

NeDDF: 距離場と密度場を互恵的に制約する 3次元形状表現

上田 樹^{*1} 福原 吉博^{*2} 片岡 裕雄^{*3}
相澤 宏旭^{*4} 穴戸 英彦^{*1} 北原 格^{*1}

Abstract – This paper proposes a novel 3D representation method, Neural Distance-Density Field (NeDDF), to constrain the distance and density fields reciprocally. Recently, several methods have been proposed to construct distance and density fields using Implicit Neural Representation (INR) for 3D reconstruction problems. However, methods using density fields such as NeRF do not provide density gradient in most free regions and thus have poor tracking performance for camera pose estimation. Also, applications of distance field methods such as NeuS are limited to object shapes with boundary surfaces. We propose a distance field representation that extends distances to non-boundary shapes and can be explicitly transformed into a density field.

Keywords : NeRF, Implicit Neural Representation, Distance Field, Density Field

1 はじめに

本研究では, Implicit Neural Representation(INR)を用いる 3次元復元問題に対して, 距離場・密度場を互恵的に制約する Neural Distance-Density Field (NeDDF) を提案する.

点群やボクセルに代わる 3次元形状表現として, INRを用いる手法が注目されている [4][1][13]. これらの手法では, INRは 3次元位置や視線方向を入力に色や密度などを出力する場を記述する. 微分可能なレンダリング方程式によって新規視点での画像を生成し, また既知視点での観測画像を生成画像と比較することで最適化を行う. INRでは従来の点群やボクセルといった離散化を用いる陽的な表現と異なり, 連続的な場の回帰表現の獲得が可能であるため, 小さいモデル容量で入力次元数の大きい場を記述することができる. その高分解能・密な形状表現により, SLAMや Registrationといったカメラ姿勢推定処理への応用に期待が集まっている [14][3][11]. 例えば, WarpFieldのような変形の密な記述 [9] やトポロジー変化の表現 [8] 性能に基づいた非剛体シーンにおける Registrationでの活用法が提案されている. しかしこのような Registrationでの利用は大局解への収束が困難である. 先行研究ではオプティカルフローなど補助的な情報を要求するものが多く, 活用可能な場面が制限されている. INRによる形状記述は高い表現力がある一方で, 形状・視点・変形といった情報を大局解へ収束させる追従性が不足し




図1 鉄球・毛玉・ガラス玉における各場の表現例

ているのが現状である.

図1に示すように, INRの3次元形状表現としては, NeRFなどで用いられる密度場, NeuSなどで用いられ

^{*1}筑波大学

^{*2}早稲田大学

^{*3}産業技術総合研究所

^{*4}広島大学

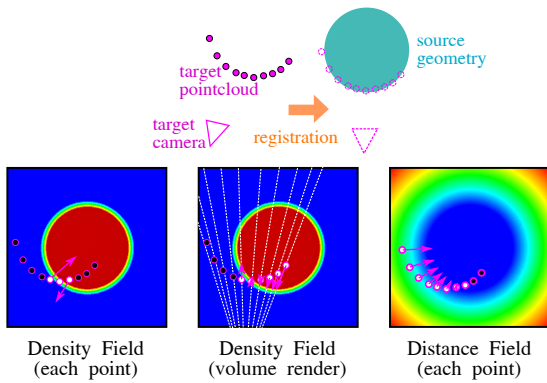


図2 各表現における Registration の追従性.

る距離場の二つが主流である。密度場は3次元位置を入力するとボリューム密度を出力する。煙や水など半透明な物体、髪などの高周波な形状に対して高い表現性能を有する。しかし、境界部以外の大半の領域では勾配が0となるため、図2に示すように、Registrationのような問題設定では凸性のある目的関数の設定が困難である。距離場は3次元位置を入力すると最近傍の境界面までの距離を出力するモデルである。物体表面付近以外では0をとる密度場と比べ、距離場は物体のない空間全体に対しても滑らかに値と勾配を提供する特徴がある。距離から密度への変換式を定義することで、ボリュームレンダリングを介した画像からの学習が可能になる。例えば、NeuSは距離0近傍で密度がlogistics density distributionに従うと仮定している。最適化が収束した後であっても広範囲で勾配が得られるため、Registrationにおいて凸性の良い目的関数が設定できる。一方で、明示的な境界面の存在を仮定しているため、変換可能な密度場が強く制限される。

