

任意方向光源下画像生成のための照明環境と補間処理の同時最適化 Relighting under Arbitrary Lighting Directions from a Small Number of Images

平尾 寿希[†] 川原 僚[‡] 岡部 孝弘[‡]
Toshiki Hirao Ryo Kawahara Takahiro Okabe

1 はじめに

被写体の見えは照明環境に依存することから、任意照明環境下画像の生成はコンピュータグラフィックス(CG)やコンピュータビジョン(CV)分野における重要な課題である。様々な照明環境下で撮影された実画像を用いて任意照明環境下の画像を生成する技術は再照明と呼ばれ、視覚効果や拡張現実などに応用されている。

従来の再照明手法では、重ね合わせの原理により、様々な照明環境下で撮影された画像を組み合わせることで所望の照明環境下における画像を生成する。そこで、ライトステージのような様々な方向に配置された単一点光源下で撮影された大量の画像を補間することで、任意照明環境下における再照明画像を生成する研究が行われてきた。しかし、ライトステージのような光源装置では光源の配置が離散的であるため、全方位における単一点光源下の画像は獲得できず、撮影画像の線形結合では表現困難な照明環境が存在する。本稿ではこのような離散的な配置の光源を想定し、既設の離散的な方向(既知方向)の光源下の画像から未設の方向(未知方向)光源下の画像を生成する再照明手法を提案する。なお、本稿では既知方向の光源下の画像を用いて未知方向の光源下の画像を生成することを補間と呼ぶ。

一般に、画像は拡散反射や鏡面反射など様々な成分で構成される。光源方向の変化に対して低周波である拡散反射成分については、異なる方向の単一点光源下で撮影した3枚の基底画像の線形結合により、任意方向光源下の画像を生成できることが知られている[1]。一方、鏡面反射成分のような光源方向の変化に対して高周波である鏡面反射成分については、密な方向における単一点光源下で撮影した大量の画像や、局所的に物体が様な反射特性および滑らかな形状を持つことを仮定した上で非線形な補間[3]が必要になることが知られている。

そこで本稿では、少数の照明環境下で撮影された画像を用いた任意方向光源下の画像生成手法を提案する。提案手法では、少数の照明環境下の画像から鏡面反射成分を効率よくとらえるために、点光源だけでなく様々な大きさの面光源やそれらの組み合わせも利用する。点光源のみを使用した場合、既知方向の光源下の画像(図1(a), (c))では鏡面反射光の振る舞いを観測できる領域が狭く、未知方向の光源下の画像(図1(b))の鏡面反射の予測は困難である。一方、面光源下の画像(図1(d), (e))を使用した場合、より広い範囲で鏡面反射光の振る舞いを観測でき、未知方向の光源下の画像(図1(b))の鏡面反射の予測が可能であると考えられる。さらに、面光源を含む複数の光源の組み合わせも利用することで、鏡面反射成分を効率よくとらえ、少数の照明環境下の画




図 1: 面光源利用の有効性：点光源下および面光源下の画像

像を用いた任意方向光源下の画像生成を実現する。

しかし、面光源を含む複数光源の組み合わせ方、および少数の照明環境下画像から任意方向光源下の画像を生成する補間手法は定かではない。そこで提案手法では、重ね合わせの原理から、複数光源(下の画像)と単一点光源(下の画像)の関係は、 1×1 の畳み込みカーネルを用いて表現できることに着目し、不定である照明環境と補間処理の両方を畳み込みニューラルネットワーク(CNN)の枠組みで同時に最適化する。さらに、実画像を用いた実験を行い、提案手法の有効性を示す。

近年のCV分野におけるディープニューラルネットワーク(DNN)を用いた研究では、Chakrabartiら[11]の手法のように、撮影済みの画像の処理方法のみならず、撮影方法(カメラ)までも最適化するディープセンシングと呼ばれる手法が提案されている。しかし、被写体の見えは前述のとおり照明環境に依存することから、カメラだけでなく撮影時の照明環境の最適化も重要である。そこで本稿では、撮影済みの画像の処理方法のみならず、撮影時の照明環境も同時に最適化するディープライティングを再照明に応用する。

