

令和3年度卒業論文

3D-SRGANにおける位相不変量
を考慮した形状改善と評価

指導教員 椋木 雅之

宮崎大学工学部 情報システム工学科

野村 淳也

概要

本論文では、3次元モデルの超解像を行う 3D-Super Resolution Generative Adversarial Networks (3D-SRGAN) に「位相不変量」の考え方を導入して、視覚的品質の改善を目指す。低解像度データから高解像度データを復元・生成する技術を超解像という。超解像を行う 3D-SRGAN の問題点として、正解データにはない誤った穴が生成され、本来繋がっている部分が途切れてしまう点や、従来の評価基準では視覚的品質を必ずしも反映していない点がある。この穴や途切れは位相幾何学において位相不変量として扱われている。位相不変量が異なる図形は本質的に異なる図形として扱われる。超解像処理においても、穴や途切れは視覚的品質に大きな影響を与える。そこで、本論文では 3D-SRGAN の超解像で位相不変を実現できるよう改良し、形状改善を目指す。具体的には、学習時の目的関数 (Loss 関数) の改良、学習後の後処理による穴や途切れの除去、評価基準への位相不変量の導入を行った。評価実験として、各改善手法について、改善前と後や、改善手法の異なる組み合わせによる超解像結果の比較を行った。結果として、それぞれの手法で形状の改善を確認できた。この結果から、Loss 関数を改良して学習を行い、その超解像結果にクロージングを行うことは、超解像 3次元モデルの誤った穴や連結成分の途切れを除去し、視覚的品質を向上させるための有効な手段であると示した。また、定量評価に位相不変量を用いることは 3次元モデルの視覚的品質を評価する際に適切であることも示した。

目次

1. はじめに	1
2. 3D-SRGAN による 3 次元モデルの超解像.....	2
2.1. 超解像の定義	2
2.2. 3D-SRGAN による 3 次元モデルの超解像.....	3
2.3. 3D-SRGAN の学習.....	4
2.4. 3D-SRGAN による超解像形状の問題点	5
3. 位相不変量を考慮した形状改善.....	6
3.1. 位相不変量.....	6
3.2. 形状改善へのアプローチ	7
3.3. Loss 関数の変更.....	7
3.4. 後処理による形状改善.....	8
3.4.1. クロージング	8
3.4.2. 2 値化閾値の変更	9
3.5. 形状改善の評価基準	10
4. 実験.....	11
4.1. 実験設定	11
4.2. 学習用モデルを限定することによる学習への影響.....	12
4.2.1. 実験手法.....	12
4.2.2. 実験結果・考察.....	13
4.3. Loss 関数の変更による形状改善の検証	17
4.3.1. 実験手法.....	17
4.3.2. 実験結果・考察.....	17
4.4. 後処理による形状改善の検証.....	21
4.4.1. 実験手法.....	21

4.4.2. 実験結果・考察.....	22
5. おわりに	26
謝辞	27
参考文献	28

1. はじめに

近年、機械設計において 3D-CAD や 3D プリンターなど 3 次元モデルを利用する機会が多くなっている。2 次元の図面と比べて 3 次元モデルを利用すると、誰でも簡単に物体の形状を把握できる、物体の体積、表面積、重量、重心といった幾何情報を簡単に取得できる、複雑な形状の設計が容易であるなどの利点がある。

3 次元モデルの表現方法の 1 つに、ボクセルと呼ばれる立方体を積み重ねて 3 次元モデルを表現するボクセル表現がある。このボクセル表現では、3 次元空間の i 行 j 列 k 段の画素における濃度値 f_{ijk} を 0、1 で 2 値化し、ボクセルが存在しているかどうかを表現している[1]。多数のボクセルを積み重ねることにより精細な 3 次元モデルを作成することができるが、粗い 3 次元モデルと比較するとボクセルを積み重ねる手間が増える。粗い 3 次元モデルから精細な 3 次元モデルを生成することができればこの手間が軽減できる。このような粗いデータから精細なデータを生成する処理を超解像と呼ぶ。

3 次元モデルの超解像の手法として 3D-Super Resolution Generative Adversarial Networks (3D-SRGAN)[2]がある。3D-SRGAN は、2 次元画像の超解像に有効な Super Resolution Generative Adversarial Networks(SRGAN)[3]の超解像の対象を、ボクセル表現の 3 次元モデルに拡張した手法である。

この手法は SRGAN と同じく Generative Adversarial Network(敵対的学習: GAN)[4]を用いている。GAN は Generator と Discriminator の 2 つのネットワークが互いに学習を行うことで性能を高めていく。これにより、粗い 3 次元モデルを与えることで高解像度 3 次元モデルと見分けがつかないような 3 次元モデルを作り出すことが出来る。しかし、現状の 3D-SRGAN では超解像 3 次元モデルに誤った穴が開いたり、本来繋がっている部分が途切れたりするという問題がある。このような穴や途切れは位相幾何学において 3 次元モデルを分類

するのに重要な要素で、位相不変量と呼ばれる。位相不変量が異なる 3 次元モデルは本質的に異なる図形として分類される。超解像処理においても穴や途切れは、視覚的品質に大きな影響を与える。そこで、本研究では超解像処理の結果において、位相不変量が適正になるよう処理を行い、形状を改善する。具体的には、超解像時の穴を塞ぐために穴が開きにくいよう学習時の目的関数(Loss 関数)を改良する。さらに学習後に後処理を行い穴や連結成分の途切れを除去する。また、評価基準に位相不変量を導入して評価を行う。

以下、2 章で 3D-SRGAN について述べ、3 章で形状改善のための提案手法について述べる。そして 4 章で提案手法が超解像 3 次元モデルの形状改善に有効であることを実験により実証する。最後に 5 章で結論を述べる。

2. 3D-SRGAN による 3 次元モデルの超解像

2.1. 超解像の定義

超解像とは低解像度のデータから高解像度のデータを生成・補完する技術である。解像度とは、データを構成する単位が一定の間にどれだけ存在しているかを表している。本研究では超解像の対象として、ボクセル表現の 3 次元モデルを扱う。また、超解像によって生成された高解像度データを超解像 3 次元モデルと呼ぶ。

超解像は、低解像度データから高解像度データを生成する技術であるが、この問題は不良設定問題[5]である。不良設定問題とは、解を求めるために必要な情報が一部欠けている問題のことである。低解像度データから高解像度データに変換するためには、低解像度データには存在しない部分のデータを生成する必要がある。この低解像度データに存在しない部分には無数の生成パターンがあり得る。

