

딥 러닝 기반 얼굴 메쉬 데이터 디노이징 시스템

A Deep Learning-Based Face Mesh Data Denoising System

노 지 현*, 임 현 승*, 김 중 민*

Jihyun Roh*, Hyeonseung Im*, Jongmin Kim*

Abstract

Although one can easily generate real-world 3D mesh data using a 3D printer or a depth camera, the generated data inevitably includes unnecessary noise. Therefore, mesh denoising is essential to obtain intact 3D mesh data. However, conventional mathematical denoising methods require preprocessing and often eliminate some important features of the 3D mesh. To address this problem, this paper proposes a deep learning based 3D mesh denoising method. Specifically, we propose a convolution-based autoencoder model consisting of an encoder and a decoder. The convolution operation applied to the mesh data performs denoising considering the relationship between each vertex constituting the mesh data and the surrounding vertices. When the convolution is completed, a sampling operation is performed to improve the learning speed. Experimental results show that the proposed autoencoder model produces faster and higher quality denoised data than the conventional methods.

요 약

3차원 프린터나 깊이 카메라 등을 이용하면 실세계의 3차원 메쉬 데이터를 손쉽게 생성할 수 있지만, 이렇게 생성된 데이터에는 필연적으로 불필요한 노이즈가 포함되어 있다. 따라서, 온전한 3차원 메쉬 데이터를 얻기 위해서는 메쉬 디노이징 작업이 필수적이다. 하지만 기존의 수학적 디노이징 방법들은 전처리 작업이 필요하며 3차원 메쉬의 일부 중요한 특징들이 사라지는 문제점이 있다. 본 논문에서는 이러한 문제를 해결하기 위해 딥 러닝 기반의 3차원 메쉬 디노이징 기법을 소개한다. 구체적으로 본 논문에서는 인코더와 디코더로 구성된 컨볼루션 기반 오토인코더 모델을 제안한다. 메쉬 데이터에 적용하는 컨볼루션 연산은 메쉬 데이터를 구성하고 있는 각각의 정점과 그 주변의 정점들 간의 관계를 고려하여 디노이징을 수행하며, 컨볼루션이 완료되면 학습 속도 향상을 위해 샘플링 연산을 수행한다. 실험 결과, 본 논문에서 제안한 오토인코더 모델이 기존 방식보다 더 빠르고 더 높은 품질의 디노이징된 데이터를 생성함을 확인하였다.

Key words : 3D mesh data, denoising, deep learning, autoencoder, convolution

* Dept. of Computer Science, Kangwon National University

★ Corresponding author

E-mail : jongmin.kim@kangwon.ac.kr,

Tel : +82-33-250-8447

※ Acknowledgment

This work was supported by the National Research Foundation of Korea (NRF) grant funded by the Korea government (MSIT) (No. 2019R1F1A1063467).

Manuscript received Dec. 6, 2019; revised Dec. 22, 2019; accepted Dec. 26, 2019.

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

1. 서론

메쉬 (mesh) 데이터는 3차원 물체를 표현하는 데이터 타입 중 하나로, 적게는 수천 개 많게는 수만 개의 정점들과 각각의 정점들을 잇는 간선들, 그리고 이러한 간선들로 구성된 삼각형들로 이루어져 있다. 이러한 메쉬 데이터는 영화, 게임, 시뮬레이션 등의 산업 및 연구 분야 등에서 널리 사용되고 있다. 과거 오랫동안, 대부분의 메쉬 데이터는 숙련된 사용자가 상용 소프트웨어를 이용하여 직접 제작해왔다. 하지만, 최근에는 3차원 프린터나 깊이 카메라를 이용하여 실세계의 물체를 자동으로 녹

화해 메쉬 데이터로 저장할 수 있게 되었고, 이에 따라 누구나 쉽게 원하는 물체의 메쉬 데이터를 획득할 수 있게 되었다. 하지만, 3차원 프린터나 깊이 카메라로 녹화된 메쉬 데이터에는 하드웨어 성능의 한계로 인하여 불필요한 노이즈(noise)가 빈번하게 포함되어 있으며, 노이즈가 없는 메쉬 데이터를 얻기 위해서는 노이즈 제거를 위한 후처리 작업이 필수적이다.