本研究の貢献を以下に示す。

- 実画像を撮影するときの照明環境として点光源だけでなく面光源やそれらの組み合わせを利用した効率的な再照明の実現
- CNNの枠組みで再照明のために照明環境と補間処理の両方をデータ駆動で同時に最適化する新たなアプローチの提案

2 関連研究

2.1 再照明

2.1.1 大量画像に基づく再照明

従来、映画産業などでの応用を目的に人の顔を対象とする再照明の研究が広く行われている。光源方向の変化に対して低周波である拡散反射成分については、線形補間により、任意方向光源下の拡散反射成分を生成できることが知られている。具体的には、Lambertモデルを仮定すると、任意方向光源下の画像の拡散反射成分は、異なる方向光源下で撮影された3枚の基底画像の線形結合により補間できる[1]。

[†] 九州工業大学大学院情報工学府情報創成工学専攻
Kyushu Institute of Technology

[‡] 九州工業大学大学院情報工学府情報創成工学専攻
研究系 Kyushu Institute of Technology

一方、光源方向の変化に対して高周波である鏡面反射成分については、拡散反射成分とは異なり、単純な基底画像の線形結合では任意方向光源下の画像を生成できないことが知られている。そこで Debevec ら [4] は、密な方向光源下で撮影した数百枚の画像を使用してライトトランスポートを密に計測することで、鏡面反射などの高周波成分を含む再照明画像を生成する手法を提案した。しかしながら、上記の手法では大量の画像を撮影する必要があり、撮影コストが高いという問題が存在する。

2.1.2 物理モデルに基づく再照明

撮影コスト削減のために、鏡面反射などの高周波成分を含む一般物体に対し、様々な物理モデルの仮定のもとに再照明を行う手法が提案されてきた。Lin ら [2] は、鏡面反射によるハイライト領域が重なっていることを仮定し、対数領域での線形結合により、異なる方向光源下における鏡面反射成分を近似的に補間する手法を提案した。しかし、この手法ではハイライトが重なっていない条件下では、補間を行うことができない。

一方、Fuchs ら [3] は、少数の異なる照明環境下の画像から任意照明環境下の画像の補間を行う手法を提案した。具体的には、撮影画像から画素値をもとに鏡面反射領域を分離し、物体表面において鏡面反射が滑らかに移動することを仮定して、オプティカルフローに基づいた非線形補間を行った。しかしながら、実シーンにおいては、不連続な反射特性や形のために、鏡面反射が滑らかに移動するという仮定が成り立たない被写体が多く存在し、そのような被写体の補間には密な方向光源下で撮影した大量の画像が必要になる。

2.1.3 機械学習に基づく再照明

近年、深層学習を用いた再照明手法が多く提案されている。人の顔を対象とする再照明 [5], [6], [7] では、深層学習を用いることで人の顔に対しては写実的な画像が生成できる反面、被写体が顔に限定されているため、多様な反射特性や形を持つ一般物体の補間は困難である。

一方、深層学習を用いた一般物体の再照明手法 [8], [9], [10] も提案されている。Ren ら [8] は少数の撮影画像から、撮影したシーンのライトトランスポートを複数のニューラルネットワークを用いたアンサンブル学習によって獲得することで、任意照明環境下の再照明画像の生成を行った。しかし、鏡面反射などの高周波成分を多く含む場合など、シーンによっては大量の画像が必要となり、撮影コストが高くなるという問題が存在する。また、Xu ら [9] は密な方向光源下で撮影した大量の入力画像から深層学習の枠組みで光源選択を行い、少数の単一点光源下の画像から再照明画像を生成する手法を提案した。しかし、この手法では光源として単一点光源のみを仮定しており、照明環境の設計としてさらなる工夫の余地が存在する。また、前述の研究の多くは照明環境として単一点光源もしくは環境光を仮定しており、サイズの異なる面光源や、面光源を含む複数光源の同時点灯を許容していない。そこで提案手法では、サイズの異なる面光源や、面光源を含む複数光源の同時点灯を許容し、照明環境の最適化を行うことで、鏡面反射成分を効率よくとらえ、少数の照明環境下の画像を用いた任意方向光源下の画像生成を実現する。