そのため無数のパターンから適切なパターンを選択できる手法を導入することが必要である。

2.2. 3D-SRGAN による 3 次元モデルの超解像 [6]

3D-SRGAN は深層学習を用いた 3 次元モデル超解像の手法であり、2 次元画像の超解像で視覚的品質の向上に有効性が知られている SRGAN を、3 次元モデルが扱えるように拡張したものである。

3D-SRGAN は Generator と Discriminator の 2 つのネットワークで構成されている (図 1)。入出力データとしてボクセル表現の 3 次元モデルを扱う。学習用データにはペアとなる低解像度と高解像度の 3 次元モデルを使用する。Generator は低解像度 3 次元モデルから超解像 3 次元モデルを生成し、Discriminator は入力された 3 次元モデルが Generator によって生成された 3 次元モデルなのか学習用データの高解像度 3 次元モデルなのかを識別する。この 2 つは敵対関係にあり、Generator は Discriminator を騙すように学習用データと似た 3 次元モデルを生成することが、Discriminator は生成された 3 次元モデルと学習用データとを見分けることが目的となっている。3D-SRGAN の最終的な目的は、Discriminator が識別できないような 3 次元モデルを Generator が生成できることである。また、学習の結果得られた Generator が生成モデルとなる。

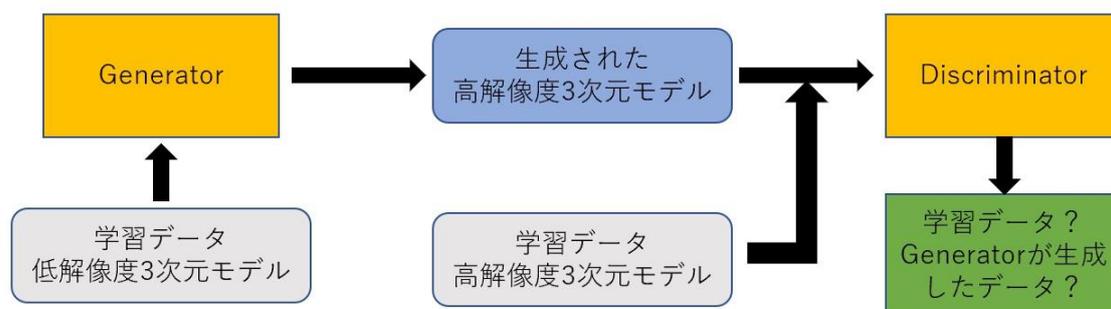


図 1 GAN の構成 [6]

2.3. 3D-SRGAN の学習

超解像生成モデルとなる Generator の学習では、Loss 関数 l_G^{3DSR} の値が小さくなるようにネットワークのパラメータを逐次更新する収束計算を行う。

Generator の Loss 関数 l_G^{3DSR} は式(1)で表現する。

$$l_G^{3DSR} = (l_{Con}^{3DSR} + \lambda l_{Gen}^{3DSR}) \quad (1)$$

$$l_{con}^{3DSR} = \sum_{m=1}^m \frac{1}{r^3 W H D} \sum_{x=1}^{rW} \sum_{y=1}^{rH} \sum_{z=1}^{rD} (I_{x,y,z}^{HR} - G(I^{LR})_{x,y,z})^2 \quad (2)$$

$$l_{Gen}^{3DSR} = \sum_{m=1}^m -\log D(G(I^{LR})) \quad (3)$$

式(1)の l_{Con}^{3DSR} は Content Loss、 l_{Gen}^{3DSR} は Adversarial Loss を表す。

Content Loss は式(2) で計算され、 r 、 W 、 H 、 D はそれぞれ 3次元モデルの拡大倍率、3次元空間の幅、高さ、奥行きを表している。式(2)では学習用データの高解像度 3次元モデル I^{HR} と Generator が生成した超解像 3次元モデル $G(I^{LR})$ の平均二乗誤差を計算している。学習において低解像度データが入力された時、Content Loss では元のデータの見た目のある程度そのままに別の操作を加えることができるため、超解像後に元のデータから見た目が大きく変化することがない。

Adversarial Loss は式(3)で計算される。 $G(I^{LR})$ は Generator の出力結果、 $D(x)$ は Discriminator の識別結果を表している。式(3)では Discriminator が学習用データと見分けがつかないように学習をする。これらを係数 λ で調整し足し合わせて超解像を行っている。通常 $\lambda = 10^{-3}$ を使用する。

2.4. 3D-SRGAN による超解像形状の問題点

3D-SRGAN では、Discriminator を騙せるように Generator を学習することで生成データのボクセル分布を本物データに近づけていく。そのために Loss 関数が小さくなるように学習を更新する。この Loss 関数には高解像度 3 次元モデルと超解像 3 次元モデルのボクセル毎の値の一致と Discriminator の識別の結果のみを用いている。そのため、従来の超解像 3 次元モデルでは高解像度にはない誤った穴や空洞が生成される、本来繋がっている部分が途中で途切れてしまうといった問題がある (図 2)。この穴や途切れは、視覚的品质に大きく影響する。従来の定量評価[6]では、ボクセル毎の値の一致を評価しており、穴や途切れは考慮していなかった。そのため、視覚的品质を定量評価の結果が必ずしも反映していないという問題もあった。

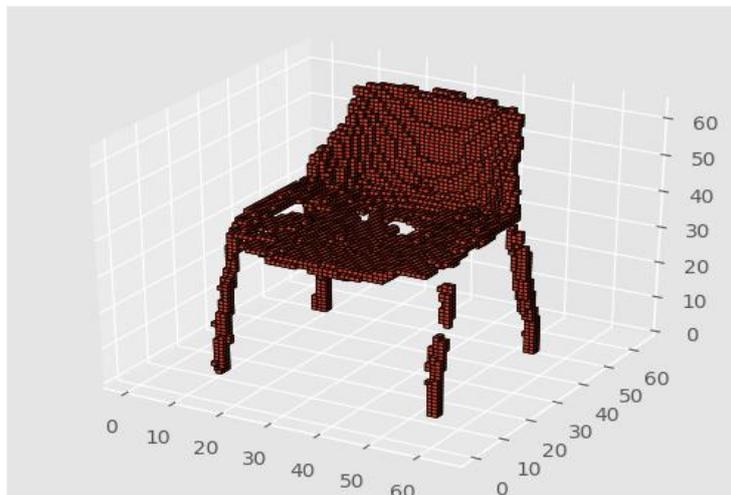


図 2 従来の超解像結果

3. 位相不変量を考慮した形状改善

3.1. 位相不変量

位相不変量とは、位相幾何学で図形を解析し分類する際に用いられる重要な量である[7][8]。位相幾何学とは図形の長さ、大きさなどを無視し、図形に伸び縮みのみの変形（連続変形）をさせても保たれる不変な性質、量について研究する幾何学である。不変な性質は位相的性質と呼ばれ、図形の連結性、コンパクト性などがある。不変な量は位相不変量と呼ばれる。