메쉬 데이터에 포함된 노이즈 제거는 주로 통계학적 혹은 기하학적 방법을 통해 연구되어왔다. 이러한 기존의 메쉬 데이터 필터링 방법은 메쉬 데이터의 전체적인 노이즈를 일부 제거하는 데에는 효과적이거나, 원래 메쉬 데이터가 가지고 있던 섬세함을 동시에 제거하는 문제점을 가지고 있다. 또한, 노이즈의 형태, 종류 그리고 크기에 따라서 한 번 이상의 반복적인 필터링 연산이 필요할 수도 있고, 반복된 필터링 수행으로 인하여 필연적으로 메쉬 데이터에 포함되고 있고, 유지되어야 할 디테일이 상당 부분 제거되는 단점이 있다. 또한, 필터링 연산을 위해 복잡한 행렬 연산 과정이 포함된 전처리 작업이 필요하여 메쉬 데이터의 해상도에 따라 많은 연산 시간이 필요하다.

이러한 문제점을 해결하기 위해서, 본 논문에서는 메쉬 데이터에 포함된 노이즈를 효과적으로 제거하기 위한 딥 러닝 기반의 메쉬 디노이징 방법을 제안한다. 구체적으로 본 논문에서는 인공 신경망 구조 중 하나인 인코더와 디코더로 구성된 컨볼루션(convolution) 기반 오토인코더 모델을 활용하였다. 오토인코더의 입력은 노이즈가 포함된 메쉬 데이터이며 출력은 노이즈가 없는 메쉬 데이터이다. 메쉬 데이터에 적용된 컨볼루션 연산은 메쉬 데이터를 구성하고 있는 각각의 정점과 그 주변의 정점들 간의 관계를 고려하며, 각각의 정점에 대한 컨볼루션이 완료되면 학습 속도 향상을 위해 샘플링 연산을 수행한다. 학습이 완료된 후에 노이즈가 포함된 3차원 메쉬 데이터를 오토인코더의 입력으로 넣어주면, 학습된 네트워크는 메쉬의 특징을 자동으로 추출하고, 추출된 특징들을 통해서 디노이징된 메쉬 데이터를 결과로 출력한다. 본 논문에서는 학습데이터로 MPI-IS(<https://coma.is.tue.mpg.de/>)의 얼굴 데이터를 사용하였으며, 다양한 형태의 노이즈가 얼마나 효과적으로 제거될 수 있는지 확인하기 위해 기존 딥 러닝 기반 메쉬 데이터 디

노이징 기법과 비교하였다. 실험 결과 본 논문에서 제안한 방법이 기존의 다른 방법에 비해 더 빠른 속도로 더 높은 품질의 디노이징된 메쉬 결과를 생성함을 확인하였다.

II. 관련연구

메쉬 데이터에는 고주파 형태의 노이즈들이 존재한다고 가정하고 이를 제거하기 위해, 메쉬 데이터를 구성하고 있는 정점의 위치와 삼각형의 법선의 급격한 변화를 최대한 부드럽게 만드는 연구들이 진행되어왔다[1]-[2]. 하지만, 위 방법들은 노이즈를 제거하기 위해 반복적으로 필터링 작업을 수행하는 단점을 가지고 있다. 따라서, 한 번의 연산으로 노이즈를 효과적으로 제거하기 위해, 각 정점과 주변 정점과의 차이를 최소화하는 라플라시안(Laplacian)식을 통한 행렬 연산으로 문제를 재구성하는 연구들이 소개되어왔다[3]. 하지만, 이러한 방법들은 노이즈를 효과적으로 제거할 수는 있지만, 반드시 보존되어야 할 메쉬 표면의 뚜렷한 특징들도 필터링 후에 동시에 제거하는 단점을 가지고 있다. 영상처리 분야에서 활용되고 있는 이방성 확산[4]-[8]과 양방향 필터링[9]-[10], 평균 및 중간 필터링[11]-[12] 등을 메쉬 노이즈 제거에 적용하면, 메쉬 데이터에 포함된 노이즈를 효과적으로 제거함과 동시에 반드시 보존되어야 할 메쉬 표면의 기하학적인 디테일들을 유지할 수 있다. 하지만, 위 방법들이 잘 작동되기 위해서는 매개변수들이 신중하게 선택되어야 하며, 최적화된 매개변수를 찾기 위해서는 숙련된 사용자도 수차례 실험을 반복해야 하는 시행착오가 뒤따르게 된다.