2.2 センサと画像処理の同時最適化

CV 分野において深層学習を応用した研究が多く行われている。従来の応用としては、撮影済みの画像を用いて、所望の画像処理タスクの処理方法のみを学習により最適化することで、様々な画像処理タスクにおいて性能の向上を実現してきた。しかし、学習に使われる画像を撮影する際に利用するカメラや照明の設計は信号処理理論などの解析的な手法で行われることが一般的であり、工夫の余地がある。

これに対し、近年、撮影済みの画像の処理方法のみならず、深層学習の枠組みにおいて、カメラのレンズやフィルタ等のセンサ部分の設計までも同時に最適化するディープセンシング [11], [12], [13] と呼ばれる手法が提案されている。Chakrabarti ら [11] は、カラーカメラに使用されているカラーフィルタアレイ、および、それを用いて撮影された画像からフルカラー画像の生成を行う手法を DNN の枠組みで同時に最適化する手法を提案した。

提案手法では、カメラのセンサ部分ではなく、再照明において重要である照明環境に着目し、撮影済みの画像の処理方法のみならず、照明環境も最適化するディープライティングを再照明に応用する。ディープライティングの手法としては、王ら [14] の手法が挙げられる。この手法では表面材質識別のために、波長と方向の異なる光源の組み合わせと非線形関数で表現される材質の特徴抽出の両方を、データ駆動のアプローチで最適化した。この研究に触発され、提案手法では、照明環境の最適化として特定の大きさ・方向の光源の組み合わせ方（点灯パターン）の最適化を行う。光源には点光源だけでなく面光源も利用し、さらに照明環境として複数光源の同時点灯を許容することで、再照明のために照明環境までも CNN の枠組みで同時に最適化する。

3 提案手法

3.1 ネットワーク構造

照明環境と補間処理の同時最適化のために、撮像層と補間処理ネットワークで構成される図 2(a) のような同時最適化ネットワークを考える。学習の際は、 D 方向・ S サイズの単一点光源画像（点灯パターン画像）およびその光源下で撮影した単一点光源下画像（点灯パターン下画像）を入力とし、図 2(a) の撮像層で最適な照明環境（最適な点灯パターン）を学習する。学習された最適な点灯パターンの画像（最適な点灯パターン画像）およびその点灯パターン下で撮影した少数の画像（最適な点灯パターン下画像）を補間処理ネットワークに入力し、出力単一点光源画像で指定する方向光源下の画像を補間する非線形な画像補間処理を学習する。CNN の枠組みにおいて、撮像層と補間処理ネットワークの学習を繰り返し行うことで、照明環境および補間処理の同時最適化を行う。

テストの際は、図 2(b) のように、学習の結果得られた最適な点灯パターン画像および最適な点灯パターン下画像を使用し、出力単一点光源画像で出力したい光源方向を指定することで、少数の照明環境下の画像から任意方向光源下の画像を生成を行う。