本研究では、距離場・密度場を互恵的に制約するNeural Distance-Density Field (NeDDF)を提案する。我々は、ボリュームレンダリング方程式から導出される奥行きには、図4に示すように奥行きの勾配値や極小値に密度が現れることに着目する。このデプス値を当てはめることで、任意の密度分布を復元可能な形に距離場を拡張する。画像から距離場を学習する際にNeuSのような密度への制約が不要になる。その結果、密度場の学習時に形状やカメラ姿勢が同じ最適値をもつような整合性のとれた距離場が同時に獲得できる。我々は図3に示すように、位置を入力し距離とその勾配を出力するネットワークと、明示的に密度を算出する変換器によってNeDDFを記述した。NeDDFは、密度場に対する高い表現力と、対応する距離場による追従性の両立を可能にする。

本研究の貢献は次の三つである。(1) 任意の密度分布に対して定義可能な形に距離場を拡張する。(2) 距

離場とその勾配情報を用いて、独立点から対応する密度を復元する方法を導出する。(3) 補助勾配の導入により不連続点の問題を解決し、任意の点で距離場から密度場への変換を実現する。加えて、実験を通じて表現力と追従性の両面から本手法の有効性を確認する。




図3 提案モデル. 位置 \mathbf{p} を入力し、対応する距離を出力、さらに密度へ変換する

2 関連研究

2.1 Implicit Neural Representation

近年、INRを用いた空間的に連続な形状表現が注目されている。INRでは形状を、密度場や距離場など位置を入力に目的の値を出力する関数と捉える。これを小規模なMultiple Layer Perceptron (MLP)で回帰することで、形状表現を獲得している。INRでは、分解能が必要な箇所に自動的にネットワークの表現力が割り当てられることから、ボクセルなどの離散表現に比べ大幅に小さいパラメータ数で解像力の高い形状表現が可能である。さらに、軸ごとの明示的な分割数がないことから、モデル容量をそのままに入出力の次元数を追加することができる。これにより、従来疎なグラフなどによるモデル化が要求されていたWarpFieldを回帰によって連続的に求めることが可能となった。入力に多次元のDeformation Codeを追加した時系列情報のEmbedding[9]や、密度場を超次元空間の3次元スライスと捉えたトポロジー変化のモデル化[8]など、離散表現では記述が難しい形状の表現が可能となる。

また、MLPで滑らかな活性化関数を使用することで、INRは連続的微分可能な場とみなすことができる。変形量への制約として、場のダイバージェンス[12]やJacobian行列を用いた弾性制約[9]など勾配情報を活用したモデル化が提案されている。このような発想を参考に、我々は距離場の勾配により密度情報を記述するようなモデル化を行った。提案モデルは、明示的にお互いの整合性をとるような距離場と密度場を出力する。ペナルティ項による最適化ベースの制約ではないため、それぞれの場に適した目的関数から互恵的な最適化が可能である。

2.2 Density Field

密度場は、3次元位置を入力にボリューム密度を出力する。NeRFなど多くの手法が、密度場を色場と合

わせて活用している。密度場は表現力の高さが特徴である。例えばガラスや煙など半透明な物体を、小さい密度で記述することで割合的な光の透過が表現できる。また毛皮など境界面設定が困難な高周波形状に対して、その占有率を密度に置き換えて記述することで、映像生成時の整合性がとれるような形状表現が可能である。特に色場と組み合わせることで、視線依存性を含む複雑な反射のモデル化が可能である。

NeRFは観測画像についてカメラ姿勢が既知で静的なシーンであるという強い制限があり、利用可能な画像群の撮影が困難であった。そこで視点未知や動的なシーンでも利用できるよう、NeRFをベースにしたカメラ姿勢推定や被写体変形追従の手法が多数提案されている。しかし密度場は図2に示すように空中では0が最適値であり、学習が進むほどに勾配の取得できる領域が狭くなる。NeRF--[14]はカメラパラメータへの逆伝搬モデルを実現したが、視線方向の近いカメラ配置に利用が限定されている。NSFF[2]は変形の追従にオプティカルフローを要求する。Nerfies[9]はPositional EmbeddingにWarmupを追加し、高周波成分の学習を遅延させることで追従性を確保するが、視線方向の近いカメラ配置に限定される。