本論文では位相不変量の中の連結成分、穴、空洞の数を使用する。連結成分とは、3次元空間内に存在するひと繋がり図形のかたまりである。空洞は連結成分内部に存在し、連結成分の外周に接していない空間のことである。穴の数は、図形の形状によっては直感的にわかりづらい場合がある。だが、すべての有限な大きさを持つ図形は連続変形によって図3のような穴の数が分かりやすい形状に変形できる。

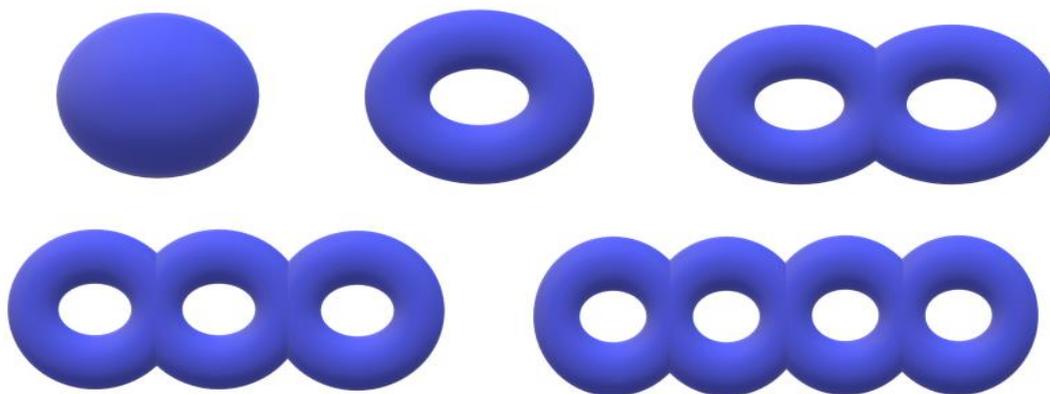


図3 穴の数が分かりやすい形状

3.2. 形状改善へのアプローチ

2.4 節で示したように、従来の 3D-SRGAN で生成した 3 次元超解像モデルでは、高解像度 3 次元モデルにはない誤った穴や空洞、途切れが多い。

超解像モデルの形状が悪い原因としては、学習の際に Loss 関数が隣接するボクセルとの繋がりを考慮していない、ボクセル生成の際の 2 値化閾値が高く、生成されるボクセルの総数が少ないことが考えられる。そのため、形状改善へのアプローチとして、高解像度 3 次元モデルにはない穴、連結成分の途切れができないようにする。そのためのアイデアとして、

- ① 学習時の Loss 関数に 3 次元モデル表面の差を計算する式を追加する
- ② 超解像結果にクロージングを行い、小さな穴や途切れた部分を埋める
- ③ ボクセル生成時の 2 値化閾値を下げ、生成するボクセル総数を増やすを行う。

3.3. Loss 関数の変更

3D-SRGAN の学習において、Loss 関数 l_G^{3DSR} では 3 次元モデルのボクセルの連続性を考慮していない。3 次元モデルの表面の連続性を考慮して学習することで、より表面が高解像度 3 次元モデルに近いものを生成できる。3 次元モデル表面が高解像度 3 次元モデルと一致していれば外見上の差はないので、超解像 3 次元モデルの形状改善を期待できる。そのために、Content Loss を高解像度モデルとの誤差に加えて表面の連続性も考慮するように変更する。Content Loss の計算式を従来の式(2)から式(4)に変更する。

$$l_{con}^{3DSR} = \sum_{m=1}^m \frac{1}{r^3 WHD} \sum_{x=1}^{rW} \sum_{y=1}^{rH} \sum_{z=1}^{rD} (I_{x,y,z}^{HR} - G(I^{LR})_{x,y,z})^2 + \frac{1}{r^3 WHD} \sum \left(\nabla I^{HR} - \nabla G(I^{LR}) \right) \quad (4)$$

$$\nabla I = \left(\frac{\partial I}{\partial x}, \quad \frac{\partial I}{\partial y}, \quad \frac{\partial I}{\partial z} \right)$$

∇ は勾配を表しており、x、y、z軸それぞれの偏微分を計算することで3次元モデルのエッジ部分（表面）を得ている。

式(4)では高解像度モデルと超解像3次元モデルの表面の平均二乗誤差を計算している。そのため式(4)の計算結果が小さいほど超解像3次元モデルの表面の連続性（表面形状）が高解像度モデルと一致する。

3.4. 後処理による形状改善

3.4.1. クロージング

クロージングとは、2値データに対して膨張・収縮処理を複数回行うことでノイズを除去する処理である。形状を整える処理であるモフォロジー処理の1つで、2値データのノイズを除去する有効な手段である。

膨張処理は、ボクセル値1をもつボクセル（1-ボクセル）が存在する領域を増やす処理である。処理としては3次元空間内の各ボクセルに対して、注目ボクセルの近傍に1-ボクセルが1つでも存在すれば注目ボクセルを1-ボクセルに置き換える。膨張処理を行うことで、隣り合った箇所を繋げることが出来るが、繋げたい部分以外も広がるため、2値化した部分よりも太く大きな領域になってしまう。

収縮処理は、膨張処理と逆に 1-ボクセルが存在する領域を縮める処理である。処理としては 3 次元空間内の各ボクセルに対して、注目ボクセルの近傍に空白のボクセル (0-ボクセル) が 1 つでも存在すれば、注目ボクセルを 0-ボクセルに置き換える。収縮処理を行うことでノイズを消したり、太く大きくなった領域を縮めたりできる。クロージングでは 2 値化領域を膨張した回数分収縮することで、領域の大きさを変えずにノイズや小さな穴などを除去する。例えば膨張・収縮処理をそれぞれ 3 回行う場合は元の 2 値データに膨張処理を 3 回連続で行い、その後収縮処理を 3 回連続で行う。

