Neuro-OSVETA：一种稳健的三维网格水印方法

Bata Vasic[*], Nithin Raveendran[+], Bane Vasic[+], *IEEE*会士[*]电子系，电子工程学院，尼什大学，塞尔维亚[+]电气与计算机工程系，亚利桑那大学，图森

摘要

用于三维网格版权保护的最佳实用水印方案，必须具备盲检测能力，并能抵御攻击和错误。本文介绍三维盲水印领域的最新进展，重点阐述我们的有序统计顶点提取与跟踪算法（OSVETA）及其改进。OSVETA 将量化索引调制（QIM）与纠错编码相结合，并采用新颖的方法，审慎选择在网格简化后仍保持稳定的网格顶点。本文提出的技术则提供了一种基于神经网络进行顶点选择的系统化方法，以取代 OSVETA 中的启发式方法。Neuro-OSVETA 能够更精确地估计网格几何，并更准确地估计曲率和拓扑特征。这些改进使稳定顶点的识别更加准确，从而显著降低顶点被删除的概率。

I. 引言

我们正见证着一场神经网络革命，深度学习技术正在影响几乎每一个技术领域。计算能力和互联互通方面的进步促成并推动了这一转变。有趣的是，最早具有革命性的神经网络理念实际上出现在图像分类[1], [2], 和目标识别[3]领域。图像水印也被视为一个重要领域，近期许多研究论文都对此进行了广泛研究[4], [5], 和[6]。水印技术也使神经网络本身的版权保护成为可能 [7]。尽管相关理念最早可追溯至上世纪，但利用人工智能处理三维（三维）对象及其分类与识别的研究仍处于起步阶段。其原因部分在于三维对象缺乏统一的表示与描述方式，以及几何网络分析的复杂性；此外，相关工具和供其使用的互联网引擎也相对不成熟。尽管如此，过去几年中这一领域已有所进展，并取得了一些初步成果。

与图像处理领域一样，三维目标识别始于三维形状描述研究。同样地，正如上文提到的二维（2D）情况中的发展趋势，三维曲线研究也采用了神经网络。近来，卷积神经网络（CNN）在三维目标识别、形状分析和三维场景合成领域引起了广泛关注 [8], [9], 和 [10]。然而，据我们所知，目前尚无使用人工智能技术进行水印的研究成果。唯一的一次尝试 [11] ——尽管提出了一个原创性思路——却缺乏对神经网络使用方法的数学或方法论解释。此外，作者试图仅使用一个特征向量描述三维几何结构，虽然颇具热情，却未能确保所嵌入水印的鲁棒性。

本文研究了利用神经网络对三维网格进行水印处理的问题。正如我们所展示的，这种方法非常适合解决这一问题。其数学形式化表述为 a

用于选择三维网格中隐藏（承载）水印信息的顶点的准则较为复杂，涉及许多先验未知或依赖于数据的参数，而这恰恰是神经网络非常擅长处理的情况。

我们的方法 NEURO-OSVETA 在顶点提取算法 OSVETA 中采用了神经网络 [13]。它能够更精确地估计网格几何，并更好地估计曲率和拓扑特征。这些改进使稳定顶点的识别更加准确，从而显著降低了网格简化过程中顶点被删除的概率。

本文其余部分安排如下：第二节概述问题定义。第三节介绍相关的 OSVETA 符号和定义，并列出用于三维网格表征的所有几何和拓扑判据。第四节阐述神经网络构建的理论原理，并介绍神经网络的学习、反向传播思路和优化方法。第五节说明我们提出的水印方案，该方案能够进一步增强水印鲁棒性。最后，第六节展示顶点删除概率和误差概率性能的初步结果。

II. 问题定义

三维水印领域的首要挑战是确保水印数据能够抵御最常见的几何和拓扑变换，同时设计出适当的方案来定义水印提取规则。为确保嵌入数据的盲提取，提取算法需要对三维模型及其基元进行某种独特的拓扑表征。然而，由于三维模型的表示方式，网格基元通常没有确定的顺序，因此水印数据提取任务会面临同步问题。即使满足上述条件，第二个挑战仍是建立可靠的方案，以选择用于嵌入水印数据的载体。因此，所选载体最重要的特性是能够抵御各种变换，包括仿射变换以及复杂得多的优化和简化操作。