3.2 光源点灯パターン

複数の光源を同時点灯したパターン下で撮影された画像を縦ベクトルで表現した i_{mul} は、重ね合わせの原理によ

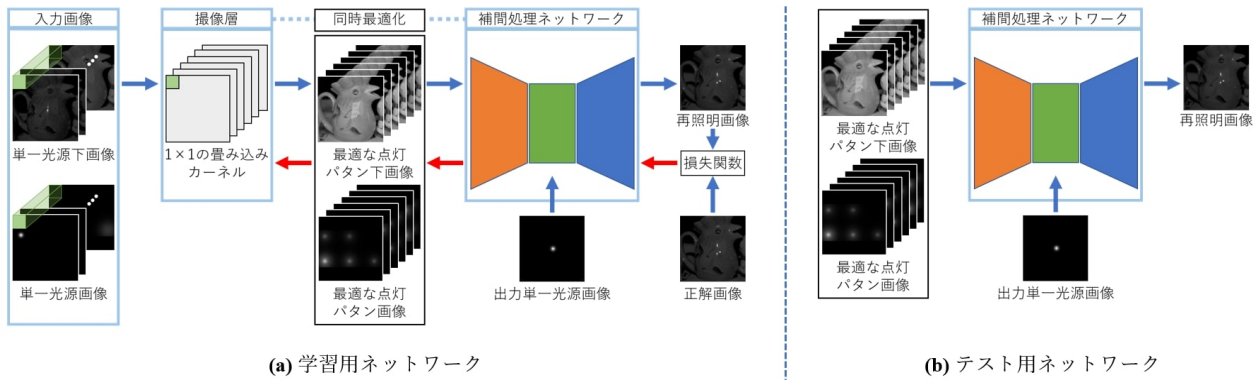


図2: 点灯パターンと補間処理の同時最適化ネットワーク

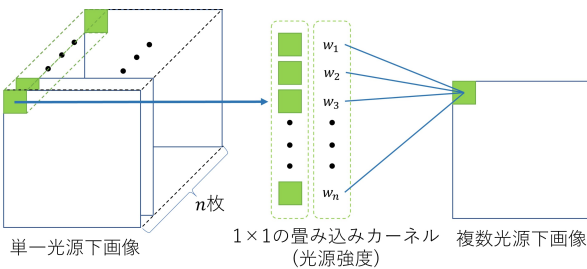


図3: 1×1の畳み込み

り, 単一光源下で撮影された N 枚の画像 $I(i_1, i_2, \dots, i_N)$ を用いて,

$$\begin{aligned} i_{\text{mul}} &= i_1 w_1 + i_2 w_2 + \dots + i_N w_N \\ &= Iw \end{aligned} \quad (1)$$

のように線形結合で表現でき, 各光源の明るさ w が結合係数となる. このような線形結合は CNN の枠組みにおいて 1×1 の畳み込みで, 結合係数である各光源の明るさ w は 1×1 の畳み込みカーネルで表現される (図3). この処理を応用し, 照明環境の最適化を行う.

従来の深層学習を用いた再照明手法 [9] では, 単一点光源のみを利用し, 座標値をもとに定数画像を作成し, 定数画像で照明環境を表現している. しかし, 座標では様々なサイズ, 方向, 明るさを持つ複数光源の組み合わせの表現が困難である. そこで提案手法では, 点灯パターン画像を用いて照明環境を表現する. 照明環境を点灯パターン画像とすることで, 1×1 の畳み込みカーネルを用いて, 複数光源を組み合わせさせた同時点灯パターンの表現が可能である.

図4に照明環境の最適化手順を示す. まず, 図4(a)のように同一方向の光源 S 枚の組み合わせを非負制約を課した 1×1 の畳み込み処理によって D 枚作成し, 作成後の畳み込みカーネルに対してそれぞれ正規化を行う. これにより, 各方向ごとに点灯可能な範囲での光源の組み合わせの最適化を行う. 次に, 図4(b)のように, 図4(a)で作成した各方向ごとに最適な方向光源を非負制約および最大値制約を課した 1×1 の畳み込み処理によって組み合わせることで D 方向・ S サイズの点灯パターン画像を組み合わせさせた最適な点灯パターン画像を作成する. また, 最適な点灯パターンの画像も同様の処理で取得可能である.



(a) 同一方向の光源 (S 枚) の組み合わせ(b) 複数方向の光源 ($D \times S$ 枚) の組み合わせ

図4: 照明環境の最適化

3.3 観測ノイズ・量子化ノイズ

前述の処理により作成した最適な点灯パターン下画像にはノイズが非常に少ないのに対し, 実シーンにおいて最適な点灯パターン下で撮影した画像には撮影時の観測ノイズが含まれることから, 学習時には実シーンと同様の状況を再現するためのノイズを付与する. 具体的には, 撮影時の観測ノイズとしてガウスノイズの付与を行う. また, 画像を実数から整数値に変換 (A/D 変換) する際に生じる量子化ノイズに関しては, -0.5 から 0.5 の範囲で一様分布するノイズを付与し, 四捨五入と同等の丸め誤差を再現する. これにより, ネットワーク内で作成する最適な点灯パターン下画像と実際に最適な点灯パターン下で撮影する画像を同等として扱う.