3D-SRGAN による超解像において、誤った穴や連結成分の途切れは学習方法を改良してもすべてなくすことは難しい。そこで、超解像結果に対してクロージングを行うことで小さな穴や空洞、連結成分の途切れの除去を期待できる。収縮・膨張の回数を増やすほど、除去出来る穴や空洞、切れ目の大きさは大きくなる。しかし、回数を増やしすぎると繋がってはならない部分まで繋がってしまう可能性が高くなるという問題がある。そのため、収縮・膨張の回数は適切に定める必要がある。

3.4.2. 2 値化閾値の変更

3D-SRGAN では、ボクセル生成時に Generator が出力した 0 以上 1 以下の各値を偶数丸め (最も近い整数に丸める、ただし 0.5 は最も近い偶数に丸める) することで 0、1 に 2 値化している。よって、2 値化閾値は 0.5 である。2 値化閾値を小さくすることで、総ボクセル数が増えるので高解像度 3 次元モデルにはない穴や空洞、連結成分の途切れを除去することが期待できる。一方で間違ったボクセルが増える、超解像モデル全体が大きくなってしまったといった問題点が考えられる。

3.5. 形状改善の評価基準

従来の評価[6]は、超解像 3 次元モデルを目視で確認し評価する定性評価と、高解像度モデルと超解像 3 次元モデルのボクセル毎の値が異なるものの数を用いる定量評価を評価基準として超解像 3 次元モデルの評価を行っていた。しかし、定量評価についてこの評価基準では超解像 3 次元モデルのボクセルの連続性を考慮できていない。そのため定量評価の結果が視覚的品質の評価と必ずしも一致しない。

そこで、従来の定量評価の評価基準に加えて 3.1 節で示した連結成分数、穴の個数、空洞数を加えることで、位相幾何学の観点から定量評価を行う。

連結成分の数は、3 次元空間内の連結成分にラベル付けを行い、そのラベルの個数から求められる。空洞の数は、超解像 3 次元モデルの各ボクセルで 0、1 の値を入れ替えて連結成分を求め、ボクセル値入れ替え前に求めた連結成分の外周と接していないものの数で求める。穴の数はオイラー数を使って求める。

オイラー数は次式で定義される。

$$(\text{オイラー数}) = (\text{連結成分数}) + (\text{空洞の数}) - (\text{穴の数})$$

また、ボクセルモデルに対しては、ボクセルデータから次式で計算できる[7]。

$$(\text{オイラー数}) = (\text{頂点の総数}) - (\text{辺の総数}) + (\text{面の総数}) - (\text{体の総数}) \quad (5)$$

オイラー数を式 (5) で求める。連結成分数、空洞数は上記の方法で求められるので、次式により穴の数を求める。

$$(\text{穴の数}) = (\text{連結成分数}) + (\text{空洞数}) - (\text{オイラー数})$$

4. 実験

4.1. 実験設定

学習、評価に用いる 3 次元モデルとして、データセット ModelNet10[9]のイスのクラスを使用した。イスのクラスでは学習用データが 889 個、テスト(評価)用データが 100 個用意されている。学習用データ、評価用データともにボクセル数が $16 \times 16 \times 16$ の低解像度 3 次元モデルと $64 \times 64 \times 64$ の高解像度 3 次元モデルのペアに変換し、モデル内の空洞をボクセルで埋めた。そのため、高解像度 3 次元モデル(正解)では、すべて連結成分は 1、空洞の数は 0 である。穴の数は 0~84 である。学習回数はバッチサイズを 4、epoch 数を 200 とした。

評価方法として、主観的な品質を比較するために以下の評価項目①から③について定性評価を行う。良いものを○、普通のを△、悪いものを×とし、3段階で評価する。

① 3次元モデルの形状の滑らかさ(滑)

② 3次元モデルの連結成分の連続性(連)

③ 3次元モデルの表面の連続性(表)

また、以下の評価項目①から④について定量評価も行った。各評価項目について値が小さい方が良い性能とする。

① 高解像度モデルと超解像 3 次元モデルの連結成分数の差(連)

② 高解像度モデルと超解像 3 次元モデルの穴の総数の差(穴)

③ 高解像度モデルと超解像 3 次元モデルの空洞の総数の差(空)

④ 高解像度モデルと超解像 3 次元モデルの同じ位置にあるボクセル同士の保持する値(ボクセル値)が異なるものの数(値)

4.2. 学習用モデルを限定することによる学習への影響

3次元モデルの超解像において、高解像度3次元モデルには存在した穴が低解像度3次元モデルではつぶれてしまっている場合がある。この場合、超解像時に繋がっている部分に新たな穴を開ける必要があるため、低解像度3次元モデルにはない穴を開けるように学習する。その結果、3D-SRGANが本来穴のない部分に穴を開けるように学習してしまい、超解像3次元モデルの視覚的品質が悪くなっている可能性がある。学習用データの低/高解像度ペアの位相がすべて同じならば誤った穴や連結成分の途切れがなくなることが期待できる。

3D-SRGANにおける超解像3次元モデルの形状改善についての事前実験として、学習において学習用の低/高解像度モデルの位相の違いが学習結果にどの程度影響を与えるのかを検証する。

4.2.1. 実験手法

本実験では、学習用データを低/高解像度ペアの位相の差で限定して学習を行うことで、学習用データの位相の違いによる超解像結果への影響を検証する。

学習用データの位相は3次元モデルの連結成分、穴、空洞の総数で考える。本実験において学習用データの空洞はすべて埋めており、連結成分はすべて1のため、位相の違いは穴の総数のみを考えればよい。3D-SRGANの学習用データの低/高解像度ペアで、位相が同じもの（同位相）のみで学習した場合、位相が違うもの（異位相）のみの場合、すべてのモデルを使って学習した場合の3パターンでの超解像3次元モデルを比較し、視覚的品質に違いがあるのかを検証した。

学習用データ 889 個の内訳は、同位相が 418 個、異位相が 471 個である。テスト用データ 100 個の内訳は、同位相が 39 個、異位相が 61 個である。