为了概括所有关于鲁棒性和盲水印的要求，我们需要明确可用于嵌入水印数据的宿主基元的重要性定义。因此，所有选定的基元都应能抵抗各种变换和变形过程，即使面对破坏性的抽取算法也不例外。选定的基元应能够承载全部水印信息，包括水印提取任务中的同步要求。这类基元还应定义为对拓扑重排保持不变。实际上，参与三维网格形状构建的顶点满足上述所有要求。因此，只有几何上重要的顶点集合才能用作水印宿主向量，我们的目标就是定义这样的宿主顶点集合。宿主顶点的重要性定义为：在优化和简化过程中，删除这些顶点所造成影响的不变性。

III. 有序统计顶点提取与追踪算法

为定义对形状的主要神经感知，我们首先讨论三维形状表征。然而，确定构成简单且可被计算机识别的三维形状的重要顶点，并非易事。因此，有必要先定义离散曲率估计问题，同时指出其与已知方法的差异。

A. 算法定义与符号说明

OSVETA 包含三个步骤：i）定义并排序顶点评估标准；ii）准确评估曲率并计算其特征；iii）根据网格拓扑追踪提取出的顶点的重要性。更具体地说，若()MVF是给定三维曲面的网格，其中V 和F分别是顶点向量和顶点之间拓扑连接的向量，则算法会生成两个向量作为结果：**s**, 即按降序排列的顶点稳定性向量，以及**q**, 即对应的索引向量。网格顶点按稳定性降序排列，构成向量。V =ᵢ**v**；长度为L的向量**p**则由。V =ᵢ**v** .中的前L 个元素构成。

即使描述符数量较少，OSVETA 也能取得良好效果，但仍有更多可用于网格分割的描述符[13]。此处为便于说明，我们暂时只考虑表 1 [13]中给出的描述符。

表 1 OSVETA 评估标准及其评分

N^0	标准	描述	Rate
1	$\psi_{min} \geq 0$	正最小二面角	1.0
2	$\Theta < 2\pi$	较小的θ角	1.0
3	$\kappa_{G1} > 0$	正高斯曲率	1.0
4	$\psi_{max} \geq 0$	较大的二面角	0.9
5	$\theta > 2\pi$	较大的θ角	0.8
6	$\kappa_G < 0$	负高斯曲率	0.8
7	$\kappa_{G1} < 0$	负高斯曲率	0.7
8	$\kappa_G > 0$	正高斯曲率	0.4

此列表列出了给定特征值对应的变量、函数和条件的符号，也列出了所有描述符的比率，这些比率将在后续反向传播过程中用作初始权重值。在图1中，我们展示了与感兴趣顶点 ᵢ*v*相关的主要角度和面积。

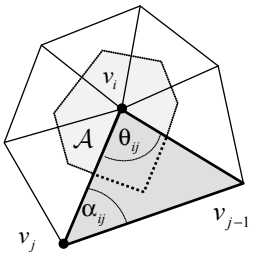

图1. 感兴趣顶点 **v**处相关特征和变量的示意图ᵢ

B. 离散高斯曲率描述符

将三维网格计算推广到一般条件下的主要问题，在于离散网格计算的准确性。从表中可以看出，高斯曲率是最重要的形状描述符之一。因此，下面简要讨论离散高斯曲率估计的两种方法。

1) 微分几何方法

我们从[14] 得知，对于$\mathbb{R}^3$中的流形曲面M及给定曲面上的每个点，都可以在局部用其切平面近似该曲面；该切平面与法向量$\mathbf{n}$正交。$\mathbf{K}$定义为同时属于曲面本身以及由$\mathbf{n}$和切平面内单位方向$\mathbf{e}$共同确定的平面的曲线的法曲率。我们将平均曲率$H=(\kappa_1+\kappa_2)/2$定义为曲面M的两个主曲率κ_1 和κ_2 的平均值。高斯曲率κ_G 定义为两个主曲率的乘积，即$\kappa_G=\kappa_1\kappa_2$。对于离散曲面$M$上的给定点$\mathbf{v}_i$ ，平均曲率法向量（拉普拉斯-贝尔特拉米算子）$K(\mathbf{v}_i)=2H(\mathbf{v}_i)\mathbf{n}(\mathbf{v}_i)$同时给出平均曲率$H(\mathbf{v}_i)$以及顶点$\mathbf{v}_i$处的单位法向量$\mathbf{n}(\mathbf{v}_i)$。仅取决于离散曲面顶点位置以及相邻三角形角度的高斯曲率分别定义如下：