NeDDFでは、密度場の表現力を保ちつつ、整合性の取れた距離場を提供する。対象物体の存在しない領域においても勾配を作るだすことが可能であるため、追従性の改善が期待される。

2.3 Distance Field

距離場は、3次元位置を入力に最近傍境界面までの距離を出力する。従来離散表現として利用されてきた距離場として、Signed Distance Field(SDF)がある。境界面や法線方向を安定して提供できることから、FusionやRegistrationの文脈で幅広く利用されている[5][6]。

いくつかの研究がINRで距離場ベースの記述を実現する方法を提案している。DeepSDF[7]は連続したSDFの生成モデルを構築した。NeuS[13]は、符号付き距離場から静的な密度分布を仮定することで、ボリュームレンダリング方程式による最適化を可能にしている。しかし、これらの距離場はいずれも境界面の存在を前提としているため、表現可能な形状に制限が存在する。本研究では、ボリュームレンダリングから導出されるデプス値から、多様な密度分布と対応付けられるよう距離場を拡張することにより、Registrationに有用な近傍の物体までの距離と方向を広域的に提供する。

3 提案手法

3.1 非境界モデルにおけるデプス値の定義

本節では、密度情報を保持できるように距離場を再定義する。

従来の距離場 $D_b(\mathbf{p})$ は、位置 $\mathbf{p} \in \mathbb{R}^3$ に対して最近傍の境界面までの距離を記述する。図2に示すように、 $D_b(\mathbf{p})$ は最短距離を取る視点方向 $\mathbf{v} \in \mathcal{S}^2$ を採用したデプス値 $d_b(\mathbf{p}, \mathbf{v})$ と解釈できる。

$$D_b(\mathbf{p}) := \min_{\mathbf{v} \in \mathcal{S}^2} [d_b(\mathbf{p}, \mathbf{v})] \quad (1)$$

図4に示すように、デプス値 $d_f(\mathbf{p}, \mathbf{v})$ をボリュームレンダリングから得られる奥行き $d(\mathbf{p}, \mathbf{v})$ へ置き換えることで、任意の密度分布に対して定義できるように距離場を拡張する。

密度分布 $\sigma(\mathbf{p})$ が既知であるとして、視点位置 \mathbf{p} 、視線方向 \mathbf{v} におけるデプス値 $d(\mathbf{p}, \mathbf{v})$ を考える。式(2)はNeRF[4]におけるボリュームレンダリング方程式である。レイ上の点 $\mathbf{r}(t) = \mathbf{p} + t\mathbf{v}$ について、各色 $\mathbf{c}(\mathbf{r}(t), \mathbf{v})$ を透過率 $T(t)$ で加重平均を取得することでレイごとの色を取得している。

$$C(\mathbf{r}) := \int_{t_n}^{t_f} T(t)\sigma(\mathbf{r}(t))\mathbf{c}(\mathbf{r}(t), \mathbf{v})dt \quad (2)$$

$$T(t) = \exp\left(-\int_{t_n}^t \sigma(\mathbf{r}(s))ds\right) \quad (3)$$

$d(\mathbf{p}, \mathbf{v})$ も同様に、レイ上の各点のデプス値についての加重平均として以下のように定義する。

$$d(\mathbf{p}, \mathbf{v}) := t_n + \int_{t_n}^{t_f} T(t)\sigma(\mathbf{r}(t))tdt \quad (4)$$

この式は、境界面が存在する時のデプス値 d_b について、密度 σ を以下のように解釈した値である。

$$\sigma(\mathbf{r}(t)) = \begin{cases} 0 & 0 < t < d_b \\ \infty & d_b \leq t \end{cases} \quad (5)$$

実際には、全方向のデプスの推定に必要な観測は困難であることから、視線依存性を除去した距離場を利用する。境界面モデルと同様に各位置について最短のデプスを採用した距離場 $D(\mathbf{p})$ を以下のように定義する。

$$D(\mathbf{p}) := \min_{\mathbf{v} \in \mathcal{S}^2} [d(\mathbf{p}, \mathbf{v})] \quad (6)$$