한편, 이러한 메쉬 디노이징 기술은 비교적 큰 노이즈를 가진 메쉬 데이터에 대해서는 잘 작동하지 않기 때문에, 이차 피팅(second-order fitting)[13], L1 근사[14], 정규 분산 클러스터링[15]을 포함한 다양한 기술을 이용하여 메쉬의 기하학적인 특성을 파악하고 이를 통해 노이즈를 제거하는 연구가 진행되었다. 하지만 이러한 방법들은 노이즈가 쉽게 검출되는 메쉬 데이터에 대해서는 성공적으로 작동되지만, 감지되기 어려운 약한 노이즈에 대해서는 과도하게 필터링을 적용하는 문제가 있다.

본 논문에서 제안하는 딥 러닝 기반 메쉬 데이터 노이즈 제거 방법은 메쉬 데이터가 원래 가지고 있

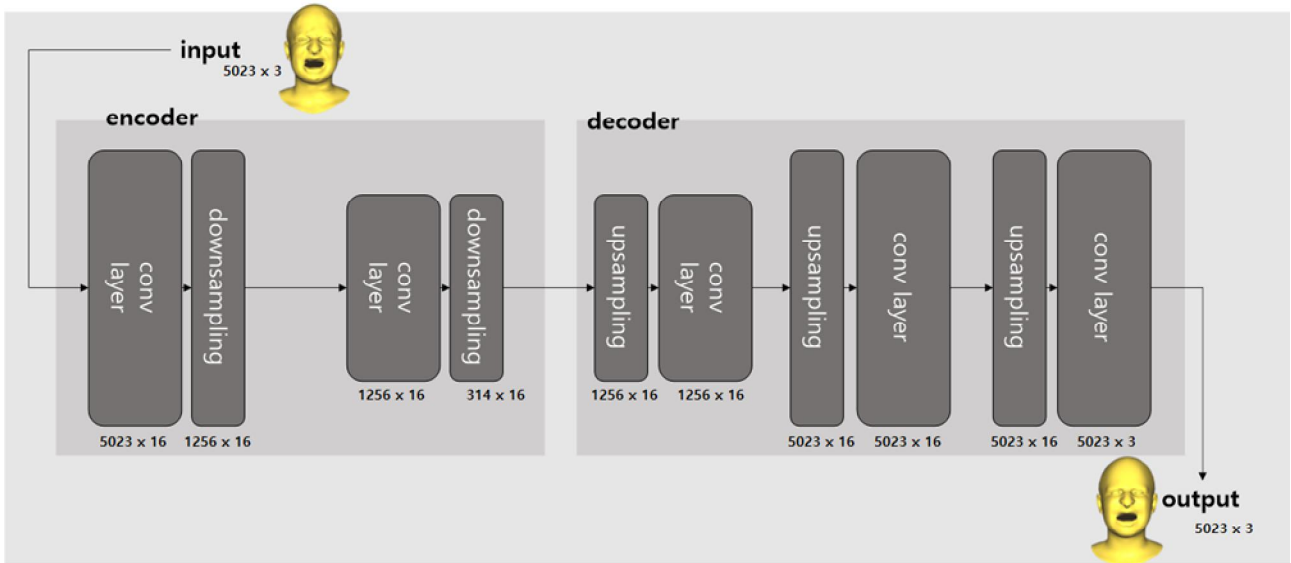


Fig. 1. Our autoencoder model for mesh denoising.

그림 1. 메쉬 디노이징을 위한 오토인코더 모델

던 특징들은 잘 유지하면서, 노이즈의 종류, 형태, 크기에 상관없이 효과적으로 노이즈를 제거한다.