$$\kappa_G(\mathbf{v}_i)=\frac{1}{\mathcal{A}}\left(2\pi-\sum_{j=1}^{\#f}\theta_{ij}\right) \tag{1}$$

点$\mathbf{v}_i$ 处有$\#f$个相邻三角形，θ_{ij} 是点$\mathbf{v}_i$处第j个相邻三角形的角度。点$\mathbf{v}_i$ 周围第一环三角形的面积为$\mathcal{A}$ [15]。

2) 二次曲面拟合方法

二次曲面拟合曲率估计方法的基本思路是：光滑曲面几何可在局部近似为二次多项式曲面。该方法在局部坐标系中，为每个选定点拟合其局部邻域内的点所构成的二次曲面。将该二次曲面在选定点处的曲率作为离散曲面的曲率估计值。对于简单二次曲面形式$z=ax^2+bxy+cy^2$，其步骤如下：i) 通过以下两种方法之一估计点$\mathbf{v}$ 处的曲面法向量$\mathbf{n}$：简单平均或加权平均，或者对该点及其邻点进行最小二乘拟合平面；ii) 在点$\mathbf{v}$处建立局部坐标系(x',y',z')，并使坐标轴“z”与估计的法向量对齐。McIvor 和 Valkenburg[16] 建议将“x”坐标轴与全局x轴在由$\mathbf{n}$定义的切平面上的投影对齐。如果采用这些改进，并将映射数据拟合到扩展二次曲面：$z'=ax'^2+bx'y'+cy'^2+dx'+ey'$，再求解所得线性方程组，就可以计算出两个主曲率$\kappa_1$ 和 κ_2。由此可估计高斯曲率：

$$\kappa_{G1}=\frac{4a'c'-b'^2}{\left(1+d'^2+e'^2\right)^2} \tag{2}$$

C. 拓扑特征

我们可以考虑使用的第二组拓扑特征，是一组用于表征区域显著性和抵抗变换能力的特征。由于优化和简化过程会破坏物体几何，因此某些角、顶点、边和面会被归类为高风险基本元素（例如 由共线边连接的顶点、边界顶点，以及平坦光滑区域中的顶点、边和面），甚至会被视为拓扑错误（空间中彼此孤立的孤立顶点、仅属于一条边界边的顶点、复杂顶点，以及连接三个或更多面的边、彼此没有共同顶点的交叉边）。

然而，某些拓扑特征对于形状描述至关重要（例如，同一条边上两个面之间的最小和最大二面角：$\psi_{\text{最大}}$ 和$\psi_{\text{最小}}$，分别如此。

我们提出的三维形状表征技术采用能够处理三维网格核心几何和拓扑表示的神经网络（NN）架构。下面介绍该神经网络架构，重点说明 Neural OSVETA 的实现。

IV. 神经 OSVETA

与二维图像分类卷积神经网络不同，三维卷积的数据稀疏性和计算成本严重限制了三维网格和点的体积表示。在水印应用中，这种分类的结果会导致顶点信息以及全部水印数据丢失。我们的目标是根据三维对象的基本表示，确定其主要特征，并恰当地关联这些特征定义与输入表示。遵循基于特征的神经网络的原则，并纳入所有相关的三维网格特征，我们设计了一种特征学习框架，直接将所有顶点的向量作为神经网络的输入。

