

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}	宍戸 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}產業技術総合研究所

^{*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.物体表層 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 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 $\mathbf{v} \in S^2$ を採用した デプス値 $d_b(\mathbf{p}, \mathbf{v})$ と解釈できる.

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

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.

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

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

d(**p**,**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.

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

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.

$$\sigma(\mathbf{r}(t)) = \begin{cases} 0 & 0 < t < d_b \\ \infty & d_b \le t \end{cases}$$
(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*(**p**)を以下のように定義 する.

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

ここで、採用された視線方向 $\mathbf{v}_n = \underset{\mathbf{v} \in S^2}{\operatorname{argmin}[d(\mathbf{p}, \mathbf{v})]}$ 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.

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

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

なお実際には、*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.

日本バーチャルリアリティ学会 複合現実感研究会 Vol.25, No.1, 2022



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 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 $D(r(t)), \mathbf{r}(t)p + t\mathbf{v}$ を考える. $\Delta t \sim 0$ について式 (4), (7) より以下が成立する.

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

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.

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

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に以下の関係が成り立つ.

$$\frac{\partial D(\mathbf{r}(t))}{\partial t} = \frac{\partial D}{\partial p_x} \frac{\partial p_x}{\partial t} + \frac{\partial D}{\partial p_y} \frac{\partial p_y}{\partial t} + \frac{\partial D}{\partial p_z} \frac{\partial p_z}{\partial t} (11)$$
$$= \mathbf{g}(\mathbf{p}) \cdot \mathbf{v}$$
(12)
$$= -|\mathbf{g}(\mathbf{p})|$$
(13)

式 (10),(13) より, 密度 σ は以下のように求まる.

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

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

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

$$\sigma(\mathbf{p}) \simeq \frac{1 - |\mathbf{g}(\mathbf{p})|}{D(\mathbf{p})}.$$
 (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, $0 \le t \le 1$ 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 $\left|\frac{\partial D}{\partial t}\right| = 0$ 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 $\sqrt{\frac{\partial D}{\partial t}^2} + \frac{\partial D}{\partial w}^2 = \sigma$ 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 20 > 0 のとき,以下の拘束を利用する.

$$\frac{\partial^2 D}{\partial t \partial w} = \alpha \frac{1}{D} \frac{\partial D}{\partial w} \tag{18}$$

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 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

日本バーチャルリアリティ学会 複合現実感研究会	Vol.25,	No.1, 2022
-------------------------	---------	------------

表1	表現力の検証結果:		$\uparrow PSNR[dB]$	
	w/ Depth		w/o Depth	
Method	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.RM	SE[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

- 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 spacetime view synthesis of dynamic scenes. In CVPR, 2021.
- [3] Chen-Hsuan Lin et al. Barf: Bundleadjusting 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: Realtime dense surface mapping and tracking. In *IS-MAR*, 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 higherdimensional 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.