 所述图还包括图边。每个相应的图边连接两个相应的图节点,即相应的第一节点和相应的第二节点。第一图节点表示相应的共边。第二图节点表示以下各项之一:

[0067] -与相应共边相关联的面(即,共边的父面,即其定义边界的面),

[0068] -边(即,共边的父边),

[0069] -相邻的共边(即,下一个或上一个共边,即共边所属的环中的下一个或者上一个共边),或者

[0070] -匹配的共边(即,具有相同父边的共边)。

[0071] 获得训练数据集可包括创建训练数据集,即创建或生成B-rep图。创建/生成B-rep图可包括:

[0072] -获得(例如,从(例如,远程)存储器或服务器或B-rep数据库检索或下载)编码为B-rep文件(例如,已经设计的CAD模型)的B-rep,其可以是STEP文件;

[0073] -将B-rep文件转换(通过任何已知方法)为初始B-rep图,其

[0074] 中,图节点是B-rep的拓扑组件,边表示它们之间的交互;

[0075] -从B-rep文件提取几何参数并计算拓扑和/或几何特征;以及

[0076] -将所计算的特征整合到初始B-rep图,从而形成训练数据集的B-rep图形。

[0077] 可替换地,获得训练数据集可包括从(例如,远程)存储器、服务器或数据库检索或下载B-rep图。

[0078] 除了获得训练数据集之外,所述方法还包括基于训练数据集学习深度CAD神经网络。学习意味着所述方法将训练数据集的B-rep图作为神经网络的输入,并且只要神经网络没有输出足够令人满意的输出(例如,关于合适的收敛标准,例如,关于损失优化),就修改神经网络的权重。对于输入的B-rep图,神经网络的输出是由B-rep图表示的B-rep的拓扑签名。拓扑签名是神经网络为输入B-rep输出的嵌入向量,它捕获底层B-rep的拓扑。

[0079] 深度CAD神经网络是一种深度神经网络,也称为DNN。DNN是神经网络中一组强大的学习技术,它是一种受生物学启发的编程范式,使计算机能够从观测数据中学习。在对象识别中,DNN的成功归因于其学习丰富的中层介质表示的能力,而不是其他方法(min-cut、SVM、Boosting、Random Forest等)中使用的手工设计的底层特征(Zernike矩、HOG、Bag of Words、SIFT等)。更具体地,DNN专注于基于原始数据的端到端学习。换句话说,他们通过完成从原始特征开始到标签结束的端到端优化,尽可能地远离特征工程。DNN在以下参考文献中被讨论,D.E.Rumelhart,G.E.Hinton,R.J.Williams,“Learning internal representations by error propagation,Parallel distributed processing: explorations in the microstructure of cognition”,vol.1:foundations,MIT Press,Cambridge,MA,1986,其通过引用并入本文。

[0080] 深度CAD神经网络可具有经典图卷积网络的架构,例如,在以下参考文献中被讨论,T.N.Kipf and M.Welling,“Semi-Supervised Classification with Graph Convolutional Networks”,2016,其通过引用并入本文。这种架构特别适用,因为深度CAD神经网络的输入数据是图形。这种模型的标准目标是为图形的每个节点计算嵌入向量。这些模型通常基于消息传递:为了计算一个嵌入向量来描述图形的节点,每个节点都会从其邻域中收集先前的特征向量,并将其传递给深度学习网络。深度CAD神经网络架构可具体是以下通过引用并入本文的参考文献J.G.Lambourne,K.D.Willis,P.K.Jayaraman,A.Sanghi,P.Meltzer and H.Shayani,"BRepNet:A topological message passing system for solid models"CVPR 2021中提出的一种深度学习模型(如先前引用的参考文

献T.N.Kipf and M.Welling,“Semi-Supervised Classification with Graph Convolutional Networks”,2016中讨论的),其基于与经典图卷积网络相同原理,但具有基于共边的拓扑交互的消息传递。

[0081] 深度CAD神经网络可包括卷积单元,卷积单元是神经网络的发生消息传递的一层。卷积单元被配置为执行内核级联。核级联根据神经网络的内核将每个共边的特征向量与其相邻B-rep元素的特征向量级联。正如机器学习领域本身所知,内核是特定的路径(specified walk),神经网络根据该特定的路径将输入的特征级联,这些特征在这里是拓扑和/或几何特征。内核根据这个路径将每个共边的特征与其邻域的特征级联。内核路径可以是以下五个基本路径操作的组合:下一个共边、上一个共边、匹配的共边、父面和父边。图3示出了这些操作(PE:父边,PF:父面,N:下一个,P:上一个,M:匹配,C:共边,E:边,F:面)。最后两个路径操作是终结性的,因为它们最终出现在不是共边的实体上。内核可以是{I,N,P,M,PE,PF},即每个共边将其当前特征向量与下一个共边、上一个共边、匹配的共边、父边和父面的当前特征向量级联,从而产生以下级联的特征向量(对于每个共边c):

[0082] $$\phi_c^{(i)} = \left[X_c^{(i)} \middle| X_N^{(i)} \middle| X_P^{(i)} \middle| X_M^{(i)} \middle| X_{PE}^{(i)} \middle| X_{PF}^{(i)}\right]$$

[0083] 其中,$X_k^{(i)}$是实体k在步骤i处的特征向量。

[0084] 卷积单元可进一步被配置为将由内核级联得到的共边的每个级联特征向量作为输入传递到密集神经网络。密集神经网络是一种深度神经网络,其为一种多层感知(MLP)。密集网络可输出(对于每个共边c):

[0085] $$\psi_c^{(i)} = MLP\left(\phi_c{}^{(i)}\right) = [\,\psi_{CC}^{(i)} \middle| \psi_{CF}^{(i)} \middle| \psi_{CE}^{(i)}\,]$$

[0086] 其中,$\psi_{CC}^{(i)}$, $\psi_{CF}^{(i)}$, $\psi_{CE}^{(i)}$具有相同的维度h,使得$\psi_c^{(i)}$的维度为3*h。

[0087] 卷积单元还可被配置为,对于由密集神经网络针对共边的输入级联特征向量输出的每个向量,计算新的边特征向量、新的面特征向量和新的共边特征向量。例如,对于由内核级联得到的共边c的输入级联特征向量$\varphi_c{}^{(i)}$,密集神经网络可输出:

[0088] $$\psi_c^{(i)} = MLP\left(\phi_c{}^{(i)}\right) = \left[\,\psi_{CC}^{(i)} \middle| \psi_{CF}^{(i)} \middle| \psi_{CE}^{(i)}\,\right],$$