A. 神经网络架构

输入神经元矩阵 $\{\}I = \mathbf{v}\ \mathbf{f}$ 表示为以下向量的集合：i）顶点向量 $\{\}$ $1,\ldots,_{i}\ i\ n$ $=$ $=\mathbf{v}\ \mathbf{v}$，其中每个顶点都是由其$()_{x\ y\ z}v\ v\ v\mathbf{v}$ 欧几里得坐标构成的向量；ii）拓扑通道向量 $()\{\}$ $1,\ldots,_{j}i\ f\ j\ m=$ $=\mathbf{f}$，包含表示给定三维网格中各个面的所有顶点连接。图2展示了所提出神经网络的示意架构。

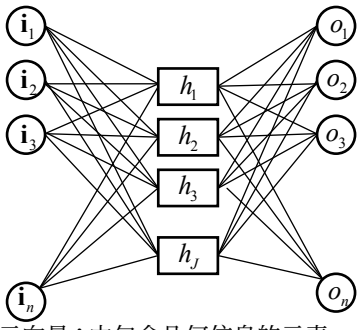

图 2. 神经网络　　网络架构：输入神经元表示向量 **i** 中包含几何信息的元素。及拓扑数据 **v** 和 **f**分别。隐层是一组用于描述三维网格内部形状的特征（第 II 节）。

隐层神经元表示表 **1** 中给出的几何和拓扑描述符及条件，并满足我们的特定要求。接下来，每个隐层神经元都与输出神经元相连，构成一个全连接神经网络（FNN），其输出向量为索引$()\mathbf{o}\ i$，并按顶点索引在$()\mathbf{o}\ i$中的位置对应顶点重要性的方式排序。为了避免三维网格几何与拓扑的不规则性问题，我们设置所有隐层神经元均由相同的输入权重值激活，并且所有输入神经元具有相同的偏置。因此，我们的算法支持不同的输入规模和网格规模。在[13] 中，我们证明，即使采用经验权重系数也能取得良好结果，从而提高水印鲁棒性。神经网络通过调整所有

权重和偏置并进行反向传播，学习得到按序排列的顶点索引向量，该向量提供顶点重要性信息。这些信息对于水印任务中的宿主顶点选择至关重要。现在，我们将介绍神经网络的学习过程以及本方案所采用的损失函数。

B. 反向传播与学习

为说明我们的反向传播方案，我们考虑一个隐层神经元 *H*，它接收来自输入神经元 *I* 的输入。这些神经元的激活（输出信号）分别是输入向量 $\{\}$ $1,,\ldots$ $iI\ i\ n$ $=$ $=i$ 的分量。我们用 $IJ\ \omega$ 表示输入 *II* 与隐层单元 *JH* 之间的权重。例如，第 *j* 个神经元 *H* 的净输入 *jhin* 是来自神经元 1，2，…，*n i i i* 的加权信号之和：$j\ j\ i\ ji\ i\ hin\ b$ $=$ $+\sum$ ωi。偏置 *b* 通过将其加入输入向量来纳入计算，并且与其他权重完全相同地处理。隐层神经元 *H* 的激活 *h* 由其净输入的某个函数给出，即 $()h\ g\ hin=$，其中 *Sigmoid* 函数为 $()\ ()\sigma$ $=$ $1+$ $^{-}$ $^{-1}$ $e\ i\ i$。下标 *JK* 类似地用于表示隐层单元 *JH* 与输出单元 *KO* 之间的权重 $JK\ \omega$ ；这些权重被视为任意但固定。采用这一记法，相应的小写字母可在推导权重更新规则时用作求和指标。对于任意激活函数 $()g\ x$，其导数记为 g'。激活对权重的依赖性源于将激活函数 *g* 应用于净输入 $K\ j\ jK$