III. 제안 시스템

본 논문에서는 그림 1과 같이 정의된, 인코더와 디코더로 이루어진 오토인코더 메쉬 디노이징 모델을 제안한다. 인코더의 구조는 표 1과 같다. 인코더는 두 개의 컨볼루션 층으로 구성되었다. 각 컨볼루션 층 다음에는 편향(bias) ReLU 함수를 적용하였다. 메쉬 데이터에 대해서 컨볼루션 연산만을 적용한다면 학습 속도가 느려질 수 있다는 단점이 있다. 이를 해결하기 위해, 원본 메쉬 데이터에 대해 다운 샘플링을 컨볼루션 후에 적용하였다. 다운 샘플링 층은 두 번씩 메쉬 데이터의 정점 수를 감소시킨다. 인코더는 메쉬 데이터를 $n=5023$ 일 때, $R^{n \times 3}$ 에서 $R^{314 \times 16}$ 로 변환시켜 준다. 디코더의 구조

Table 1. Encoder structure.

표 1. 인코더 구조

Encoder structure		
Layer	Input size	Output size
Convolution	5023×3	5023×16
DownSampling	5023×16	1256×16
Convolution	1256×16	1256×16
DownSampling	1256×16	314×16

는 표 2와 같다. 디코더의 컨볼루션 연산과 업샘플링 층은 메쉬 데이터를 다시 $R^{n \times 3}$ 으로 만들어준다. 각 컨볼루션 층의 끝에는 인코더와 같이 편향(bias) ReLU 함수를 적용하였다. 각 업샘플링 층은 두 번씩 메쉬 데이터의 정점 수를 증가시킨다.

Table 2. Decoder structure.

표 2. 디코더 구조

Decoder structure		
Layer	Input size	Output size
UpSampling	314×16	1256×16
Convolution	1256×16	1256×16
UpSampling	1256×16	5023×16
Convolution	5023×16	5023×16
Convolution	5023×16	5023×3

본 논문에서는 체비쇼프 (Chebyshev) 다항식 기반의 필터와 이웃 정점 간의 거리 평균 컨볼루션 필터, 두 개의 필터를 이용해 메쉬 디노이징을 수행한다. 먼저, 라플라시안 행렬을 사용하는 체비쇼프 필터는 메쉬를 구성하고 있는 각 정점과 이웃 정점 간의 특징을 추출하는 역할을 하고, 두 번째 필터인 컨볼루션 필터는 메쉬 데이터에 포함된 노이즈를 제거하는 역할을 한다. 두 필터는 서로 경쟁하며 메쉬 데이터에 포함된 노이즈를 제거한다. 이러한 방식으로 메쉬 데이터에 포함된 특징들은

유지하면서도 노이즈는 제거할 수 있다.

보다 구체적으로, 체비쇼프 필터 g_θ 는 차수 K 의 체비쇼프 다항식을 이용하여 아래 식과 같이 정의된다[16].

$$g_\theta(L) = \sum_{k=0}^{K-1} \theta_k T_k(\tilde{L}) \quad (1)$$

여기에서 $\tilde{L} = 2L/\lambda_{\max} - I_n$ 은 크기가 조정된 라플라시안이며, 매개변수 $\theta \in R^K$ 는 체비쇼프 계수 벡터이다. $T_k \in R^{n \times n}$ 는 차수 K 의 체비쇼프 다항식으로 다음과 같이 재귀식으로 정의된다. $T_0 = 1, T_1 = x$ 이고 $T_k(x) = 2xT_{k-1}(x) - T_{k-2}(x)$. 체비쇼프 필터를 이용해 스펙트럴 컨볼루션(spectral convolution)은 다음과 같이 정의된다.

$$y_j = \sum_{i=0}^{F_{in}} g_{\theta_{i,j}}(L)x_i \in R^n \quad (2)$$

여기에서 y_j 는 $y \in R^{n \times F_{out}}$ 의 j 번째 특징(feature)을 계산한다. 입력 $x \in R^{n \times F_{in}}$ 는 F_{in} 특징을 가지며, 입력 메쉬는 메쉬 데이터의 3D 정점 위치에 해당하는 $F_{in} = 3$ 인 특징을 가진다. 각 컨볼루션 층은 학습 가능한 매개변수로서 $\theta_{i,j} \in R^K$ 인 체비쇼프 계수들의 벡터 $F_{in} \times F_{out}$ 를 가진다. 본 논문에서는 $K=6$ 인 체비쇼프 필터를 사용한다. 그림 2는 체비쇼프 다항식 기반 필터만을 이용하여 메쉬 디노이징을 적용한 결과이다. 체비쇼프 다항식 기반 필터는 노이즈 제거보다는 메쉬 특징을 유지하는 역할을 하기 때문에 원하는 메쉬 품질을 얻기 어렵다.