ここで、採用された視線方向 $\mathbf{v}_n = \underset{\mathbf{v} \in \mathcal{S}^2}{\operatorname{argmin}} [d(\mathbf{p}, \mathbf{v})]$ に連続性を仮定すると、距離場の勾配 $\mathbf{g}(\mathbf{p})$ から次のように接平面を復元できる。

$$\mathbf{v}_n = \frac{-\mathbf{g}(\mathbf{p})}{|\mathbf{g}(\mathbf{p})|} \quad (7)$$

$$\mathbf{g}(\mathbf{p}) = \begin{bmatrix} \frac{\partial D(\mathbf{p})}{\partial p_x} & \frac{\partial D(\mathbf{p})}{\partial p_y} & \frac{\partial D(\mathbf{p})}{\partial p_z} \end{bmatrix} \quad (8)$$

なお実際には、 \mathbf{v}_n は非連続点が存在する。非連続点を解消する方法については、3.3節で後述する。

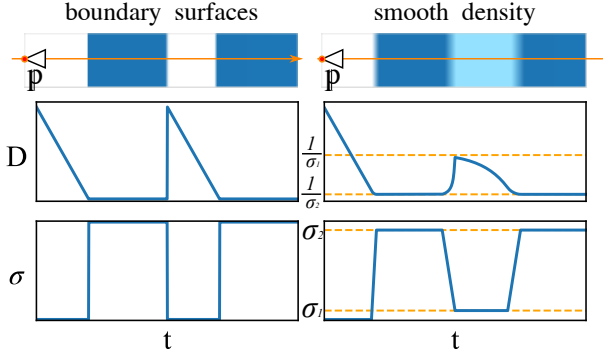


図4 非境界面モデルにおけるデプス値への拡張

3.2 密度場を内包する距離場のモデル化

前節では、距離場を非境界面モデルへと拡張し、密度場が既知とした時の距離場を導出した。本節では、距離場が既知とした時の対応する密度場の計算式を導出する。位置 \mathbf{p} 周辺の距離場について、勾配方向 $\mathbf{v}_n(\mathbf{p})$ でスライスした $D(r(t), \mathbf{r}(t)|_{\mathbf{p}} + t\mathbf{v})$ を考える。 $\Delta t \sim 0$ について式 (4), (7) より以下が成立する。

$$D(\mathbf{r}(\Delta t)) = d(\mathbf{r}(\Delta t), \mathbf{v}) \quad (9)$$

距離場の勾配方向にスライスした微分 $\frac{\partial D}{\partial t}$ を計算すると、以下のように σ についての式になる。

$$\frac{\partial D(\mathbf{r}(t))}{\partial t} \Big|_{t=0} = -1 + D(\mathbf{p})\sigma(\mathbf{p} + t_n\mathbf{v}) \quad (10)$$

また、 $\frac{\partial D}{\partial t}$ は距離場の勾配ベクトル $\mathbf{g}(\mathbf{p})$ を用いて以下のようにも表せる。また、距離場の勾配ベクトル $\mathbf{g}(\mathbf{p})$ と t についての微分の間以下関係が成り立つ。

$$\frac{\partial D(\mathbf{r}(t))}{\partial t} = \frac{\partial D}{\partial p_x} \frac{\partial p_x}{\partial t} + \frac{\partial D}{\partial p_y} \frac{\partial p_y}{\partial t} + \frac{\partial D}{\partial p_z} \frac{\partial p_z}{\partial t} \quad (11)$$

$$= \mathbf{g}(\mathbf{p}) \cdot \mathbf{v} \quad (12)$$

$$= -|\mathbf{g}(\mathbf{p})| \quad (13)$$

式 (10),(13) より、密度 σ は以下のように求まる。

$$\sigma(\mathbf{p}) = \frac{1 - |\mathbf{g}(\mathbf{p} - t_n\mathbf{v})|}{D(\mathbf{p} - t_n\mathbf{v}) - t_n} \quad (14)$$

t_n は式 (4) において透過率 $T(t_n) = 0$ とみなせる区間であり、 D の下限値である。 t_n は 0 を取るのが自然であるが、数値計算上の問題として、 $D \sim 0$ で密度が不定となる。そこで、 t_n が十分に小さいとして、式 (15),(16) の近似を導入することで、 σ は式 (17) の用に計算できる。

$$D(\mathbf{p} - t_n\mathbf{v}) \simeq D(\mathbf{p}) + t_n \quad (15)$$

$$\mathbf{g}(\mathbf{p} - t_n\mathbf{v}) \simeq \mathbf{g}(\mathbf{p}) \quad (16)$$

$$\sigma(\mathbf{p}) \simeq \frac{1 - |\mathbf{g}(\mathbf{p})|}{D(\mathbf{p})} \quad (17)$$