$o\ h=\sum$ ω 以求得 $()_K g\ o$。权重按如下方式更新：

1) 更新隐层权重

设 $()_{1\ 2},,,_n\ t\ t\ t=\mathbf{t}\ldots$ 为训练输出向量或目标输出向量。那么，需要最小化的误差为 $[\quad]^2(=1/2\sum\quad-)_{k\ k\ k}E\ t\ o$，根据链式法则 [20], 可得：$[\quad]()_{K\ JK\ K\ K\ k}E\ t\ o\ g\ oin$ $\sigma\omega=\partial\ /\partial\quad=\quad-'$。对于连接到隐层单元 $_JH$ 的权重：$()[\ ]_{IJ\ k\ Jk\ J\ I}E\ g\ hin$ $\partial\ /\partial\omega\ =-\ \sigma\ \omega'\sum\ \mathbf{i}$，其中 $()_{J\ k\ Jk\ J\ k}g\ hin\sigma\ =\ \sigma\ \omega'\sum$。隐层单元的权重梯度为 $_{ij\ ji}\Delta\omega\ =\eta\sigma$ $\mathbf{i}$。由于每个隐层神经元都由来自所有输入神经元的相同权重和偏置加权，因此隐层的权重梯度表示为 $_{j\ j}\Delta\omega\ =\eta\sigma\mathbf{i}$。

2) 更新输出层权重

为计算输出层的权重，我们采用标准的前馈神经网络方案，使所有输出单元的误差平方和最小：$(\ )\ (\ )_{1\ 2}\quad{}^2\ {}_{l\ k\ k}E\ h\ o\ =\ /\ \sum\quad-$。接下来，我们需要确定权重的调整方向。我们计算相对于权重 $E\nabla\ {}_{kj}\ \omega$ 的负误差梯度，并调整权重值。假设该节点的激活等于下一个网络输入，那么第 *j* 个神经元的输出为 $()_{j\ j\ j}\ iin\ g\ hin=$，因此输出神经元的激活为：$_{k\ kj\ j\ k\ j}oin\ iin\ b=\sum\ \omega\quad+$，其中我们的激活输出为 $()_{k\ k\ k}o\ g\ oin=$。至于权重变化的幅度，我们令其与负梯度成正比：$(\ )\ (\ )_{kj\ k\ k\ k\ k\ j}E\ h\ o\ g\ hin\ oin$ $\partial\ \partial\omega\ =\ -\ '$。令 η 为学习率，用于控制每个训练步骤中的权重调整幅度。那么，

/

输出层的权重根据以下公式更新：( ) ( ) ( ) $_{kj}$ $^{1}{}_{kj}$ $_{kj}$ t t $t\omega$ + = ω + $\Delta\omega$，其中，( ) ( ) $_{kj}$ $_{k}$ $_{k}$ $_{k}$ $_{k}$ $_{j}$ h o g hin $iin\Delta\omega$ = η − ′；对于 Sigmoid 函数，权重更新公式为( ) ( ) $_{kj}$ $^{1}{}_{kj}$ $_{k}$ $_{j}$ t t $iin\omega$ + = ω + $\eta\sigma$，其中( ) ( ) $_{k}$ $_{k}$ $_{k}$ $_{k}$ $_{k}$ h o g $oin\sigma$ = − ′ 。

C. 训练输入

根据我们的输入规则，可以使用任意三维训练向量，而不受其元素数量的限制。然而，水印数据的大小决定了所需宿主顶点的数量，因此，神经网络可以从大小等于或大于待嵌入水印比特数的训练向量中学习。另一方面，我们的水印算法能够实现足够高的水印容量，从而克服上述问题。

V. 水印方案

经过强大的 Neuro-OSVETA 顶点提取后，我们采用经验证的水印方案——稀疏量化索引调制（QIM）变体技术[21]，将低密度奇偶校验编码的水印比特嵌入三维网格的几何结构中。具体技术已在我们先前的工作[22]中详细说明。本节将通过以下三个步骤简要介绍所用的水印算法。