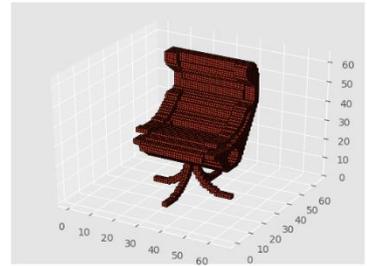
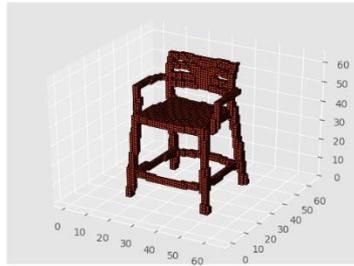
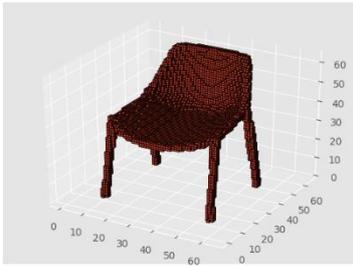
4.2.2. 実験結果・考察

図 4 に 3 種類のイスに対する超解像結果を示す。上から順に高解像度 3 次元モデル、学習用データをすべて使用して学習を行った場合、同位相のみで学習を行った場合、異位相のみで学習を行った場合の超解像 3 次元モデルである。各列はイスの種類に対応している。左から順にモデル 1、モデル 2、モデル 3 と呼ぶ。それぞれの 3 次元モデルの低/高解像度ペアの位相は、モデル 1 が同位相、モデル 2、3 が異位相である。また、表 1 に図 4 に示した超解像結果の定性評価結果を、表 2 に図 4 に示した超解像結果の定量評価結果を、表 3 にテスト用データ 100 個全体における超解像結果の平均の定量評価結果を示す。表 2、3 では最も評価が高いものを太字にしている。

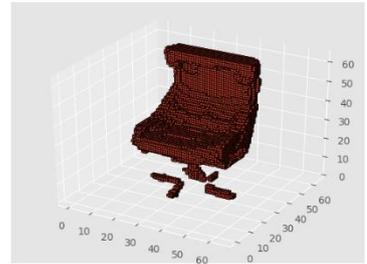
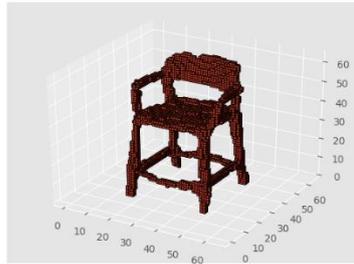
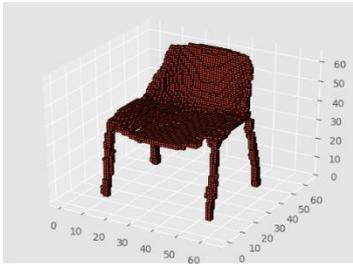
表 1 より、学習用データをすべて使用した場合と同位相のみを使用した場合の超解像 3 次元モデルでは、定性評価での違いはほぼ見られない。異位相のみを使用した場合では、他の場合に比べ表面のへこみが目立つので形状の滑らかさについての定性評価は低い。加えて、異位相のみを使用した場合では意図しない穴や足などの細い部分が途切れてしまうといった問題が多く発生しており、連結成分・表面の連続性についての定性評価も低い。この結果より、本実験の超解像において学習用データをすべて使用した場合と同位相のみで学習を行った場合で大きな差はみられなかった。

表 2、3 の定量評価でも定性評価と同じように異位相のみを使用した場合が最も評価が低く、他の 2 つの場合には大きな差は見られなかった。ただし、ボクセル値の異なるものの数については定性評価ほどの差がなかった。ボクセル値の異なるものの数については、拡張元である SRGAN で定量評価の結果が必ずしも視覚的品質の良し悪しに対応しないと指摘されている。

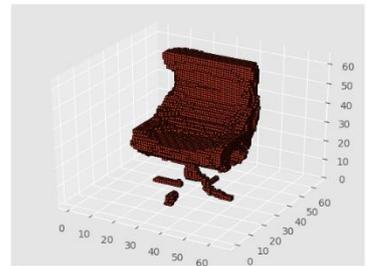
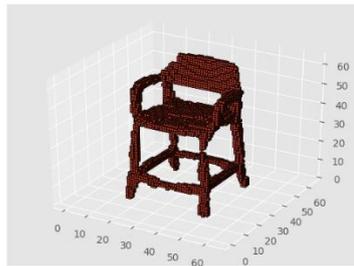
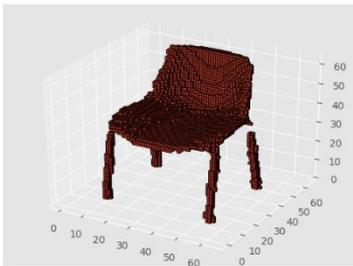
以上のことより 3D-SRGAN を用いた 3 次元モデルの超解像における学習で学習データを限定することは超解像結果の形状改善に大きな影響はないことが分かった。そのため、以降の実験では学習データを限定せずに学習を行った結果を使用する。



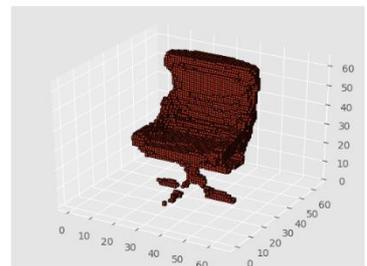
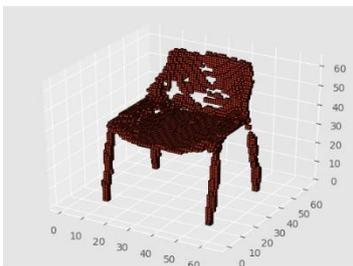
高解像度 3 次元モデル



学習用モデルすべて使用



同位相のみ



異位相のみ

モデル 1

モデル 2

モデル 3

図 4 3 次元モデルの超解像結果

表1 3次元モデルの超解像結果に対する定性評価

評価項目	モデル1			モデル2			モデル3		
	滑	連	表	滑	連	表	滑	連	表
すべて使用	○	○	○	○	○	○	△	×	○
同位相のみ	○	△	○	○	○	○	△	×	○
異位相のみ	×	△	×	×	×	△	△	×	△

表2 3次元モデルの超解像結果に対する定量評価

評価項目	モデル1				モデル2				モデル3			
	連	穴	空	値	連	穴	空	値	連	穴	空	値
すべて使用	0	35	0	2418	2	8	0	3093	5	9	0	7535
同位相のみ	3	6	0	2796	0	0	0	3344	5	8	4	7508
異位相のみ	5	50	0	2848	4	3	0	3274	12	14	6	8194