ネットワークの微分可能性より、距離場を回帰するような INR において、独立したサンプリング点 \mathbf{p}_i を入力に距離 $D(\mathbf{p}_i)$ と勾配ベクトル $\mathbf{g}(\mathbf{p}_i)$ を定められる。式 (17) により、微分可能な変換式で密度 $\sigma(\mathbf{p}_i)$ が計算できる。即ち、相互に制約された距離場・密度場の学習が可能である。なお、 $t_n > 0$ より $\sigma(\mathbf{p}) < \frac{1}{t_n}$ に制限される。

3.3 尖点の除去

距離から密度への変換式 (17) では距離勾配の情報を利用するが、距離場の尖点において勾配方向の非連続点が存在する。本節では距離場に 1 次元追加することで、勾配を滑らかに接続するような補助勾配軸 W を導入する。簡単のため、 $0 \leq t \leq 1$ を物体外部領域とする 1 次元の距離場を考える。距離場の勾配方向は

稜線となる $t = 0.5$ 付近で右向きから左向きへと非連続的に切り替わる。実際の INR による回帰では、図 5 に示すように稜線近傍で勾配が 1 から -1 へと連続的に変化する。このように非連続点が記述できないため、距離場の勾配を持つべき領域に $|\frac{\partial D}{\partial t}| = 0$ となる点が発生する。式 (17) に示すように小さい勾配値は大きい密度値に変換されるため、本来ものが無い場所に密度が誤発生してしまう。我々は、図 6 にしめすように、距離場に勾配方向の衝突のない次元を一つ追加し、勾配の大きさを保ったまま勾配方向を連続的に変化させるアプローチをとる。具体的には、距離場は 4 次元空間 $[x, y, z, w]$ の $w = 0$ におけるスライスであると捉える。 W 軸方向には障害物がないとすると、 W 軸に自由な勾配をもたせることが可能である。図 7 に示すように、峰近辺では $\sqrt{\frac{\partial D^2}{\partial t^2} + \frac{\partial D^2}{\partial w^2}} = \sigma$ となるように勾配成分を分配し、密度の誤発生を抑制する。




図5 距離場の峰付近における密度の誤発生




図6 補助勾配軸 W の導入

補助勾配にあらゆる形状を許容すると、峰以外の領




図7 補助勾配による密度誤発生の抑制

域の密度についても補助勾配で記述され、大局的な距離場の形状が失われる。そこで補助勾配の形状について制約を作り、ペナルティ項により最適な形状へ収束を誘導する。峰以外に補助勾配を励起させないためには、距離場と同じ方向に、距離場よりも急速に0へ収束するような形状を取らせれば良い。本研究では $\frac{\partial D}{\partial t} > 0$ のとき、以下の拘束を利用する。

$$\frac{\partial^2 D}{\partial t \partial w} = \alpha \frac{1}{D} \frac{\partial D}{\partial w} \quad (18)$$

ただし、 α は勾配の大きさを決めるハイパーパラメータである。 $\alpha = 1$ で直線、 α が大きくなるほど峰付近に集中した形状を取る。この拘束を加えることで、補助勾配を一意に設定することが可能である。