3.4 補間処理ネットワーク

再照明画像の生成において, 前述のように, 任意方向光源下の拡散反射成分は, 異なる方向光源下で撮影した3枚の基底画像の線形結合により補間できるのに対して, 鏡面反射成分の生成には非線形の補間が必要である. そこで, 少数の最適な点灯パターン画像および最適な点灯パターン下画像を入力とし, 出力単一光源画像で指定した単一光源下画像を生成する非線形補間を図2の補間処理ネットワークで学習する. 具体的には, 補間処理ネットワークとして, U-Net[15] のボトルネック部分に出力単一光源画像を入力する層を追加したネットワークを用いる (図5). U-Net の特徴であるスキップ接続によ

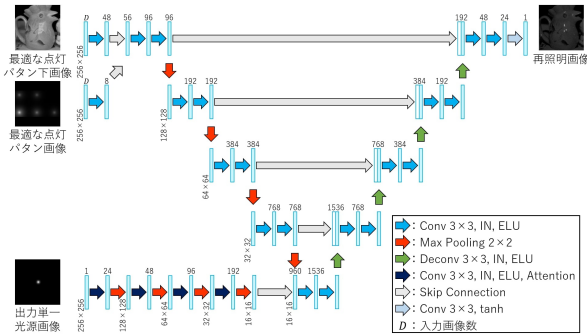


図 5: 補間処理ネットワーク

り大域的な特徴と局所的な特徴をとらえることで、拡散反射などの低周波数成分および鏡面反射などの高周波数成分の両方の補間が可能であると考えられる。また、ネットワークの各層における特徴マップ数に関しては Optuna[16] によりパラメータの組み合わせ最適化を行った。

ネットワークの前半部分では、撮像層の出力である 256×256 サイズの最適な点灯パターン画像および最適な点灯パターン下画像を入力とし、それぞれカーネルサイズ 3×3 の畳み込み処理後、インスタンス正規化 [18] を行い、活性化関数 ELU による非線形変換を行う。その後、スキップ接続により最適な点灯パターン画像および最適な点灯パターン下画像の特徴マップを統合する。特徴マップの統合後、同様にカーネルサイズ 3×3 の畳み込み処理、インスタンス正規化、活性化関数 ELU による非線形変換の処理を 2 回経て、 2×2 サイズの max pooling を行う操作を 4 回繰り返す。

出力単一光源画像に関しては同様にカーネルサイズ 3×3 の畳み込み処理、インスタンス正規化、活性化関数 ELU による非線形変換を行うのに加え、画像領域内において注目領域を決定する画像空間方向の Attention 機構 [17] を導入した。Attention 機構により、出力したい光源方向を効率的に学習するよう工夫を加えた。その後、 2×2 サイズの max pooling を行い、特徴マップのサイズを縮小させ、ネットワークのボトルネック部分で最適な点灯パターン画像および最適な点灯パターン下画像の特徴マップと結合する。ボトルネック部分では畳み込み、インスタンス正規化、活性化関数 ELU による非線形変換処理を 2 回行う。

ネットワークの後半部分では、カーネルサイズ 3×3 の逆畳み込み操作によって特徴量の拡大を行い、前半同様インスタンス正規化、活性化関数 ELU による非線形変換を行う。この出力と、前半の畳み込み層を経た出力をスキップ接続により連結した特徴マップを入力とし、前半と同様の畳み込み、インスタンス正規化、活性化関数 ELU による非線形変換の操作を 2 回繰り返す。この操作を 2 つのデコーダ部分で 4 回繰り返すことで、入力と同解像度の出力を得る。最後に 2 つのデコーダの出力を連結した特徴マップを入力とし、畳み込み、インスタンス正規化、活性化関数 ELU による非線形変換を 2 回行い、最後にカーネルサイズ 3×3 、活性化関数 tanh の畳み込み処理によって再照明画像の生成を行う。

4 実験



図 6: 実験のセットアップ




図 7: (a)-(c) 学習画像撮影用光源点灯パターン, (d)-(f) 正解画像撮影用光源点灯パターン例

4.1 実験環境

提案手法の有効性を示すために実画像を用いた実験を行った。実験環境を図 6 に示す。実験では光源として Philips 社の 439P9H1 液晶ディスプレイ (LCD)、カメラとして FLIR 社の CMLN-13S2M-CS モノクロカメラを利用した。LCD を光源として利用することで任意の大きさ・方向の光源の作成が可能であり、ライトステージを模倣した離散的な光源を作成した。