[0089] 其中,$\psi_{CC}^{(i)}$, $\psi_{CF}^{(i)}$, $\psi_{CE}^{(i)}$具有相同的维度h,使得$\psi_c^{(i)}$的维度为3*h,以及对于每个共边c、每个面F和每个边E的新特征向量可以是

[0090] $$\begin{cases} X_c^{(i+1)} = \psi_{CC}^{(i)} \\ X_E^{(i+1)} = MaxPool(\psi_{CE1}^{(i)}, \psi_{CE2}^{(i)}) \\ X_F^{(i+1)} = MaxPool(\psi_{CF1}^{(i)}, \ldots, \psi_{CFk}^{(i)}) \end{cases}$$

[0091] 其中:

[0092] • $X_c^{(i+1)}$是密集神经网络对于共边c的输出$\psi_c^{(i)}$计算得到的新共边特征;

[0093] • $X_E^{(i+1)}$是对于边E计算得到的新边特征,其中,$\psi_{CE1}^{(i)}$和$\psi_{CE2}^{(i)}$对应于其两个相关联的共边的特征向量;

[0094] • $X_F^{(i+1)}$是对于面F计算得到的新面特征,其中,$\psi_{CF1}^{(i)}, \ldots, \psi_{CFk}^{(i)}$对应于其k相关联的共边的特征。

[0095] 新特征向量的计算可被称为“实体池化”,因为这种计算池化了先前计算的特征向量(即在共边级别)以获得面和边实体的新特征。这种计算分离实体用于池化的中间向量的事实有助于学习的神经网络学习每种类型实体的特定特征。

[0096] 在卷积单元的结束,输出可因此仍然是图形,其中,新的特征向量附加到每个实体。深度CAD神经网络可被配置为重复应用卷积单元预定次数,例如,至少三次,例如三次。换句话说,所述方法可一个接一个地堆叠几个卷积单元。就像在计算机视觉中堆叠卷积层增加了模型的感受场一样,堆叠卷积单元有助于每个共边看到其邻域的更大部分,从而有助于捕捉更多的全局和/或复杂特征。

[0097] 深度CAD神经网络可进一步被配置为通过执行由卷积单元应用得到的面特征向量的聚合来计算全局特征向量。这种计算被称为“全局池化”。这种全局特征向量的计算允许实现深度CAD神经网络的目标,即为输入CAD模型返回单个签名,因为它允许从每个节点实体都具有嵌入向量的图中生成单个嵌入。全局池化只聚合面特征,这即足够,因为每个面在B-rep图中都级联到一组共边。因此,相比于边或共边,它们收集更多关于其本地邻域的信息。

[0098] 聚合可基于最大池化方法/策略,即,聚合可在面上使用最大池化策略/方法。最大池化可如下实现。设Z_g是全局输入B-rep图的嵌入,$Z_F^{(k)}$是深度CAD神经网络的最后一个卷积层输出的面(k)的嵌入。则最大池化可包括如下计算Z_g:

[0099] $$Z_F^{(k)} \in \mathbb{R}^h$$

[0100] $$Z_g = MaxPool\left(Z_F^{(1)}, Z_F^{(2)}, \ldots, Z_F^{(K)}\right) \in \mathbb{R}^h$$

[0101] 其中,h是面嵌入的维度。

[0102] 可替换地,聚合可基于注意力机制方法(Attention Mechanism method)。这种方法在参考文献M.Ilse,J.M.Tomczak and M.Welling,″Attention-based Deep Multiple Instance Learning″,2018中被讨论,其通过引用并入本文。这种替换聚合策略在模型中引入了额外的学习模块。在这种情况下,池化是面嵌入$(Z_F^{(1)}, \ldots, Z_F^{(K)})$的加权平均值:

[0103] $$Z_g = \sum_{k=1}^{K} a_k \, Z_F^{(k)}$$

[0104] 权重$(a_1, \cdots, a_K)$由神经网络计算,其中

[0105] $$a_k = \frac{e^{w^T \tanh(V \, Z_F^{(k)^T})}}{\sum_{i=1}^{K} e^{w^T \tanh(V \, Z_F^{(i)^T})}}$$

[0106] 其中,$W \in \mathbb{R}^{hx1}$, $V \in \mathbb{R}^{hxh}$是学习的参数。

[0107] 这两种策略都允许处理输入可具有完全不同数量的节点或边的挑战。图4示出了两种策略(F:面,C:共边,E:边)。图5示出了深度CAD神经网络的全局架构的示例,其中,在执行全局池化之前连续应用三个卷积单元。每个卷积单元执行内核级联、多层感知器(MLP)的

应用和实体池化。

[0108] 深度CAD神经网络的学习可包括执行对比学习以训练深度CAD神经元网络来计算全局特征向量的拓扑签名。持续学习允许处理B-Rep图或B-Rep模型(由其形成图)未标记的情况。对比学习的概念从参考文献T.Chen,S.Kornblith,M.Norouzi and G.E.Hinton,"A Simple Framework for Contrastive Learning of Visual Representations"2020中已知,其通过引用并入本文并适用于实施在所述方法中。

[0109] 在原始论文(T.Chen,S.Kornblith,M.Norouzi and G.E.Hinton,"ASimple Framework for Contrastive Learning of Visual Representations"2020)中,框架提出了使用对比学习范式以无监督的方式学习图像嵌入,如图6所示。目标是学习训练数据的表达性潜在表示,诸如具有近嵌入向量的两个相似输入(正对)和具有远嵌入向量的不同输出(负对)。然而,如果训练数据未标记,则最初无法访问正对和负对。对比学习范式通过数据扩充技术综合创建这些对而避开了这一限制。具体地,每个输入数据经历如图6所示的随机变换(步骤1)),使得同一输入的两个变换构成正对,否则构成负对。例如,对于它们在图像数据集上的应用,可选择诸如随机色移和随机裁剪之类的经典图像变换。

[0110] 本方法的对比学习可基于正变换,其包括:

[0111] -身份转换,

[0112] -将随机几何体分配给具有概率p的边(例如,直线变为椭圆),

[0113] -将随机几何体分配给具有概率p的面(例如,平面变成柱面),

[0114] -将具有零的面的特征向量替换为概率p,以及

[0115] -删除具有概率p的边,如果该删除将使得面与输入B-rep图断开连接,则不进行此删除。

[0116] 换句话说,这些转换可以是用于生成持续学习框架的对的转换。这允许为该方法所考虑的特定输入(B-rep图,可能未标记)实现对比学习框架,因为这些正变换适用于特定的输入数据类型。所有变换都保留了图拓扑,这导致学习的网络捕获拓扑相似性。

[0117] 对比学习可包括最小化基于余弦相似性的归一化温度标度交叉熵损失,该损失的类型为:

[0118] $$L(i,j) = -\log \frac{e^{sim(z_i,z_j)}}{\sum_{k=1}^{2N} 1_{[k\neq i]} e^{sim(z_i,z_k)}},$$

[0119] 其中,(i,j)表示正对,(Z_i,Z_j)表示深度CAD神经网络对正对的嵌入,其中,sim是由以下公式定义的余弦相似性:

[0120] $$sim(x,y) = \frac{x.y}{\|x\|\|y\|} = \frac{\sum_{i=1}^{h} x_i y_i}{\sqrt{\sum_{i=1}^{h} x_i^2}\sqrt{\sum_{i=1}^{h} y_i^2}},$$

[0121] 对于$x,y \in \mathbb{R}^h$。通过小批处理训练将损失用于小批处理,其中,N是小批处理大小。因此,扩展批处理(具有对)具有2N个要素。将扩展批处理传递到深度CAD神经网络以计算嵌入(如图6的步骤2)。神经网络的目标(如图6的步骤3所示)是最大化嵌入与其正对之间的相似性,并最小化其他2(N-1)个嵌入之间的相似。相似性函数是余弦相似性。在上式中,(i,j)表示大小为2N的扩展批处理中的正对。

[0122] 还提供了一种可根据所述方法学习的神经网络,即具有通过所述方法学习到的神经网络的权重的计算机实现的神经网络数据结构。所提供的神经网络例如可通过所述方法直接学习,其权重已通过所述方法的学习步骤固定。

[0123] 还提供了一种使用神经网络的方法。所述使用方法包括获得表示B-rep的B-rep图。所述使用方法还包括将神经网络应用于B-rep图,从而获得B-rep的拓扑签名。

[0124] 所述使用方法可用于CAD模型之间的相似性搜索以及用于CAD对象检索。事实上,所学习的神经网络从输入的B-Reps(CAD)对象生成拓扑签名。这些签名嵌入拓扑信息。因此,拓扑相似的CAD模型(B-reps)具有或倾向于具有高的特征相似性。

[0125] 所述使用方法可用于两个CAD模型之间的拓扑相似性搜索。在这种情况下,所述使用方法可包括:

[0126] -提供第一B-rep的第一B-rep图和第二B-rep的第二B-rep图;

[0127] -将所述神经网络应用于所述第一B-rep图和所述第二B-rep图,由此获得所述第一B-rep的第一拓扑签名和所述第一B-rep的第二拓扑

[0128] 签名;以及

[0129] -评估两个签名之间的相似性。

[0130] 所述使用方法可用于通过拓扑相似性搜索在数据库中检索CAD对象。在这种情况下,所述使用方法可包括:

[0131] -提供:

[0132] o给定B-rep的给定B-rep图;

[0133] o与这些B-rep相关联的B-rep和/或CAD模型的数据库,数据库中的每个B-rep或CAD模型与其拓扑签名相关联(即,已经计算出的,例如,已经使用神经网络预先计算出的)

[0134] -将神经网络应用于给定B-rep图,由此获得给定B-rep的签名;

[0135] -用所述给定B-rep的签名查询所述数据库;以及

[0136] -对于数据库的每个B-rep和/或CAD模型,评估给定B-rep的签名与数据库的B-rep或CAD模型的签名之间的相似性。

[0137] 在所述使用方法的所有上述示例中,提供B-rep的B-rep图可包括生成如上文所讨论的用于在学习方法中提供训练数据集的B-rep图。提供数据库可包括通过将深度CAD神经网络应用于这些模型的B-rep图来获得数据库中的至少一些(例如,所有)模型的拓扑签名(提供数据库可以包含生成)。评估签名和另一签名之间的相似性可包括计算两个签名之间的余弦相似性。两个特征向量x和y之间的余弦相似性通过余弦相似性函数来计算:

[0138] $$sim(x,y)=\frac{x.y}{\|x\|\|y\|}=\frac{\sum_{i=1}^{h}x_i y_i}{\sqrt{\sum_{i=1}^{h}x_i^2}\sqrt{\sum_{i=1}^{h}y_i^2}}.$$

[0139] 由于计算两个签名之间的相似性非常快,因此可在很短的时间内将结果提供给用户。

[0140] 图7示出了示例结果,其是从在150k工业设备(螺钉、螺母、旋钮等)的数据库上训练的深度CAD神经网络获得的,并在工业设备数据集和学术数据集上测试字母大写的实心字母(在参考文献P.K.Jayaraman,A.Sanghi,J.G.Lambourne,K.D.Willis,T.Davies,

H.Shayani and N.Morris,"UV-Net:Learning from Boundary Representations"CVPR 2021中被讨论,其通过引用并入本文),分别显示在3个顶部行和3个底部行中。每个对象顶部的数字是与输入签名的相似性。图7示出了当对象属于数据库时,最相似的对象是对象本身。与之前引用的参考文献P.K.Jayaraman,A.Sanghi,J.G.Lambourne,K.D.Willis,T.Davies,H.Shayani and N.Morris,"UV-Net:Learning from Boundary Representations"CVPR 2021中讨论的几何检索相比,其中,类似的模型属于同一字母类别,拓扑检索更倾向于提取图信息(结构和元素特征)方面的相似对象。

[0141] 所述学习方法和使用方法可在相同的CAD对象检索过程中实现,该过程包括首先执行学习方法(该步骤可被称为"离线阶段"),然后执行使用方法(该步骤可被称作"在线阶段")。图8和图9示出了这种过程的示例的流程图。过程示例如这些图所示,包括离线和在线阶段:

[0142] -离线阶段:该阶段旨在使用制造B-rep对象训练模型。该阶段

[0143] 可对用户是透明的;

[0144] o训练B-rep图生成代表实现从原始B-rep训练文件到图的转换管道,其中,图的节点都是拓扑组件,边表示它们之间的交互。

[0145] 数据解析包括几何参数提取和不同组件的特征计算;

[0146] o基于训练的B-rep图学习神经网络模型。它由基于B-repDNN的模型组成;

[0147] -在线阶段:给定B-rep文件和B-rep数据库,首先对数据进行预处理,以生成相应的B-rep图。然后,将训练后的模型应用于计算输入和数据库对象的签名。最后,根据签名相似性(距离),从B-rep数据库检索到输入B-rep的最相似对象。

[0148] 图10至图13示出了在线阶段的示例。每个图都示出了查询B-rep和数据库中检索到的拓扑结构最相似的B-rep。每个图还示出了几何上最相似的B-rep,用于说明几何检索与拓扑检索之间的差异。