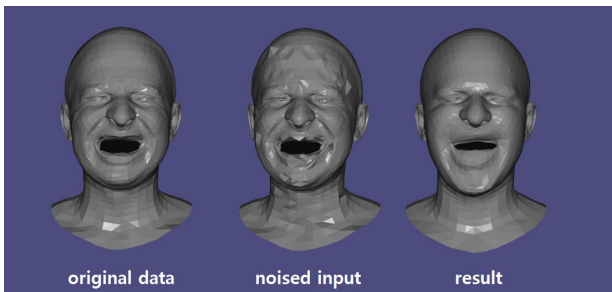


Fig. 2. Mesh denoising result using Chebyshev filters. 그림 2. 체비쇼프 필터만 이용한 메쉬 디노이징 결과

노이즈를 효과적으로 제거하기 위해서, 다음과 같이 이웃 정점 간의 거리 평균 컨볼루션 기반 필터를 정의하여 이용할 수 있다.

$$y_i = W_i \frac{\sum_{j \in N(i)} x_j}{N_i} \quad (3)$$

여기에서 입력 데이터 $x \in R^{N \times F_{in}}$ 는 입력 데이터의 개수 N 과 차원의 수 F_{in} 으로 구성된다. 출력 데이터는 $y \in R^{N \times F_{out}}$ 으로 F_{out} 은 출력 데이터의 차원의 수이다. $W_i \in R^{F_{in} \times F_{out}}$ 는 컨볼루션 연산을 위한 가중치 행렬이고, $N(i)$ 는 i 번째 정점과 이웃한 정점의 개수를 의미한다. 그림 3은 이웃 정점 간의 거리 평균을 이용한 컨볼루션 필터만을 이용했을 때의 결과이다. 노이즈가 제거되기는 하였지만, 메쉬 데이터가 가지고 있는 디테일이 상당히 제거되었음을 확인할 수 있다.

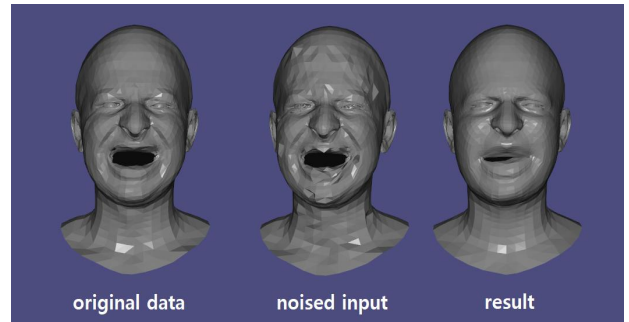


Fig. 3. Mesh denoising result using convolution filters. 그림 3. 이웃 정점 간의 거리 평균 컨볼루션 필터만 이용한 메쉬 디노이징 결과

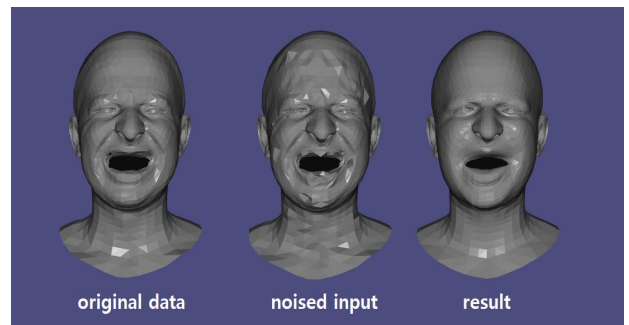


Fig. 4. Mesh denoising result using both Chebyshev and convolution filters. 그림 4. 체비쇼프 필터와 컨볼루션 필터를 모두 이용한 메쉬 디노이징 결과

체비쇼프 필터와 컨볼루션 필터만을 사용했을 때의 문제점을 보완하기 위해, 두 필터를 함께 사용하여 메쉬 디노이징을 적용하면 그림 4에서 볼 수 있듯이 원본의 특징은 유지하면서도 노이즈는 효과적으로 제거할 수 있다. 따라서 본 논문에서는