4.2 学習データとパラメータ設定

今回の実験では、図 7(a) に示す $D = 6$ 方向の光源下の画像から、任意方向光源の単一光源下画像を生成する。学習の際は、学習用画像として図 7(a), (b), (c) の $D = 6$ 方向・ $S = 3$ サイズの光源をそれぞれ順番に点灯した単一光源下画像 18 枚、正解画像として図 7(d), (e), (f) に示すような各シーンごとに異なる 30 方向の光源をそれぞれ順番に点灯した単一光源下画像 30 枚を用いた。今回の実験では学習データとして 9 シーン、評価データとして 3 シーン、テストデータとして 3 シーンの画像を準備して実験を行った。限られた学習データから効率的に学習するために、画像データを 256×256 のサイズの小画像として切り出して使用した。

補間処理ネットワークは、最適化手法として Adam オプティマイザー [19] を用いて学習を行い、学習率は 1.0×10^{-3} を初期値とし、学習の経過により徐々に減衰させた。初期学習率を大きくすることで入力層付近での勾配消失問題を解消し、撮像層における 1×1 の畳み込みカーネルの初期値への依存を小さくすることで、照明環境の学習が進むよう設計した。損失関数としては MSE (最小二乗誤差)、評価関数は MSE, SSIM を用いて学習を行った。ネットワークにおける重みの初期値としては、撮像層に関しては 0.4 から 0.6 の値をとる一様分布、その他の重みに関しては He の初期値 [20] を利用した。また、本実験では観測ノイズとして平均 0、標準偏差 2 のガウスノイズを付与した。

4.3 定性評価

図 8 に、(a) 再照明画像として出力する方向光源 (出力単一光源画像) 下における正解画像、(b) 図 7(a) の 6 方向の単一点光源下画像 6 枚を用いて単純な線形補間により生成した画像、(c) 図 7(a) の 6 方向の単一点光源下画像 6

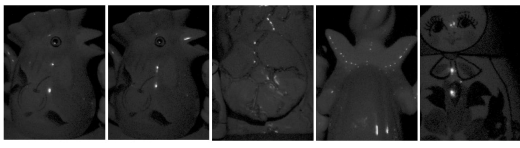
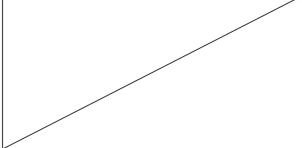
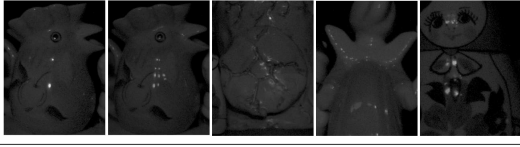
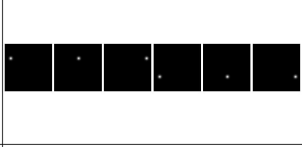
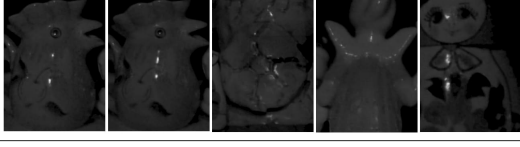
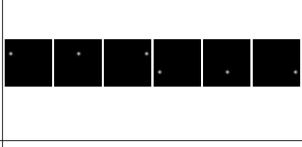
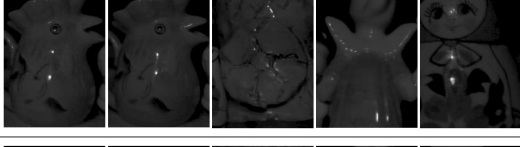
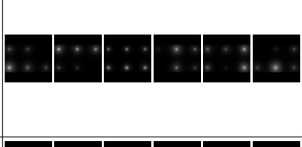
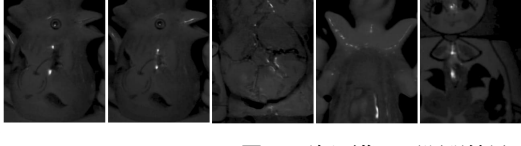
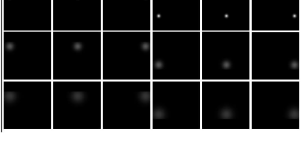
	出力単一光源下画像の再照明画像	点灯パターン	PSNR ↑	SSIM ↑
(a) 正解画像				
(b) 線形補間 (単一サイズ光源下 6 枚)			35.57	0.919
(c) 非線形補間 (単一サイズ光源下 6 枚)			36.93	0.929
(d) 提案手法：非線形補間 (最適照明下 6 枚)			37.66	0.932
(e) 非線形補間 (複数サイズ光源下 18 枚)			37.75	0.930