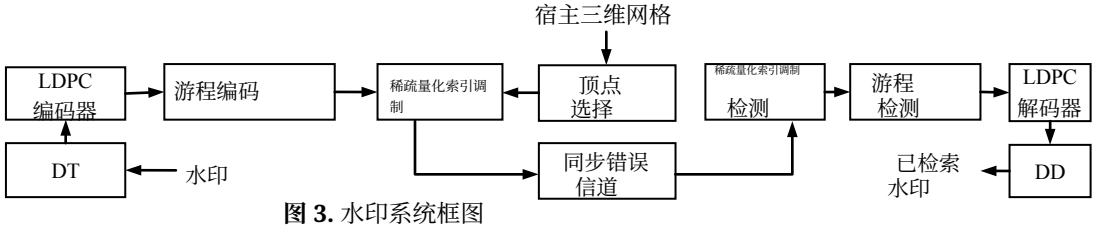

图 3. 水印系统框图

步骤 ***1***）。首先，使用结构化LDPC码对水印信号进行编码。需要注意的是，LDPC码有许多优良类别，我们的方法并不严格依赖于所采用的具体类别。为简便起见，此处使用正规准循环码。校验矩阵的列重和行重分别为$_{v}d\mu$=和$_{c}d$ = η，。不过，在编码之前，水印序列首先经过分布变换器（DT）处理，以优化 0 和 1 的概率，然后再进行低密度奇偶校验编码，并转换为游程后通过信道传输。

步骤 ***2***）。为了将具有无限记忆的信道转换为无记忆信道，信道输入符号以比特游程表示。表示 0 和 1 的游程长度根据信道同步统计信息进行选择。换言之，奇数索引的输入符号编码为由k 个 1 组成的游程，其中符号 0 对应$k = 2$，符号 1 对应$k = 3$。偶数索引的符号则以类似方式编码为由 0 组成的游程。

步骤 ***3***）。由于欧几里得意义上的微小误差可能会被人类视觉系统（HVS）感知为较大的失真，QIM 的通用版本可能导致水印三维信号的质量严重下降。为避免这一问题，我们采用 QIM 的稀疏变体。稀疏 QIM 将水印比特分散到载体信号L个元素上。长度为$\mathbf{x}_L$ 的载体序列被投影到一个L维单位范数向量$\mathbf{p}$ 上，并对相应投影的范数进行量化。所得L-维水印

向量$\mathbf{y}_L$ 可写为$(\ )(\ )^T\ T\ L\ L\ u\ L\ L = \quad + \qquad - \mathbf{y}\ \mathbf{x}\ \mathbf{xp}\ \mathbf{xp}\ \mathbf{p}\boldsymbol{Q}$ 。检测器将接收到的水印载体向量$_L\mathbf{r}$ 投影到$\mathbf{p}$上，并将嵌入比特恢复为$_2\{ = \quad \in 0,1 \quad - \}\hat{}\ \arg\min(\ )$。$_T\ T\ L\ L\ u\ L\ \|\ L\ u\ \boldsymbol{u}\ \mathbf{r}\ \mathbf{p}\ \mathbf{r}\ \mathbf{p}\boldsymbol{Q}$通常，水印的鲁棒性随$L$增大而提高。主成分轴是与顶点坐标协方差矩阵最大特征值对应的特征向量。

VI. 初步结果

正如我们已经提到的，目前不存在现有的神经网络水印方案，而可用的包含三维模型的训练数据库被用于分割和模型识别。因此，本文主要依赖理论假设以及使用 OSVETA 计算中所用数据集进行的实验计算；该数据集对于具有复杂几何和拓扑结构的小型和大型三维模型同样有效。我们的数据集通过对三维模型应用优化和简化函数，以及使用高斯滤波器获得并构建，这些操作都模拟了三维网格结构中的误差。由于我们独特的要求，训练集所需的目标输出向量还根据水印盲性和鲁棒性的要求，利用追踪算法以及与几何和拓扑特征之间的语义关联进行构建。

A. 隐藏层特征

三维网格的形状定义并非易事，可以证明，许多特征都会影响网格表征。然而，某些特征既能描述网格形状，也能描述网格几何的感知体验。例如，根据高斯曲率（$_G\kappa > 0$）选择重要的网格顶点，并采用两种不同的判据，具体如图 4 所示。

我们注意到，根据每项准则选取的顶点位于不同的网格区域。可以证明，表 1 中给出的其余特征也会选取不同的重要区域和顶点，这些区域和顶点可用于嵌入水印数据。此外，[13] 中列出的其他准则也可用于从水印中去除所有不重要的顶点和区域，从而减少输入神经元和输出神经元的数量，进而提高学习过程的速度和效率。



(a) (b)