4 アーキテクチャ詳細

NeDDF を記述するための具体的なネットワークを図8に示す。本ネットワークでは、位置 \mathbf{p} を入力に、距離 D 、距離勾配 $[\frac{\partial D}{\partial p_x}, \frac{\partial D}{\partial p_y}, \frac{\partial D}{\partial p_z}, \frac{\partial D}{\partial p_w}]$ 、補助勾配の位置微分 $[\frac{\partial^2 D}{\partial p_x \partial p_w}, \frac{\partial^2 D}{\partial p_y \partial p_w}, \frac{\partial^2 D}{\partial p_z \partial p_w}]$ を出力する。本モデルを8層のMLPをベースに実装する。距離と補助勾配の間に拘束は不要であることから、 $D, \frac{\partial D}{\partial p_w}$ を直接出力し、それぞれ位置での1階微分を求めることで残りの値を決定する。微分値を利用することから、本ネットワークでは2階微分が連続となる活性化関数を利用する。中間層ではTanhExp, RGB出力層では恒等写像, D の出力層はSoftplus, $\frac{\partial D}{\partial p_w}$ の出力層ではSigmoidを利用する。なお、 $D > 0, 0 < \frac{\partial D}{\partial p_w} < 1$ に値域を制限している。




図8 アーキテクチャ詳細

従来法は、ボリュームレンダリングの際に Hierarchical Sampling を用いて密度の濃い場所を重点的に

サンプリングする。これらの手法は Positional Encoding の周波数を、重点サンプリングの分解能に合わせ高く設定している。本手法では密度は距離場の勾配を決定する値であり、距離の空間的な従属性が高い。そのため、疎なサンプリング間隔よりも細かい Positional Encoding を使用すると、大局的な距離場の収束が安定しなくなる。そこで、ネットワークの入力側の浅い層で、Positional Encoding の周波数を制限した Coarse な距離場 D_c を途中出力する。 D_c の出力層以降に高周波な Positional Encoding をショートカット接続し、高周波に残る残差を獲得した D_f を出力する。従来の Hierarchical Sampling 同様に、 D_c を疎なサンプリングで、 D_f を重点サンプリングによるボリュームレンダリングで学習することで、安定した学習を可能にしている。

5 実験

5.1 実験構成

提案手法について、密度場の表現力、距離場の追従性の両方が実現されていることを確認する。データセットにはそれぞれ TUM RGBD Dataset[10] を1/3にダウンサンプリングしたものを用いる。表現力の検証では、視点既知のRGBD映像を入力に学習を行い、未知視点での生成映像品質をPSNRで評価する。比較対象として、パラメータ数を合わせたNeRF[4]をベースラインに用いる。また、iMAP[11]と同様にデプスマップを用いた目的関数を用い、各手法それぞれデプスマップの有無について性能を比較する。

追従性の検証では、視点未知のRGBD映像を逐次的に追加してトラッキングを行う。最適化手順には何れもJoint OptimizationにNeRF-[14]のフローを利用する。復元された視点位置の精度をAbsolute Trajectory Error(ATE)で評価する。

5.2 結果

表現力の検証について、各シーン、各手法のPSNRを表1に示す。NeDDFは、PSNRによる比較ではやや劣るものの、NeRFと同等な映像生成品質が維持されているといえる。また、デプスマップの情報がない場合についても、映像生成品質は同等の品質となっている。このことから、NeDDFは視点既知におけるNovel View Synthesisについて、RGB,RGBD入力ともにNeRFの代替として利用できる性能を保持していると言える。また、復元された距離場と密度場の可視化を図9に示す。デプスマップありの場合に着目すると、NeDDFは物体内部では密度場が大きく、距離場が小さい値を取っている。物体外領域についても全域的に距離場が勾配を持って提供されていることが確認できる。ただし、デプスマップなしの場合に着目する

表1 表現力の検証結果: \uparrow PSNR[dB]

Method	w/ Depth		w/o Depth	
	NeRF	NeDDF	NeRF	NeDDF
teddy	30.5	29.7	30.7	29.8
plant	29.4	29.0	29.4	29.2
room	30.2	29.6	30.3	29.7

表2 追従性の検証結果: \downarrow ATE.RMSE[mm]

Method	NeRF	NeDDF
teddy	47.25	11.74
plant	33.15	12.94
room	41.60	21.78

と、距離場・密度場ともに不安定な形をとっている。このデータセットでは単眼カメラの軌跡を利用するため、正しく形状を制限するためには視点数が不足していると考えられる。そのため、単眼映像の追従で利用する場合には、従来法と同様にデプスマップの併用が要求される。