図 8: 正解画像と再照明結果

枚を用いて非線形補間により生成した画像, (d) 最適化された照明環境下画像 6 枚を用いて非線形補間により生成した画像 (提案手法), (e) 図 7(a), (b), (c) の 6 方向・3 サイズの単一光源下画像 18 枚を用いて非線形補間により生成した画像を示す. なお, 比較のため生成結果の一部を抜粋したものを示している.

まず, 図 8(b) の単純な線形補間により生成した画像では, 鏡面反射は入力画像の鏡面反射が移動しておらず, 図 8(a) の正解画像と比較すると鏡面反射の位置および外形が大きく異なるため, 補間が不十分であることが確認できる. 次に, 図 8(c) の光源として点光源のみを用いて非線形補間により生成された画像と正解画像とを比較すると, 同一の被写体においても, 入力画像として使用した点灯パターン付近の方向光源下の再照明画像 (左から 1 列目の生成結果) は良好であるものの, 入力画像として使用した点灯パターンから大きくずれた方向光源下の再照明画像 (左から 2 列目の生成結果) においては, 一部鏡面反射の予測が正しく行っていないことが確認できる. この結果より, 点光源のみを使用する場合は, 鏡面反射光の振る舞いを観測できる領域が狭く, 未知の方向光源下画像の生成は困難であることが確認できる. 一方, 図 8(d) の提案手法では被写体によらず鏡面反射の位置および外形ともに良好な生成結果が得られており, 照明環境の最適化が再照明において有効であることが確認できる. また, 図 8(e) の 6 方向・3 サイズの単一光源下画像 18 枚の画像を用いて非線形補間により生成された画像と図 8(d) の提案手法とを比較すると, 提案手法では再照明に使用する画像数を減らしたにもかかわらず,

鏡面反射の位置および外形が類似しており, 定性的に良好な結果が得られている.

4.4 定量評価と最適な点灯パターン

各手法の定量評価を行った結果を比較する. PSNR, SSIM の両指標において, 図 8(d) の提案手法が図 8(b), (c) の単一サイズの光源下画像 6 枚を用いて生成された手法よりも良好な結果が得られており, 同一画像数では提案手法が最も良好な結果であることが確認できる. また, 図 8(e) の 18 枚の画像を用いた結果と比較しても大きな差はなく, 複数光源の組み合わせの利用が再照明において有効に機能することが分かる. 併せて, 図 8(d) に今回の実験で得られた最適な点灯パターンを示す. 最適な点灯パターンでは, 点光源のみならず, 面光源も利用しているため, 再照明において面光源の利用が有効であることが確認できる.

5 むすび

本稿では, 任意方向光源下画像生成のための照明環境と補間処理の同時最適化手法を提案した. 提案手法では, 少数の照明環境下の画像から効率的に鏡面反射成分をとらえるために, 点光源だけでなく様々な大きさの面光源やそれらの組み合わせを利用した. また, 複数光源 (下の画像) と単一光源 (下の画像) の関係が CNN の枠組みにおいて 1×1 の畳み込みカーネルを用いて表現できることに着目し, 再照明のために照明環境と補間処理の両方を同時に最適化する新たなアプローチを提案した. 実画像を用いた実験により, 照明環境および補間処理の同時最適化が, 再照明において有効であることを確

認した。影などの他の画像中の成分に対する本手法の拡張が今後の課題である。

sification”, In Proc. IEEE ICCV 2015, pp.1026–1034, 2015.