(2)와 (3) 식을 통합한 다음 식으로 정의되는 필터를 이용한다.

$$y_j = \sum_{i=0}^{F_{in}} g_{\theta_{i,j}}(L)x_i + W_i \frac{\sum_{j \in N(i)} x_j}{N_i} \quad (4)$$

IV. 실험 및 결과

실험을 위해 본 논문에서 제안한 오토인코더를 $8e-3$ 의 학습률과 매 에폭(epoch)마다 0.99의 감소율로 200번의 에폭으로 학습하였다. 오토인코더 모델이 예측한 메쉬와 실제 메쉬의 $L2$ 손실 함수의 차이를 보기 위해 모멘텀(momentum)이 0.9인 확률 경사 하강법을 사용하였다. 또한, 과적합 문제를 해결하기 위해 $L1$ 정규화 식을 손실 함수(loss function)에 추가하여 사용하였다.

실험 데이터로는 MPI-IS에서 제공하는 다양하고 복잡한 표정을 하는 사람들의 얼굴 데이터를 이용하였다(<https://coma.is.tue.mpg.de/>). 다양한 표정을 표현하는 3차원 메쉬 데이터는 복잡하고 비대칭적이다. 학습데이터를 만들기 위해 원본 데이터에 가우시안 노이즈를 추가하였다.

성능을 평가하기 위해 일반적인 컨볼루션 층만을 사용하는 방법인 convolution+neighbor(수식 3)와 본 논문에서 제안하는 체비쇼프 필터와 이웃 정점 정보를 사용하는 방법인 chebyshev+neighbor(수식 4)를 비교하였다. 한편, 오토인코더 모델을 학습시키기 위해 데이터를 학습 데이터와 테스트 데이터로 9:1의 비율로 분리하였다. 200 에폭 동안 모델을 학습시키고 테스트 데이터로 결과값을 얻어 오차값을 평가하였다. 오차는 노이즈가 들어있는 테스트 데이터와 원본 테스트 데이터 간의 유클리드 거리를 사용하여 계산하였다. 그림 5는 하나의 노이즈가 포함된 입력 데이터와 원본 데이터를 비교하여 유클리드 공간상에서의 오차를 보여준다. 실험 결과 본 논문에서 제안한 chebyshev+neighbor가 2개의 층만 사용했을 때 일반적인 컨볼루션 모델인 convolution+neighbor보다 99.2% 더 좋은 복원 성능을 보여주었다.

그림 6은 각 모델의 평균 오차에 자연로그를 취한 막대 그래프이다. 이를 통해, 그림 5와 같이 본 논문에서 제안한 chebyshev+neighbor 모델이 2개의 층만 이용했을 때 메쉬 데이터의 특징들을 잘

복원함을 확인할 수 있다.

data	chev+neighbor(2layer)	chev+neighbor(4layer)	conv+neighbor(4layer)
testdata_0	0.000657466	1.723767079	0.079376304
testdata_1	0.000786810	2.299049402	0.07958671
testdata_2	0.000775736	2.230104752	0.079661755
testdata_3	0.000781066	2.150364401	0.079633436
testdata_4	0.000771337	2.232215130	0.079679390
testdata_5	0.000433218	0.876581400	0.079734966
testdata_6	0.000725439	2.108919481	0.079720520
testdata_7	0.000735169	2.061181056	0.079462416
testdata_8	0.000711058	1.950613793	0.079453411
testdata_9	0.000669524	1.792794919	0.079368587
testdata_10	0.000572602	1.423447577	0.079388835
testdata_11	0.000715277	1.988057929	0.079459194
testdata_12	0.000417150	0.915739219	0.079783423
testdata_13	0.000782112	2.273200092	0.079688695
testdata_14	0.000754568	2.159689408	0.079545794
testdata_15	0.000757332	2.240266386	0.079637889
testdata_16	0.000764292	2.189311019	0.079677431
testdata_17	0.000784928	2.292042151	0.079751895
testdata_18	0.000424086	0.885957975	0.079732500
testdata_19	0.000607367	1.553225418	0.079362901

Fig. 5. Performance comparisons of three denoising models. 그림 5. 세 디노이징 모델의 성능 비교