表3 3次元モデルの超解像結果全体に対する定量評価

評価項目	テスト用モデル全体の平均			
	連	穴	空	値
すべて使用	2.5	8.3	2.3	6569.9
同位相のみ	4.7	10.9	0.8	8633.6
異位相のみ	12	23.9	2.3	10247.3

4.3. Loss 関数の変更による形状改善の検証

3D-SRGAN による 3 次元モデルの超解像において、Content Loss では学習用データと超解像 3 次元モデルの平均二乗誤差を計算している。この場合、Content Loss はボクセル毎に値が違うものの数のみを計算しているため、学習用データと同じ場所にボクセルを生成しようと学習する。その結果、生成すべきボクセルを少しでも生成できなかった場合に、その部分が穴や連結成分の途切れとになってしまっている可能性がある。学習用データの表面を強調して学習を行うことで、生成するボクセルの位置が多少ずれても誤った穴や途切れができにくくなることを期待できる。

この実験では、3D-SRGAN の学習における Content Loss においてモデルのエッジ部分の差を考慮するように変更することで超解像 3 次元モデルの誤った穴や連結成分の途切れがなくなるかの検証を行う。

4.3.1. 実験手法

本実験では従来の Loss 関数に対して 3.3 節で示した変更を行い、比較実験を行った。比較対象として Loss 関数を変更することによる影響を検証するために Loss 関数を変更していない場合と、3 次元モデルの表面のみを使用して学習を行った場合との違いを検証するために学習用データの内部を空洞にし、表面のみでの実験を行った。学習用データを空洞にした場合の実験では、表面のみを使用したことによる影響を見るために Loss 関数は変更していない状態とする

4.3.2. 実験結果・考察

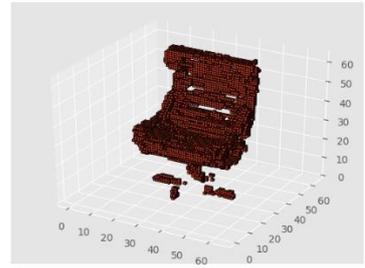
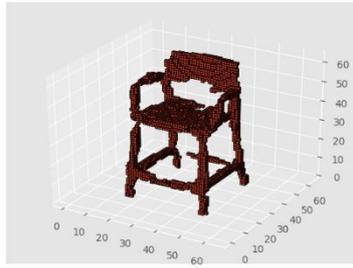
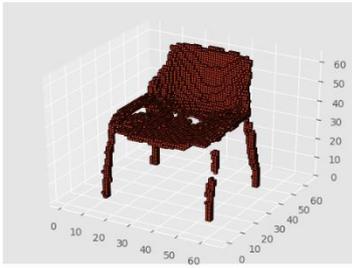
図 5 に 3 種類のイスに対する超解像結果を示す。上から順に学習用データ内部を空洞にして Loss 関数を変更していない場合、Loss 関数を変更していない場

合、Loss 関数を変更した場合の超解像 3 次元モデルである。各列はイスの種類に対応している。左から順にモデル 1、モデル 2、モデル 3 とする。また、表 4 に図 5 に示した超解像結果の定性評価結果を、表 5 に図 5 に示した超解像結果の定量評価結果を、表 6 にテスト用データ 100 個全体における超解像結果の平均の定量評価結果を示す。表 5、6 では最も評価が高いものを太字にしている。

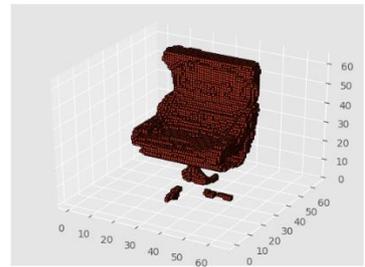
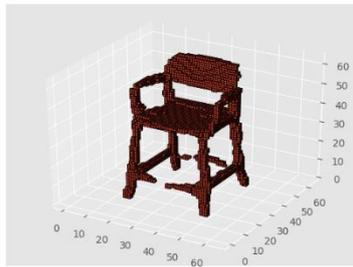
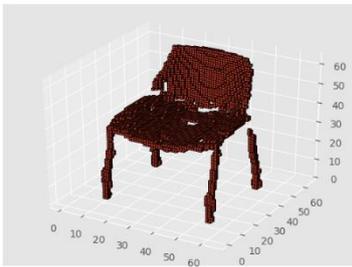
表 5 より、Loss 関数を変更した場合が全ての項目に対する定性評価で最も評価が高い。Loss 関数を変更していない場合は、Loss 関数を変更した場合に比べて表面のへこみが目立つので形状の滑らかさについての定性評価は低い。加えて誤った穴や、足などの細い部分が途切れてしまうといった問題が多く発生しており、連結成分・表面の連続性についての定性評価も低い。学習用データの内部を空洞にした場合は Loss 関数を変更していない場合よりもさらに 3 次元モデル表面のへこみや誤った穴、連結成分の途切れが多く発生していたので各評価項目に対する定性評価は最も低い。この結果より、本実験において学習用データの内部はボクセルで埋めた方が、Loss 関数は超解像 3 次元モデルの表面を考慮するよう変更する方がよりよい結果を出せた。

表 5、6 の定量評価でも最良の結果は、Loss 関数を変更した場合になっている。空洞の数ではすべての学習用データを用いた場合の評価が悪くなっているが、空洞は定性評価には影響を与えないので超解像結果の形状の良し悪しに対応するものではないと考える。

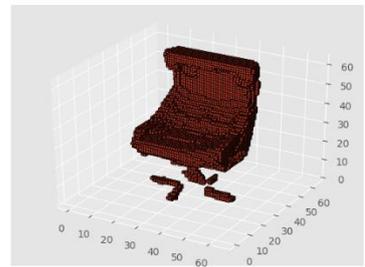
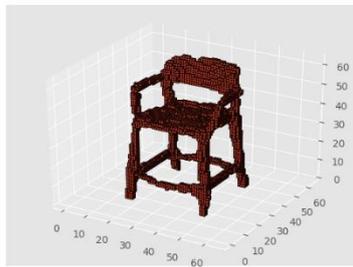
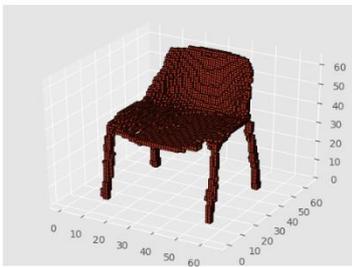
以上のことより、3D-SRGAN を用いた 3 次元モデルの超解像における学習において、Loss 関数を超解像 3 次元モデルの表面を考慮するよう変更することは超解像結果の形状改善に有効であることが分かった。