謝辞

本研究の一部は、JSPS 科研費 JP23H04357、および、JP20H00612 の助成を受けた。

参考文献

- [1] A. Shashua, “On photometric issues in 3D visual recognition from a single image”, *IJCV*, Vol.21, No.1-2, pp.99–122, 1997.
- [2] S.Lin and S.Lee, “A representation of specular appearance”, In Proc. IEEE ICCV1999, pp.855–860, 1999.
- [3] M. Fuchs, H. Lensch, V. Blanz, and H. Seidel, “Superresolution Reflectance Fields: Synthesizing images for intermediate light directions”, In Proc. EGSR2007, pp.447–456, 2007.
- [4] P. Debevec, T. Hawkins, C. Tchou, H. Duiker, W. Sarokin, and M. Sagar, “Acquiring the reflectance field of human face”, In Proc. SIGGRH2000, pp.145–156, 2000.
- [5] T. Sun, J. T. Barron, Y-T. Tsai, Z. Xu, X. Yu, G. Fyffe, et al. “Single image portrait relighting”, *ACM Transactions on Graphics*, Vol.38, No.4, pp.79–1, 2019.
- [6] H. Zhou, S. Hadap, K. Sunkavalli, and D. W. Jacobs, “Deep single-image portrait relighting”, In: Proc. IEEE ICCV 2019, pp.7194–7202, 2019.
- [7] M. Abhimitra, et al., “Deep reflectance fields: high-quality facial reflectance field inference from color gradient illumination.”, *ACM Transactions on Graphics*, Vol.38, No.4, pp.1–12, 2019.
- [8] P. Ren, Y. Dong, S. Lin, X. Tong and B. Guo, “Image based relighting using neural networks”, *ACM Transactions on Graphics*, Vol.34, No.4, pp.1–12, 2015.
- [9] Z. Xu, K. Sunkavalli, S. Hadap, and R. Ramaamoorthi, ” Deep image-based relighting from optimal sparse samples” , *ACM Transactions on Graphics*, Vol.37, No.4, pp.1–13, 2018.
- [10] Z. Xu, S. Bi, K. Sunkavalli, S. Hadap, and R. Ramaamoorthi, ” Deep view synthesis from sparse photometric images” , *ACM Transactions on Graphics*, Vol.38, No.4, pp.1–13, 2019.
- [11] A. Chakrabarti, “Learning sensor multiplexing design through back-propagation”, In Proc. NIPS2016, pp.3081–3089, 2016.
- [12] S. Nie, L. Gu, Y. Zheng, A. Lam, N. Ono, and I. Sato, “Deeply learned filter response functions for hyperspectral reconstruction”, In Proc. IEEE CVPR 2018, pp.4767–4776, 2018.
- [13] C. A. Metzler, H. Ikoma, Y. Peng, and G. Wetzstein, “Deep optics for single-shot high-dynamic-range imaging”, In Proc. IEEE/CVF CVPR 2020, pp.1375–1385, 2020.
- [14] 王超, 川原僚, and 岡部孝弘, ” 表面材質識別のための照明環境と特徴抽出の同時最適化ネットワーク” , In Proc. CVIM2022, Vol.2022, No.29 pp.1–8, 2022.
- [15] O. Ronneberger, P. Fischer, and T. Brox, “U-net: Convolutional networks for biomedical image segmentation.”, In Proc. MICCAI 2015, pp.234–241, 2015.
- [16] T. Akiba, S. Sano, T. Yanase, T. Ohta, and M. Koyama, “Optuna: A next-generation hyperparameter optimization framework.”, In Proc. 25th ACM SIGKDD international conference on knowledge discovery & data mining, pp.2623–2631, 2019.
- [17] K. Xu, et. al., “Show, Attend and Tell: Neural Image Caption Generation with Visual Attention”, In Proc. ICML2015, pp.2048–2057, 2015.
- [18] D. Ulyanov, A. Vadaldi, and V. Lempitsky, “Instance normalization: The missing ingredient for fast stylization”, arXiv:1607.08022, 2016.
- [19] D. P. Kingma, and J. Ba, “Adam: A method for stochastic optimization”, In: Proc. ICLR2015, 2015.
- [20] K. He, X. Zhang, S. Ren, and J. Sun, “Delvin Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Clas-