[0149] 这些方法是计算机实现的。这意味着所述方法的步骤(或基本上所有步骤)由至少一台计算机或任何类似系统执行。因此,所述方法的步骤由计算机执行,可能是完全自动的,或者半自动的。在示例中,可通过用户-计算机交互来执行所述方法的至少一些步骤的触发。所需的用户-计算机交互的水平可取决于所预见的自动化水平,并与实现用户愿望的需要相平衡。在示例中,该级别可以是用户定义的和/或预定义的。

[0150] 一种方法的计算机实现的典型示例是利用适用于此目的的系统来执行所述方法。所述系统可包括耦合到存储器和图形用户界面(GUI)的处理器,该存储器上记录有包括用于执行所述方法的指令的计算机程序。存储器还可存储数据库。存储器是适用于这种存储的任何硬件,可包括几个物理上不同的部分(例如,一个用于程序,可能一个用于数据库)。

[0151] 图14示出了所述系统的示例,其中,所述系统是客户端计算机系统,例如,用户的工作站。

[0152] 所述示例的客户端计算机包括连接到内部通信总线1000的中央处理单元(CPU)1010、也连接到总线的随机存取存储器(RAM)1070。客户端计算机还被提供有图形处理单元(GPU)1110,其与连接到总线的视频随机存取存储器1100相关联。视频RAM 1100在本领域中也被称为帧缓冲器。大容量存储设备控制器1020管理对诸如硬盘驱动器1030之类的大容量存储器设备的访问。适用于有形地体现计算机程序指令和数据的大容量存储器设备包括所

有形式的非易失性存储器,例如包括半导体存储器设备,例如EPROM、EEPROM和闪存设备;诸如内部硬盘和可移动磁盘的磁盘;磁光盘。上述任何一项都可以由专门设计的ASIC(专用集成电路)来补充或合并。网络适配器1050管理对网络1060的访问。客户端计算机还可包括诸如光标控制设备、键盘等的触觉设备1090。在客户端计算机中使用光标控制设备以允许用户选择性地将光标定位在显示器1080上的任何期望位置。此外,光标控制装置允许用户选择各种命令,并输入控制信号。光标控制装置包括用于向系统输入控制信号的多个信号生成装置。通常,光标控制设备可以是鼠标,鼠标的按钮用于生成信号。可替换地或附加地,客户端计算机系统可包括敏感垫和/或敏感屏幕。

[0153] 计算机程序可包括可由计算机执行的指令,所述指令包括用于使上述系统执行所述方法的装置。所述程序可记录在任何数据存储介质上,包括系统的存储器。所述程序可例如在数字电子电路中实现,或者在计算机硬件、固件、软件中实现,或在它们的组合中实现。所述程序可被实现为设备,例如有形地包含在机器可读存储设备中以供可编程处理器执行的产品。方法步骤可由可编程处理器来执行,该可编程处理器执行指令的程序以通过对输入数据进行操作并生成输出来执行所述方法的功能。处理器因此可以是可编程的,并且被耦合以从数据存储系统、至少一个输入设备和至少一个输出设备接收数据和指令,以及向数据存储系统和至少一种输出设备发送数据和指令。应用程序可以用高级过程或面向对象的编程语言来实现,或者如果需要,可以用汇编或机器语言来实现。在任何情况下,所述语言都可以是编译语言或解释语言。所述程序可以是完整安装程序或更新程序。所述程序在系统上的应用在任何情况下都会产生用于执行所述方法的指令。可替换地,计算机程序可在云计算环境的服务器上存储和执行,该服务器通过网络与一个或多个客户端通信。在这种情况下,处理单元执行程序所包括的指令,从而使所述方法在云计算环境上执行。

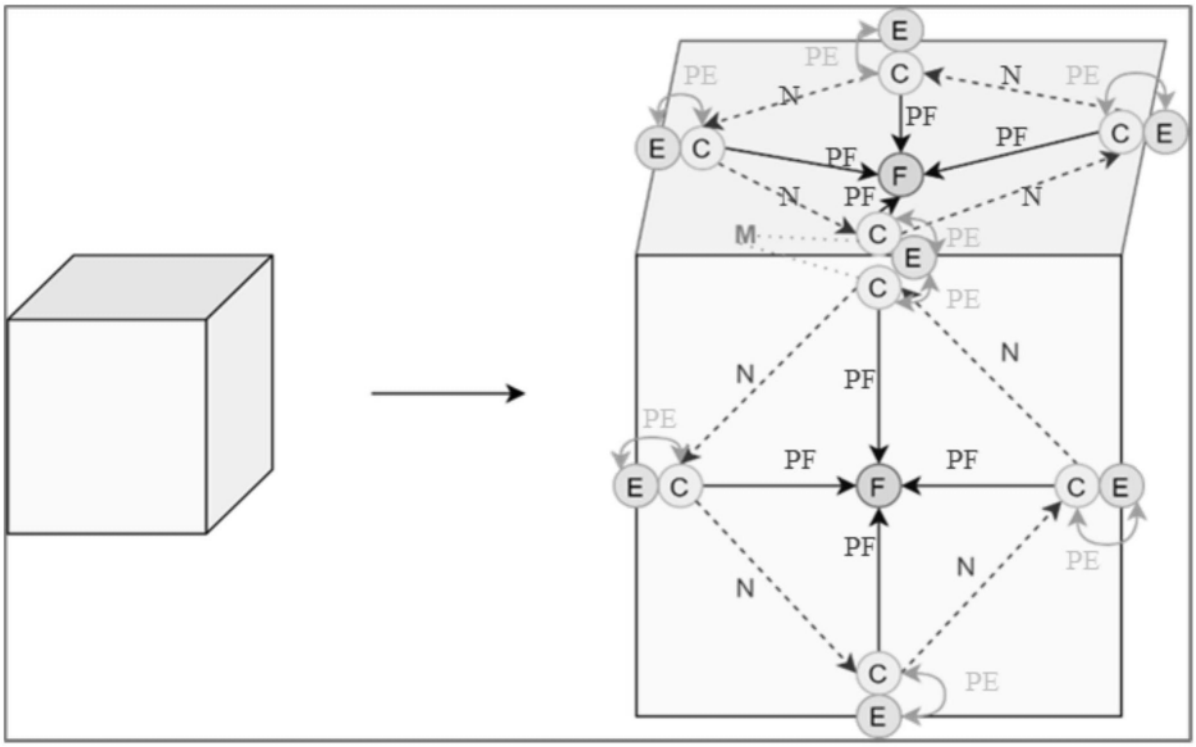
E
PE
C
N
PE
PF
E C
PF
F
PF
C E
N
PF
N
M
C
E
PE
C
PE
N
PF
N
PE
E C
PF
F
PF
C E
PF
N
PE
N
C
PE
E