学習用モデル内部空洞、Loss 関数変更なし



Loss 関数変更なし



Loss 関数変更あり

モデル 1

モデル 2

モデル 3

図 5 3次元モデルの超解像結果

表 4 3次元モデルの超解像結果に対する定性評価

評価項目	モデル 1			モデル 2			モデル 3		
	滑	連	表	滑	連	表	滑	連	表
学習用モデル内部空洞	×	△	×	×	△	△	×	×	×
Loss 関数変更なし	×	△	×	△	△	○	△	×	△
Loss 関数変更	○	○	○	○	○	○	△	×	△

表 5 3次元モデルの超解像結果に対する定量評価

評価項目	モデル 1				モデル 2				モデル 3			
	連	穴	空	値	連	穴	空	値	連	穴	空	値
学習用モデル内部空洞	5	41	0	2721	12	7	0	3993	30	79	1	11337
Loss 関数変更なし	4	33	0	2804	2	7	0	3164	5	6	0	7844
Loss 関数の変更	0	35	0	2418	2	8	0	3093	5	9	0	7535

表 6 3次元モデルの超解像結果全体に対する定量評価

評価項目	テスト用モデル全体の平均			
	連	穴	空	値
学習用モデル内部空洞	19.1	64.6	0.6	11230.9
Loss 関数変更なし	4.8	13.5	0.7	8447.1
Loss 関数の変更	2.5	8.3	2.3	6569.9

4.4. 後処理による形状改善の検証

3次元モデルの超解像において、学習が上手くいったとしても誤った穴や連結成分の途切れをすべてなくすことはできない。そのため、学習方法の改善による超解像3次元モデルの形状改善には限界がある。学習後の超解像結果に後処理を行うことで、学習の改善では除去しきれない穴や途切れを除去することを期待できる。

この実験では、ボクセル生成後の後処理を行うことによる形状改善の有効性を検証し、3次元モデルの超解像における後処理の必要性を考察する。

4.4.1. 実験手法

3D-SRGANにおける学習後の後処理として、クロージングと2値化閾値の変更を行った。後処理は4.3節の実験の中の、Loss関数を変更せず学習を行った結果に対して行い、クロージングについてはLoss関数を変更して学習を行った結果にも行い、比較対象とした。

クロージングは収縮、膨張をそれぞれ3回ずつ、2値化閾値の変更は0.5を閾値として閾値を超える場合は1、閾値以下の場合は0としていたものを、閾値0.3に変更して超解像結果を比較し、誤った穴や連結成分の途切れがなくなったかを検証した。

定量評価については後処理によって1-ボクセルが増える傾向を評価するために4.1節の4つの評価基準に加えて

⑤ 超解像3次元モデルのボクセル総数－高解像度モデルのボクセル総数（数）

も評価基準に追加した。⑤では、符号が+であればテスト用データよりも総ボクセル数が多く、-であれば総ボクセル数が少ない。

4.4.2. 実験結果・考察

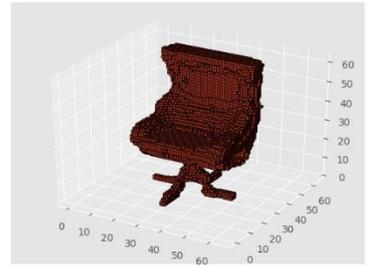
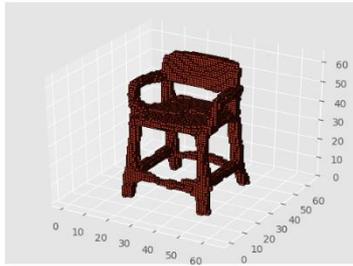
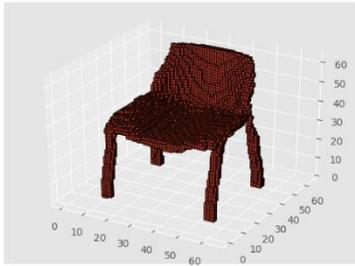
図 6 に 3 種類のイスに対する超解像結果を示す。上から順に 2 値化閾値の変更を行った場合、Loss 関数を変更せずクロージングを行った場合、Loss 関数を変更し、クロージングを行った場合の超解像 3 次元モデルである。各列はイスの種類に対応している。左から順にモデル 1、モデル 2、モデル 3 とする。また、表 7 に図 6 に示した超解像結果の定性評価結果を、表 8 に図 6 に示した超解像結果の定量評価結果を、表 9 にテスト用データ 100 個全体における超解像結果の平均の定量評価結果を示す。表 8、9 では最も評価が高いものを太字にしている。

表 8 より、2 値化閾値を変更した場合が全ての項目に対する定性評価で最も評価が高い。Loss 関数を変更していないものにクロージングを行った場合では、2 値化閾値を変更した場合に比べて、表面のへこみが目立つので形状の滑らかさについての定性評価は低い。加えて、意図しない穴や足などの細かい部分が途切れてしまうといった問題が多く発生しており、連結成分・表面の連続性についての定性評価も低い。Loss 関数を変更したものにクロージングを行った場合は、2 値化閾値を変更した場合と比べると劣るが、Loss 関数を変更していないものにクロージングを行った場合と比べると評価は高い。この結果について、クロージングによる形状改善は存在する穴や空洞が小さければ有効なので、クロージング前の超解像結果の形状によるものであると考える。

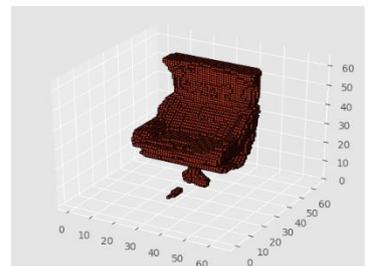
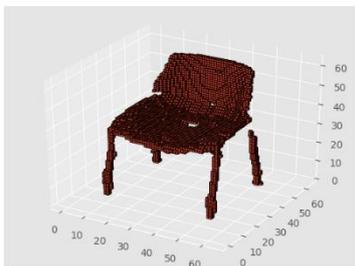
表 8、9 の定量評価では、定性評価と異なり Loss 関数を変更したものにクロージングを行った場合が最も評価が高いものが多い。この結果は、2 値化閾値を変更したものは検出したボクセル数が多いので相対的に小さな穴やボクセル値が異なる部分が多くなったためだと考えられる。