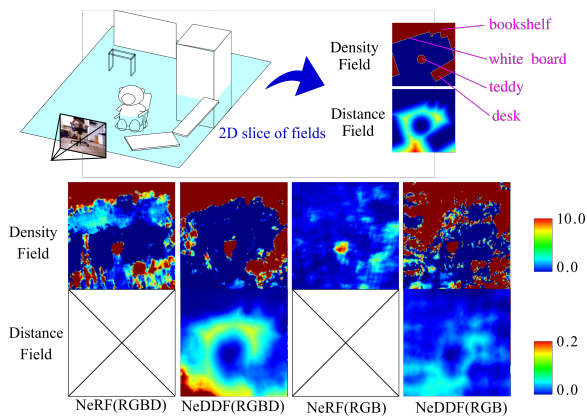


図9 距離場と密度場の可視化結果

追従性の検証についての実験結果を表2に示す。誤差はATEのRMSEを、それぞれミリメートル単位で表記したものである。形状表現にNeRFを用いる場合に比べ、ATEが半分以下と大幅な改善が見られる。また、Coarse Samplingにおけるサンプリング間隔が15.6[mm]であり、全シーンにおいて1サンプリング区間以下に誤差を収められている。すなわちこの誤差は、Trackingで得られたカメラ姿勢を初期値とするFine Tuningにより追従可能な範囲内である。

これらの実験結果から、NeDDFはNeRFと同等の映像生成品質を可能とする形状表現と、NeRFよりも高い追従性能を保持しているといえる。

6 まとめと今後の課題

本研究では、NeDDFによる形状推定や追従にRGBD映像入力を想定した。デプス値が未知の場合には、NeRFと同等の映像生成品質は得られるものの、復元される距離場はRegistrationには不適切な局所解を取ることがおおい。RGB画像のみを入力に用いる場合には、距離場に関する制約の追加が必要であると考えている。

本研究では、互恵的に制約された距離場と密度場の獲得を実現した。これにより、従来SDFなどで用いられていたRegistrationの目的関数の導入が可能になった。今後、カメラの大移動を含むシーン、複雑な非剛体変形を含むシーンなどに対し、INRの高精度な形状表現の利用が可能になることが期待される。

本研究の一部は科研費19H00806によるものである。

参考文献

- [1] Julian Chibane et al. Neural unsigned distance fields for implicit function learning. In *NeurIPS*, December 2020.
- [2] Zhengqi Li et al. Neural scene flow fields for space-time view synthesis of dynamic scenes. In *CVPR*, 2021.
- [3] Chen-Hsuan Lin et al. Barf: Bundle-adjusting neural radiance fields. *arXiv preprint arXiv:2104.06405*, 2021.
- [4] Ben Mildenhall et al. Nerf: Representing scenes as neural radiance fields for view synthesis. In *ECCV*, 2020.
- [5] Richard A Newcombe et al. Kinectfusion: Real-time dense surface mapping and tracking. In *ISMAR*, 2011.
- [6] Richard A Newcombe et al. Dynamicfusion: Reconstruction and tracking of non-rigid scenes in real-time. In *CVPR*, 2015.
- [7] Jeong Joon Park et al. Deepsdf: Learning continuous signed distance functions for shape representation. In *CVPR*, 2019.
- [8] Keunhong Park et al. Hypernerf: A higher-dimensional representation for topologically varying neural radiance fields. *arXiv preprint arXiv:2106.13228*, 2021.
- [9] Keunhong Park et al. Nerfies: Deformable neural radiance fields. In *ICCV*, 2021.
- [10] J. Sturm et al. A benchmark for the evaluation of rgb-d slam systems. In *IROS*, 2012.
- [11] Edgar Sucar et al. imap: Implicit mapping and positioning in real-time. In *ICCV*, 2021.
- [12] Edgar Tretschk et al. Non-rigid neural radiance fields: Reconstruction and novel view synthesis of a dynamic scene from monocular video. In *ICCV*, 2021.
- [13] Peng Wang et al. Neus: Learning neural implicit surfaces by volume rendering for multi-view reconstruction. In *NeurIPS*, 2021.
- [14] Zirui Wang et al. NeRF---: Neural radiance fields without known camera parameters. *arXiv preprint arXiv:2102.07064*, 2021.