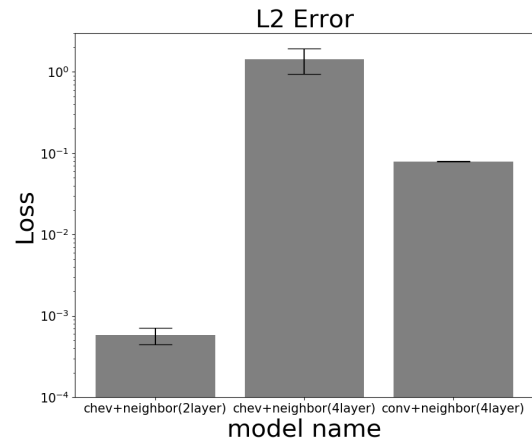


Fig. 6. Comparisons of error mean and standard deviation of the three denoising models.

그림 6. 세 디노이징 모델의 실험 오차 평균 및 표준편차 비교

마지막으로 그림 7은 본 논문에서 제안한 방법으로 3차원 메쉬 얼굴 데이터를 디노이징한 결과이다. 파란색은 원본 데이터와 차이가 매우 작다는 것을 의미하며, 색깔이 밝아질수록 오차가 크다는 것을 의미한다. convolution+neighbor 모델과 4개의 층을 이용하는 chebyshev+neighbor 모델의 경우 디노이징 결과가 원본 데이터와 많이 상이하며, 2개의 층을 이용하는 chebyshev+neighbor 모델의 경우에는 디노이징 결과가 원본 데이터와 거의 유사함을 확인할 수 있다.




Fig. 7. Qualitative comparisons of denoising results of the three denoising Models.

그림 7. 세 디노이징 모델의 디노이징 결과 질적 비교

V. 결론

본 논문에서는 3차원 메쉬 데이터의 특징들을 잘 추출할 수 있는 3차원 메쉬 디노이징 시스템을 소개하였다. 이를 위해 새로운 샘플링 연산을 정의하였으며, 컨볼루션 연산들을 오토인코더 모델에 추가하였다. 성능 평가를 위해, MPI-IS에서 제공하는 얼굴 데이터에 인공적인 노이즈를 추가해서 만든 데이터를 이용하여 모델을 학습시키고 성능을 평가하였다. 본 논문에서 제안한 시스템은 3차원 메쉬 데이터 디노이징에서 일반적인 컨볼루션 기반 모델보다 99.2% 더 나은 성능을 보였으며, 한 번도 학습되지 않은 데이터에 대해서도 잘 동작하였다. 본 논문에서는 인공적인 노이즈가 추가된 데이터만을 다루었으나, 이는 실제세계의 데이터에서 발생

하는 노이즈와는 다를 수 있다. 실제세계 데이터의 노이즈는 정해지지 않은 분포도를 가질 수 있으며, 고주파수의 형태가 아닐 수도 있다. 따라서, 정해지지 않은 형태의 자연적인 노이즈는 본 논문에서 제안 디노이징 필터가 걸러내지 못할 수 있다. 향후 연구로, 본 논문에서 제안한 방법들을 개선 보완하여, 실제세계 사물들로부터 키넥트와 같은 저가형 센서로 추출한 3차원 메쉬 데이터에 포함된 실제 노이즈를 제거하기 위한 필터링 기법들을 고안하고자 한다.

References

[1] G. Taubin, "A signal processing approach to fair surface design," In *SIGGRAPH*, pp.351-358, 1995. DOI: 10.1145/218380.218473

[2] M. Desbrun, M. Meyer, P. Schroöder, and A. H. Barr, "Implicit fairing of irregular meshes using diffusion and curvature flow," In *SIGGRAPH*, pp.317-324, 1999. DOI: 10.1145/311535.311576

[3] A. Nealen, T. Igarashi, O. Sorkine, and M. Alexa, "Laplacian mesh optimization," In *Proceedings of the 4th international conference on Computer graphics and interactive techniques in Australasia and Southeast Asia (GRAPHITE '06)*, pp.381-389, 2006. DOI: 10.1145/1174429.1174494

[4] U. Clarenz, U. Diewald, and M. Rumpf, "Anisotropic geometric diffusion in surface processing," In *Proc. of the conference on Visualization*, pp.397-405, 2000. DOI: 10.1109/VISUAL.2000.885721