以上のことより、3D-SRGAN を用いた 3 次元モデルの超解像においてクロージングの処理、ボクセル生成時の 2 値化閾値を変更し、検出するボクセル数を増やすことは超解像結果の形状改善に有効であることが分かった。しかし、ボクセ

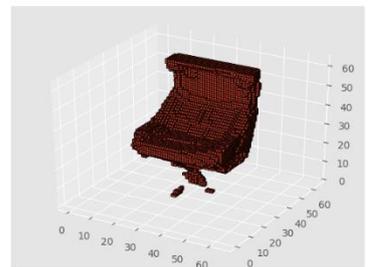
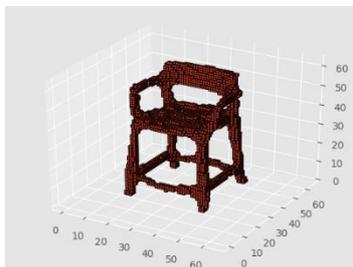
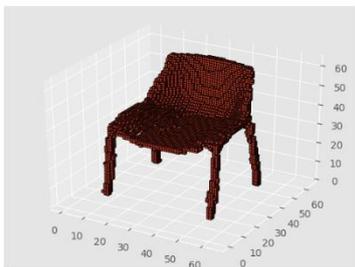
ル総数を増やすと 3 次元モデルが太く、大きくなってしまふ。そのため、超解像 3 次元モデルの大きさが重要な場合や細かいパーツが多いものについては必ずしも最善とは言えない。また、クロージングはクロージング前の超解像 3 次元モデルの形状が重要なので、Loss 関数を変更するなど他の形状改善の方法と組み合わせることでより効果を発揮できると考える。



2 値化閾値変更



クロージング、Loss 関数変更なし



クロージング、Loss 関数変更あり

モデル 1

モデル 2

モデル 3

図 6 3次元モデルの超解像結果

表7 3次元モデルの超解像結果に対する定性評価

評価項目	モデル1			モデル2			モデル3		
	滑	連	表	滑	連	表	滑	連	表
2値化閾値変更	○	○	○	○	○	○	△	△	○
クロージング	△	△	△	△	△	○	△	×	△
Loss関数変更+ クロージング	○	○	○	○	○	○	△	×	△

表8 3次元モデルの超解像結果に対する定量評価

評価項目	モデル1					モデル2					モデル3				
	連	穴	空	値	数	連	穴	空	値	数	連	穴	空	値	数
2値化閾値変更	1	1	0	4038	+3228	0	6	0	4361	+3267	1	2	0	8638	+4372
クロージング	3	37	0	2905	+91	2	7	0	3363	-105	2	7	0	7703	+1465
Loss関数変更+ クロージング	0	28	0	2640	+508	0	6	0	3189	+201	2	1	0	7833	+1841

表9 3次元モデルの超解像結果全体に対する定量評価

評価項目	テスト用モデル全体の平均				
	連	穴	空	値	数
2値化閾値変更	1.4	8.74	0.58	8290.6	+240.3
クロージング	4	9.38	0	8466.3	-4562.7
Loss関数変更+ クロージング	1.69	5.26	0	7035.5	-30

5. おわりに

本研究では 3D-SRGAN による 3 次元モデルの超解像において、超解像時の誤った穴を塞ぐために、穴が開きにくいよう学習時の目的関数(Loss 関数)を改良し、さらに学習後に後処理を行って穴や途切れを除去することで超解像結果の形状改善を行った。また、それぞれの変更点について変更前と変更後、異なる変更点同士での超解像結果を比較し、超解像 3 次元モデルの形状改善にどの程度有効であるかを評価した。結果として、それぞれの手法で形状の改善を確認できた。この結果から、Loss 関数を改良して学習を行い、その超解像結果にクロージングを行うことは、超解像 3 次元モデルの誤った穴や連結成分の途切れを除去し、視覚的品質を向上させるための非常に有効な手段であるとわかった。また、定量評価に位相不変量を用いることは 3 次元モデルの視覚的品質を評価する際に適切であることもわかった。

今後の課題としては、4.2 節の実験で、学習用データ数の差の影響がでている可能性があることから学習用データの数を調整すること、また定量評価に用いた位相不変量の誤差を Loss 関数に導入し、学習の際に誤差を減らすよう改良することが挙げられる。

謝辞

本研究を進めるにあたり、多くの方々に協力をしていただきました。ご指導いただいた椋木雅之教授に感謝いたします。指導教員である椋木雅之教授には研究についての相談や論文についてさまざまなご指導を頂きました。本当にありがとうございました。

また、研究室の皆様には研究や活動について様々な助言をいただきました。皆様のおかげでとても充実した研究室生活を送ることが出来ました。大変感謝をしております。

参考文献

- [1] 鳥脇純一郎, “3次元画像処理アルゴリズム 総論”, MEDICAL IMAGING TECHNOLOGY Vol.19 No.3, pp. 135-141(2001)
- [2] 岡和寿, 椋木雅之, “SRGAN の3次元ボクセルモデル超解像への適用”, 画像電子学会論文誌, vol. 48, no. 4, pp. 448-496(2019)
- [3] Christian Ledig, et al., "Photo-Realistic Single Image SuperResolution Using a Generative Adversarial Network", IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 105-114 (2017)
- [4] I. Goodfellow, et al., “Generative adversarial nets”, Advances in Neural Information Processing Systems (NIPS), pp. 2672–2680 (2014)
- [5] 池谷彰彦, 広明敏彦, “超解像ソリューション”, NEC 技報, vol. 60, no. 2, pp. 24-26 (2007)
- [6] 金田健太郎, “3次元モデルの超解像における敵対学習の有効性”, 令和2年度宮崎大学工学部 卒業論文(2020)
- [7] 米倉達広, 横井茂樹, 鳥脇純一郎, 福村晃夫, “3次元デジタル空間における図形の連結性とオイラー数”, 電子情報通信学会論文誌 D, Vol. J65-D No.1, pp. 80-87(1982)
- [8] 鳥脇純一郎, 横井茂樹, “3次元デジタル画像処理アルゴリズムの基礎”, 電子情報通信学会論文誌 D, Vol. J68-D No.4, pp. 426-433(1985)
- [9] ModelNet10, <http://modelnet.cs.princeton.edu/>