图1



图2

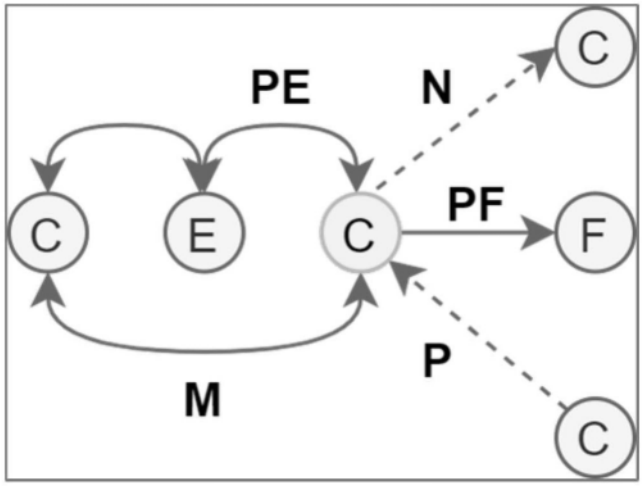
PE
N
C
C
E
C
PF
F
P
M
C

图3

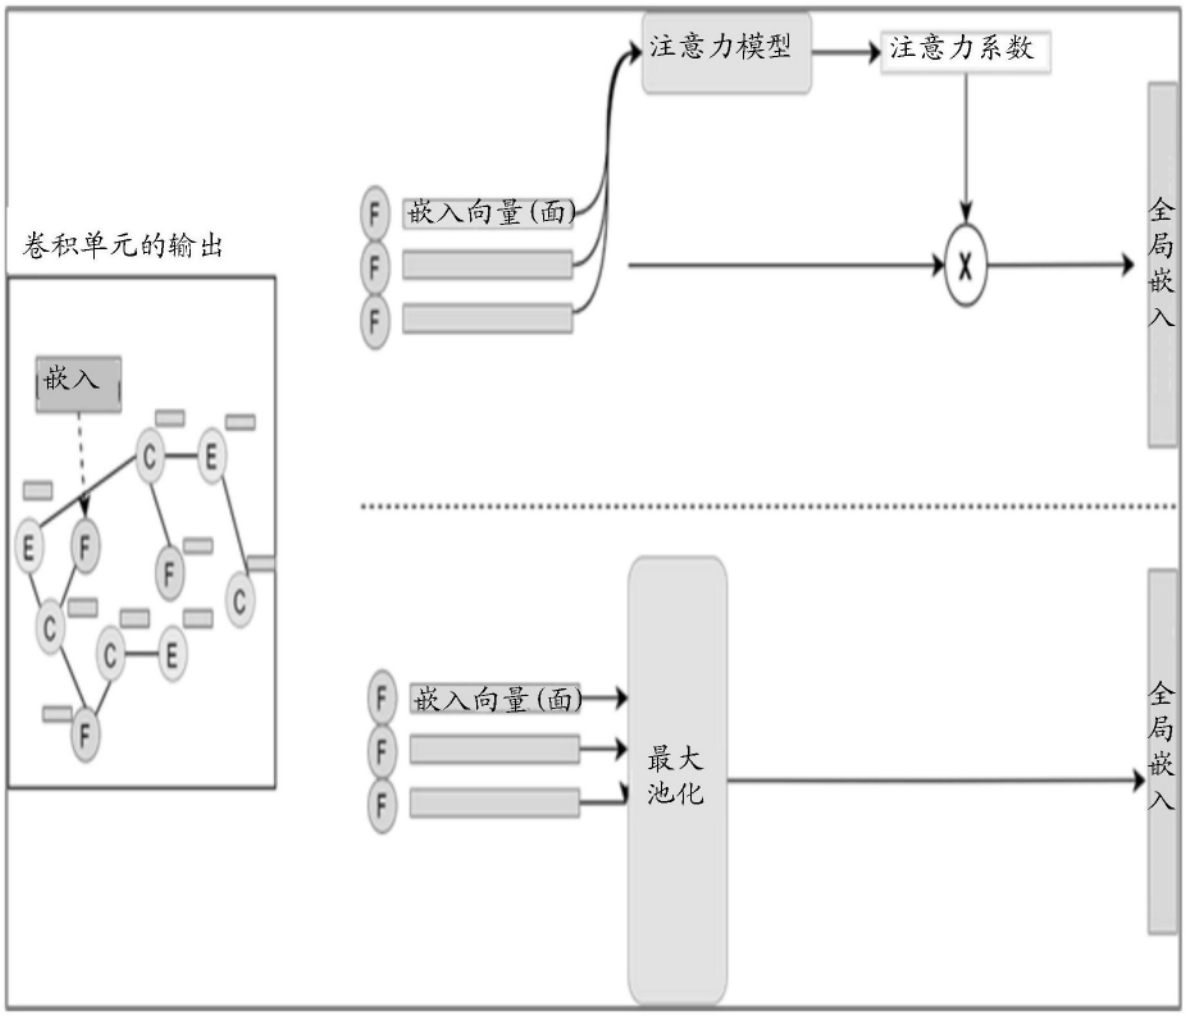

图4

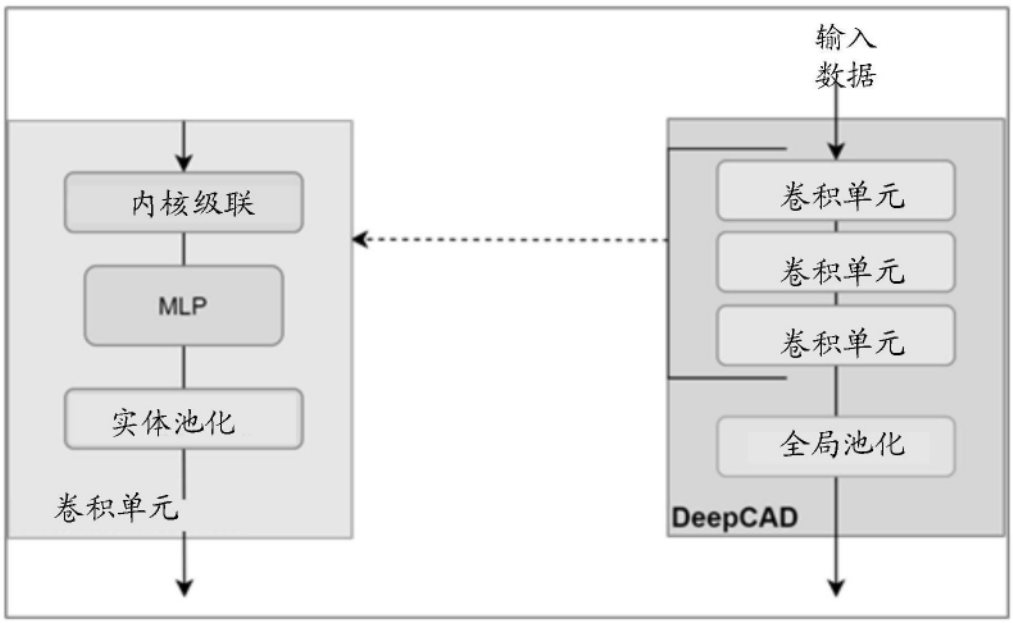

图5

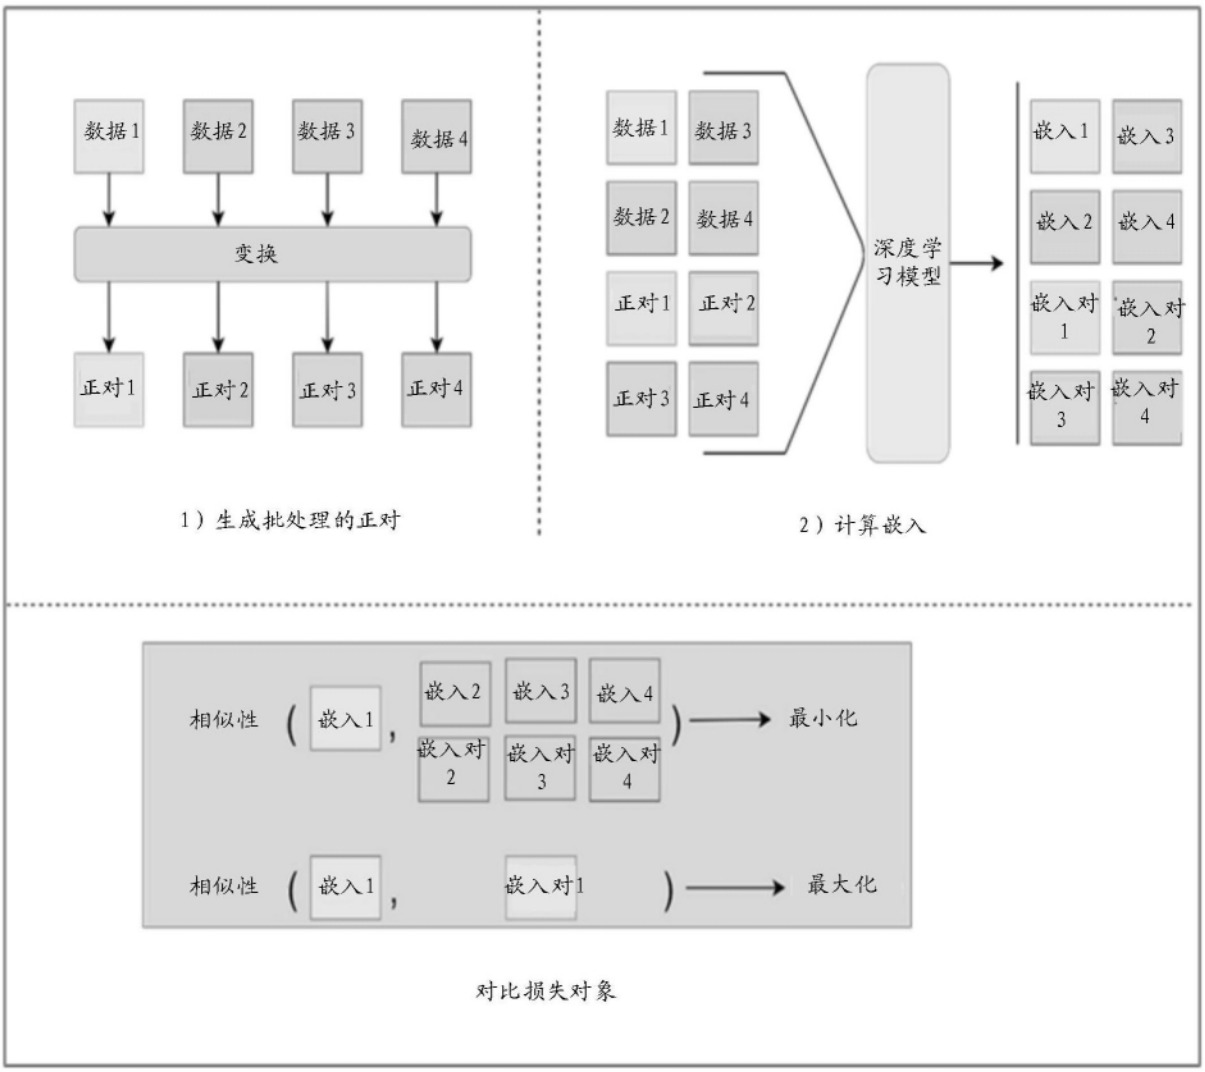
数据1
数据2
数据3
数据4
变换
正对1
正对2
正对3
正对4
1）生成批处理的正对
数据1
数据3
数据2
数据4
正对1
正对2
正对3
正对4
深度学习模型
嵌入1
嵌入3
嵌入2
嵌入4
嵌入对1
嵌入对2
嵌入对3
嵌入对4
2）计算嵌入
相似性
嵌入1
嵌入2
嵌入3
嵌入4
嵌入对2
嵌入对3
嵌入对4
最小化
相似性
嵌入1
嵌入对1
最大化
对比损失对象