图 4。 根据 $_G\kappa$ 和 $_G\kappa_1$ 准则选出的前 50 个顶点的三维位置：红色区域包含曲率值较高的顶点，绿色区域包含曲率值较低的顶点；(a) $\kappa_G>0$ -圆形，(b), $\kappa_{G1}>0$ -菱形。

B. 顶点删除概率

顶点稳定性计算与优化过程相关的结果由 Neuro-OSVETA 和 OSVETA 获得。为了消除拓扑错误，我们使用基于简化算法的 3D Studio Max 2015 应用程序中的“Pro Optimizer”修改器对模型进行优化 [24] 。即使我们的神经网络训练集相对较小，针对 Neuro-OSVETA 算法选取的 1000 个顶点与 OSVETA 分配的 1000 个顶点组进行的稳定性实验测试也显示了我们新方法的优越性。结果汇总于表2。

表2 优化删除的顶点数量

	0%	20%	40%	60%	80%	90%
总VR	17350	12209	6953	3926	2315	1448
随机	0	332	622	781	872	920
OSVETA	0	1	30	147	332	522
Neuro-OSVETA	0	0	22	121	282	421

给定剩余顶点百分比时，简化后剩余顶点的总数（Total RV）列于第一行。与随机选取的顶点（第二行）相比，第三行和第四行分别显示了 OSVETA 和 Neuro-OSVETA 从选取的 1000 个顶点中删除的顶点数量。顶点删除概率随顶点删除百分比变化的关系如图 5 所示。

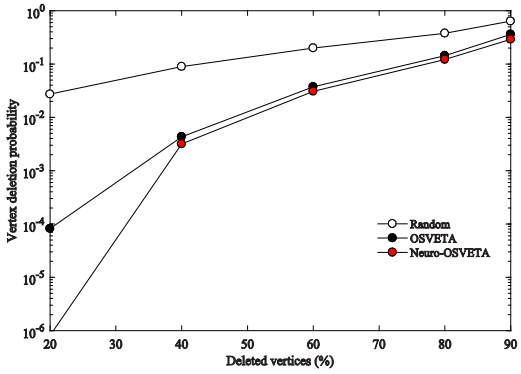

图 5。 顶点删除概率 p_d 随删除顶点数量的变化关系。

在图 5 中，我们的算法（以红点表示）比标准 OSVETA 表现更好，也远胜于随机选取顶点的方案。请注意，由于训练向量规模较小，这种改进幅度有限；增大训练向量规模可以进一步提升效果。

VII. CONCLUSION 结论与未来工作

本文提出了一种新技术，以基于神经网络的系统化方法取代 OSVETA 中的启发式顶点选择方法。Neuro-OSVETA 能够更精确地估计网格几何，并更好地估计曲率和拓扑特征。实验结果表明，通过更准确地识别稳定顶点，删除概率显著降低。未来的工作包括优化神经网络参数，并使用更大规模、种类更多的三维模型集作为训练向量，以提升整体性能。