[5] T. Tasdizen, R. Whitaker, P. Burchard, and S. Osher, "Geometric surface smoothing via anisotropic diffusion of normals," In *Proc. of the conference on Visualization*, pp.125-132 2002. DOI: 10.1109/VISUAL.2002.1183766

[6] C. L. Bajaj and G. Xu, "Anisotropic diffusion of surfaces and functions on surfaces," *ACM Trans. Graph.*, Vol.22, No.1, pp.4-32, 2003. DOI: 10.1145/588272.588276

[7] H. Yagou, Y. Ohtake, and A. Belyaev, "Mesh denoising via iterative alpha-trimming and nonlinear diffusion of normals with automatic thresholding," In *Computer Graphics International*, pp.28-33,

2003. DOI: 10.1109/CGI.2003.1214444

[8] K. Hildebrandt and K. Polthier, "Anisotropic filtering of non-linear surface features," *Comput. Graph. Forum (EG)*, Vol.23, No.3, pp.391-400, 2004. DOI: 10.1111/j.1467-8659.2004.00770.x

[9] T. R. Jones, F. Durand, and M. Desbrun, "Noniterative, feature-preserving mesh smoothing," *ACM Trans. Graph. (SIGGRAPH)*, Vol.22, No.3, pp.943-949, 2003. DOI: 10.1145/882262.882367

[10] S. Fleishman, I. Drori, and D. Cohen-Or, "Bilateral mesh denoising," *ACM Trans. Graph. (SIGGRAPH)*, Vol.22, No.3, pp.950-953, 2003. DOI: 0.1145/882262.882368

[11] H. Yagou, Y. Ohtake, and A. Belyaev, "Mesh smoothing via mean and median filtering applied to face normals," In *Geom. Model. and Proc.*, pp. 124-131, 2002. DOI: 10.1109/GMAP.2002.1027503

[12] Y. Shen and K. Barner, "Fuzzy vector median-based surface smoothing," *IEEE. T. Vis. Comput. Gr.*, 10, 3, pp.252-265, 2004. DOI: 10.1109/TVCG.2004.1272725

[13] H. Fan, Y. Yu, and Q. Peng, "Robust feature-preserving mesh denoising based on consistent subneighborhoods," *IEEE. T. Vis. Comput. Gr.*, 16, 2, pp.312-324, 2010. DOI: 10.1109/TVCG.2009.70

[14] X. Lu, Z. Deng, and W. Chen, "A robust scheme for feature-preserving mesh denoising," *IEEE. T. Vis. Comput. Gr.*, Vol.22, No.3, pp. 1181-1194, 2016. DOI: 10.1109/TVCG.2015.2500222

[15] M. Wei, J. Yu, W.-M. Pang, J. Wang, J. Qin, L. Liu, P.-A. Heng, "Bi-normal filtering for mesh denoising," *IEEE. T. Vis. Comput. Gr.*, Vol.21, No.1, pp.43-55, 2015. DOI: 10.1109/TVCG.2014.2326872

[16] A. Ranjan, T. Bolkart, S. Sanyal, M. J. Black, "Generating 3D Faces Using Convolutional Mesh Autoencoders," In *ECCV 2018*, pp.725-741, 2018.

BIOGRAPHY

Jihyun Roh (Member)



2014~ : BS student in Computer Science, Kangwon National University

Hyeonseung Im (Member)



2006 : BS degree in Computer Science, Yonsei University.

2012 : PhD degree in Computer Science and Engineering, Pohang University of Science and Technology (POSTECH).

2012~2014 : Postdoc, Université Paris-Sud, France.

2014~2015 : Postdoc, Inria, France.

2015~ : Assistant Professor in Department of Computer Science, Kangwon National University.

Jongmin Kim (Member)



2006 : BS degree in Electrical Engineering and Computer Science, KAIST.

2014 : PhD degree in Electrical Engineering and Computer Science, Seoul National University.

2015~2016 : Research Professor, Hanyang University.

2016~2017 : Mocap Researcher, Weta Digital, New Zealand.

2017~ : Assistant Professor in Department of Computer Science, Kangwon National University.