图6

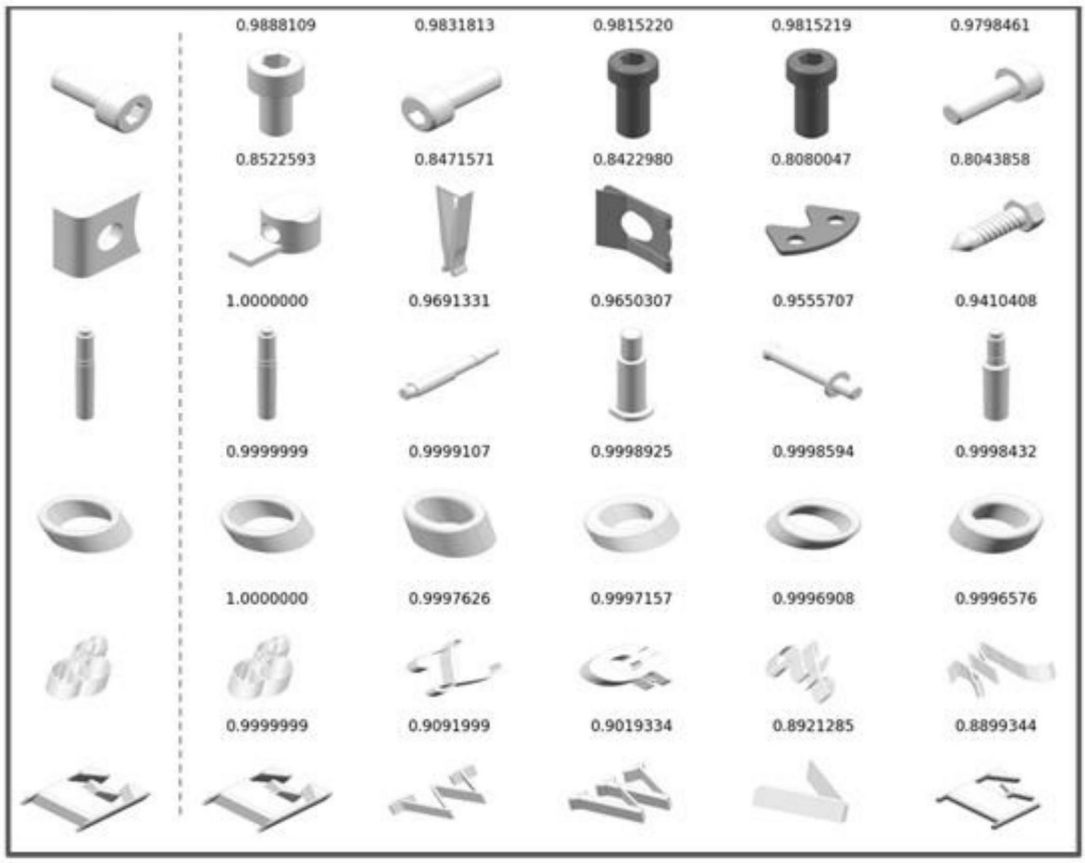

输入 从工业设备数据集（顶部3）和实心字母数据集（底部3）得到的最相似对象

图7

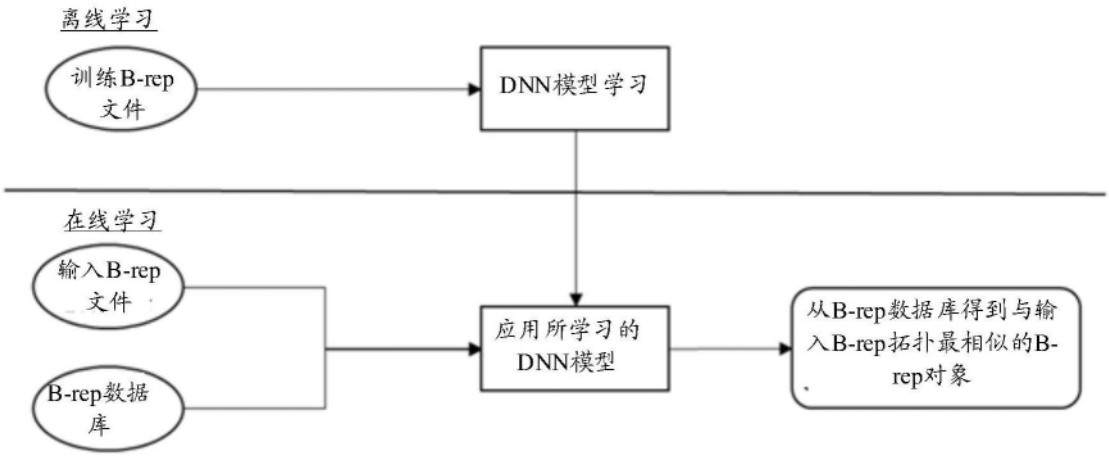

图8

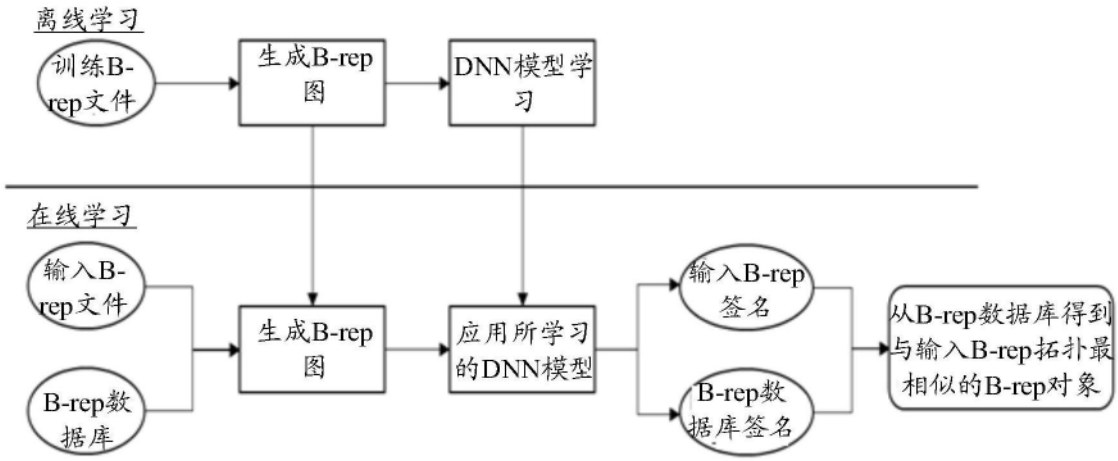
离线学习
训练B-rep文件
生成B-rep图
DNN模型学习
在线学习
输入B-rep文件
B-rep数据库
生成B-rep图
应用所学习的DNN模型
输入B-rep签名
B-rep数据库签名
从B-rep数据库得到与输入B-rep拓扑最相似的B-rep对象