参考文献

[1] Krizhevsky A., Sutskever I., and Hinton G. E., “使用深度卷积神经网络进行 ImageNet 分类”，载于《神经信息处理系统进展》论文集，第 1097–1105 页，2012 年。[2] Wu J., Yu Y., Huang C., and Yu K., “用于图像分类和自动标注的深度多实例学习”，载于《计算机视觉与模式识别》会议论文集（CVPR），第 3460–3469 页。IEEE，2015 年。[3] Simonyan K. and Zisserman A., “用于大规模图像识别的超深卷积网络”，载于第三届国际学习表征会议论文集（ICLR2015）。https://arxiv.org/abs/1409.1556。[4] Merhav N. and Sabbag E. “在检测资源有限的情况下实现最优水印嵌入与检测的策略”，IEEE 信息论汇刊，第 54 卷第 1 期：第 255–274 页，2008 年。[5] Comesana P., Merhav N., and Barni M. “高信噪比区间内渐近最优的通用水印嵌入与检测”，IEEE 信息论汇刊，第 56 卷第 6 期：第 2804–2815 页，2010 年。[6] Yu P.-T., Tsai H.-H., and Lin J.-S. “基于神经网络的彩色图像数字水印”，《信号处理》，第 81 卷第 3 期：第 663–671 页，2001 年。多媒体数字信号处理特刊。[7] Nagai Y., Uchida Y., Sakazawa S., and Satoh S., “深度神经网络的数字水印”，载于《国际多媒体信息检索期刊》，第 7 卷第 1 期：第 3–16 页，2018 年 3 月。[8] Maturana D. and Scherer S., “VoxNet：用于实时目标识别的三维卷积神经网络”，载于 2015 年 IEEE/RSJ 国际智能机器人与系统会议论文集，第 922-928 页，2015 年[9] Wang P.-S., Liu Y., Guo Y.-X., Sun C.-Y., and Tong X., “O-CNN：用于三维形状分析的基于八叉树的卷积神经网络”，《ACM图形学汇刊》，第 36 卷第 4 期，文章 72，2017 年 7 月。[10] Huang H., Kalogerakis E., Chaudhuri S., Ceylan D, Kim V.G., Ersin Y. M., “利用多视图卷积网络从部件对应关系中学习局部形状描述符”，《ACM图形学汇刊》（TOG），第 37 卷第 4 期，2018 年 7 月[11] Wang K., Angel M.S., Chang X., Ritchie D., “用于室内三维场景合成的深度卷积先验”，《ACM图形学汇刊》（TOG），第 37 卷第 4 期，2018 年 7 月[12] Motwani M.C., Bryant B.D., Dascalu S.M., Harris F.C. Jr., “利用人工神经网络保护三维多媒体”，载于 IEEE 消费者通信与网络会议论文集，拉斯维加斯，2010 年[13] Vasic B., “有序统计顶点提取与跟踪算法（OSVETA）”，《电气与计算机工程进展》，第 12 卷第 4 期，第 25 -32 页，2012 年 11 月。[14] Spivak M., “微分几何综合导论”，第 1 卷，第 3 版，Publish or Perish，1999 年。[15] Meyer M., Desbrun M., Schröder P., and Barr A.H., “三角剖分二维流形的离散微分几何算子”，《可视化与数学 III》，第 12 版，第 35 - 57 页，2003 年 8 月。[16] McIvor A.M. and Valkenburg R.J., “局部曲面几何估计方法的比较”，《机器视觉与应用》，第 10 卷第 1 期，第 17 - 26 页，1997 年 5 月。[17] Qi C.R., Mo H.S. Leonidas J. Guibas, “PointNet：面向三维分类与分割的点集深度学习”，载于 2017 年 IEEE 计算机视觉与模式识别会议论文集，第 77-85 页，2017 年。[18] Ackley D., Hinton G., and Sejnowski T., “玻尔兹曼机的一种学习算法”，《认知科学》，第 9 卷第 1 期，第 147-169 页，1985 年。[19] Ali Eslami S.M., HeesN. , Williams C.K.I. , and Winn J., “形状玻尔兹曼机：一种强大的物体形状模型”，《国际计算机视觉期刊》，2013 年 10 月。[20] Fausett L.V., “神经网络基础：架构、算法与应用”，Prentice-Hall, Inc.，美国新泽西州上萨德尔河，©1994[21] Chen B. and Wornell G., “量化索引调制：一类可证明有效的数字水印与信息嵌入方法”，IEEE 信息论汇刊，第 47 卷，第 1423-1443 页，2001 年。[22] Vasic B. and Vasic B. “适用于三维网格简化的LDPC编码稀疏QIM水印”，IEEE 多媒体汇刊，第 15 卷第 7 期，ITMUF8，第 1532-1542 页，2013 年 11 月。[23] Nguyen D.V., Chilappagari S.K., Vasic B., and Marcellin M.W., “关于无小陷阱集结构化LDPC码的构造”，IEEE 信息论汇刊，第 58 卷第 4 期，第 2280-2302 页，2012 年。[24] Kauffman M., “为 Project Newport 优化 Autodesk® 3ds Max® Design 模型”，Autodesk大学 2009, [在线] 网址：http://au.autodesk.com/?nd=material&session_material_id=6296