图9

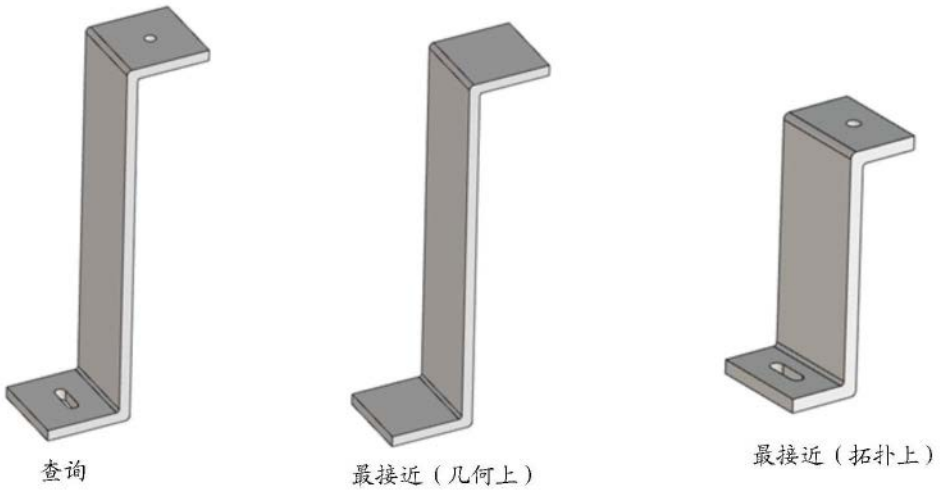
查询
最接近（几何上）
最接近（拓扑上）

图10

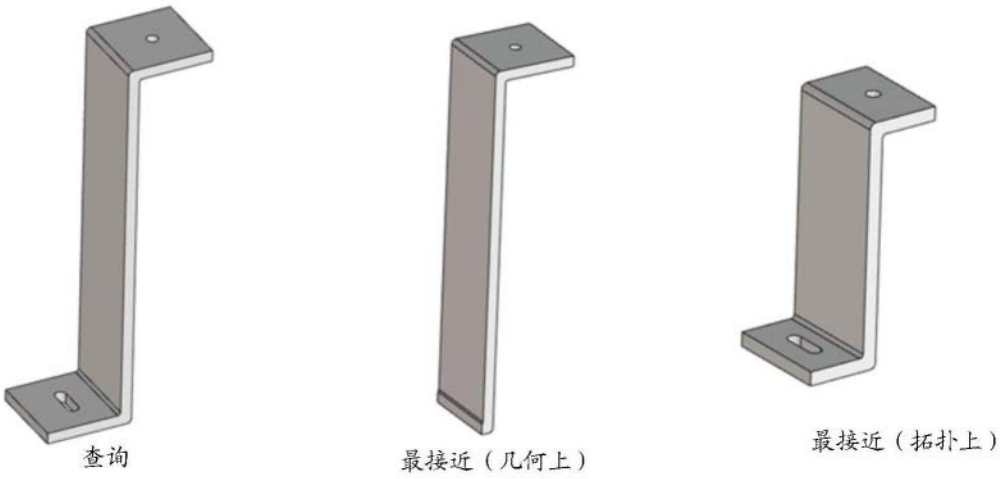

图11



图12

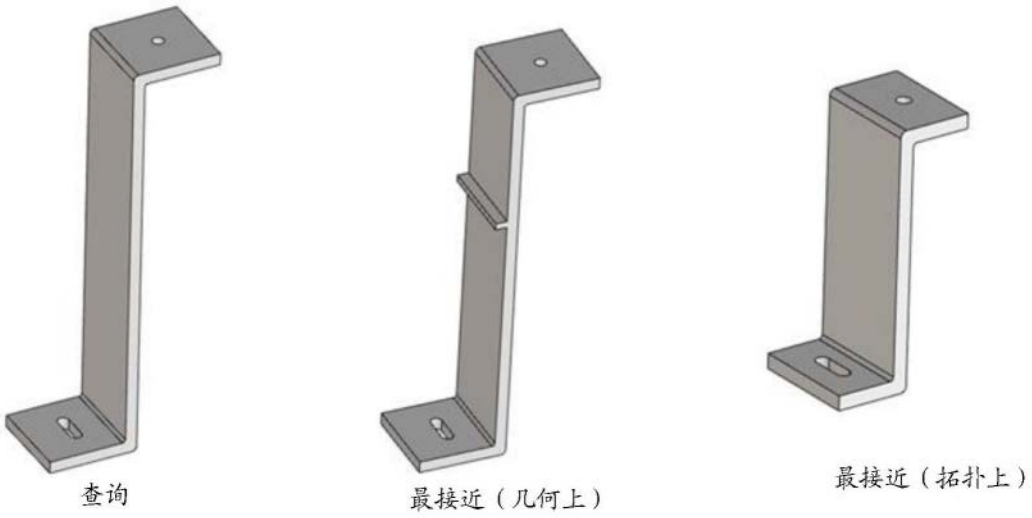
查询
最接近（几何上）
最接近（拓扑上）

图13

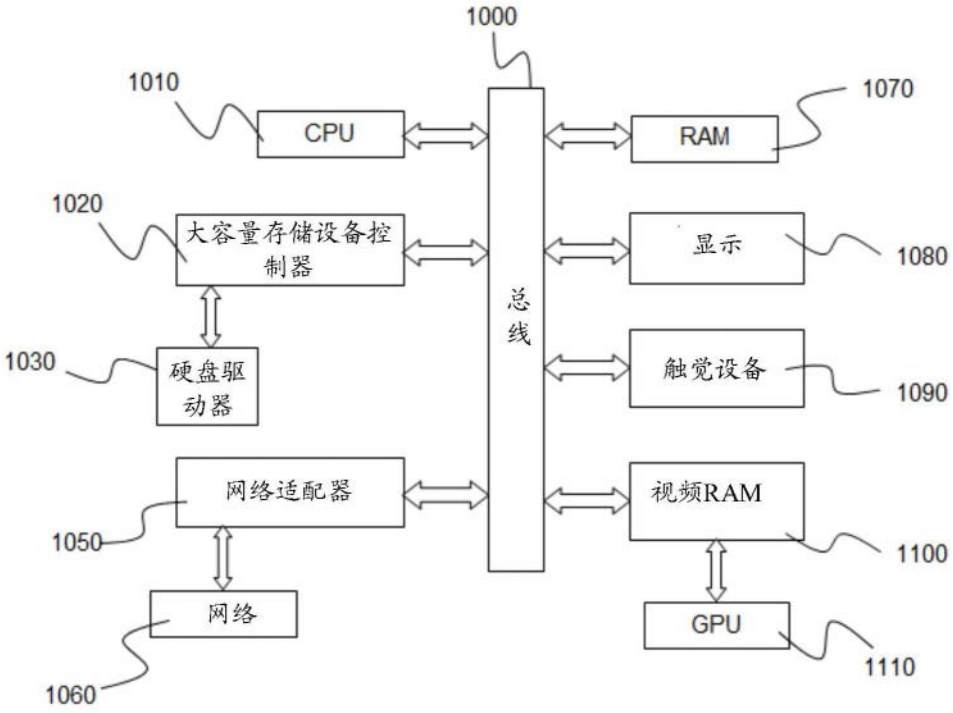
1000
1010
CPU
1070
RAM
1020
大容量存储设备控制器
显示
1080
总线
1030
硬盘驱动器
触觉设备
1090
网络适配器
视频RAM
1050
1100
网络
GPU
1060
1110

图14