

深層学習による異方性材質の双方向反射率分布関数の推定

寺田望[†] 清水郁子[†]

[†]東京農工大学 情報工学科

1 はじめに

コンピュータグラフィックスにおいて材質の外観をリアルに表現するために、材質の反射特性を表現するための双方向反射率分布関数 (Bidirectional Reflectance Distribution Function, 以下 BRDF) が用いられる。BRDF を表すモデルの進化により、適切なパラメータを与えれば比較的にリアルな材質の外観を表現できるようになったが、適切なパラメータを設定することは大変な作業である。そのため、近年、深層学習により画像の見え方と BRDF モデルのパラメータの関係を学習することで、一枚の画像から BRDF のパラメータを推定する研究が盛んに行われている。しかし、深層学習による手法では、学習用に含まれるデータセットに含まれる特定の BRDF モデルで表現可能な光学現象しか学習できないが、学習に利用可能なデータセットも少ないことから、最新的手法 [1] でも等方性の材質しか扱うことができない。

そこで、本稿では、一枚の画像から光学的に異方性の材質に対しても頑健な BRDF パラメータを推定することを目的とする。本手法は、等方性の材質に対して優れた推定性能を示した Deschaintre らの手法 [1] を拡張し、Disney Principled BRDF と呼ばれる異方性を扱える BRDF 用のパラメータマップを推定する。従来手法 [1] よりも複雑な BRDF モデルを扱うため、パラメータの推定がより困難になることが予想される。そのため、本手法では、従来手法 [1] の U-Net のスキップ接続部分に着目し、エンコーダとデコーダの特徴マップの意味的な違いを軽減するための改良 [2] を行う。学習に用いるデータセットは、Disney Principled BRDF モデルに基づき等方性および異方性のパラメータセットを生成し作成した。ネットワークの改良による異方性に関する推定性能の違いを示すため、合成データおよび実データを用いて実験を行った。本稿では代表的な結果を紹介する。

2 提案手法

提案手法は、深層学習による学習により、一枚の画像から異方性をもつ材質を扱える Disney Principled BRDF のパラメータを推定する。深層学習のネットワーク構造は Deschaintre らの手法 [1] をもとにするが、推定性能の向上のため、Ibtehaz ら [2] の提案している

Estimating Anisotropic Bidirectional Reflectance Distribution Functions with Deep-Learning

Nozomu TERADA[†] and Ikuko SHIMIZU[†]

[†]Faculty of Engineering, Tokyo University of Agriculture and Technology, 184-8588, Tokyo, Japan
s167935v@st.go.tuat.ac.jp

ResPath と呼ばれる U-Net のスキップ接続に関する改良を導入する。ネットワークの全体像を以下の図 1 に示す。

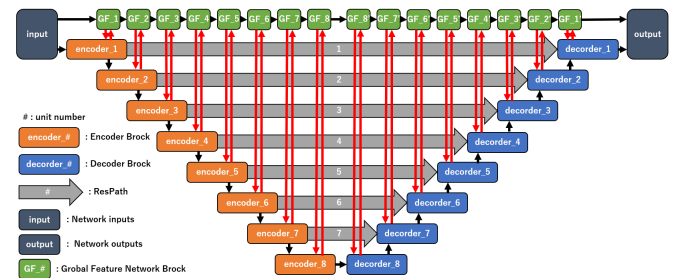


図 1: ネットワークの全体像

図 1 に示したように、オレンジと青のノードで表したエンコーダ及びデコーダに灰色矢印で示したスキップ接続がある U-Net と呼ばれるネットワークがベースとなっており、大域的な特徴を捉えるために Global Feature Network と呼ばれるサブネットワークがエンコーダ及びデコーダと密にやり取りしているような構造となっている [1]。このとき、U-Net におけるスキップ接続は同じ深さのエンコーダの特徴マップとデコーダの特徴を結合することで、出力の詳細を補う効果があるが、エンコーダの特徴マップはネットワークのより浅い層から計算されたものであり、逆にデコーダの特徴マップはネットワークのより深い位置から計算された物である。この違いにより、結合する特徴マップ同士の意味付けに矛盾が生じる可能性があり、学習全体に悪影響を与える可能性がある。そこで、[2] に従い、以下の図 2 に示すような、深さに応じた数の畳み込みを導入することでこの問題を軽減する。

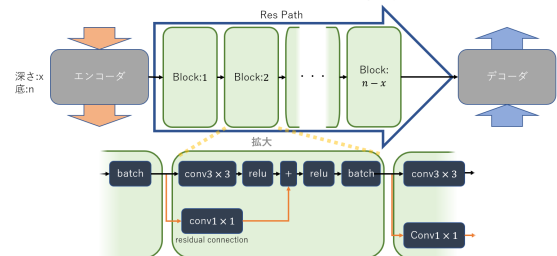


図 2: ResPath: 深さ x におけるスキップ接続の様子

図 2 における深さ x は図 1 中のスキップ接続を表すグレーの矢印中に記された数字に対応する。Res Path と呼ばれるスキップ接続は、同じ処理を行うブロックが深さに応じた数 $n-x$ だけ連なった形で表現できる。ブロック内の処理としては、 3×3 の畳み込みに Lelu 活性化関数が続くメイン経路と、 1×1 の畳み込みを持つ

スキップ接続が結合され、再び Leru 活性化関数を通した後にバッチ正規化が来るような形となっている。

損失関数は、従来手法 [1] と同様に、ネットワーク中で出力パラメータマップと正解パラメータマップをレンダリングし、その結果同士を比較した結果を用いる。なお、このレンダリングした結果同士を比較する損失関数は、BRDF のパラメータ推定を行うタスクにおいて一般的に使用されている。前述の通り、提案手法の損失関数の計算の際のレンダリングに用いる BRDF は、Disney Principled BRDF である。

3 実験

3.1 異方性に関するネットワークの改良の効果

学習に用いるデータセットは、Disney Principled BRDF モデルに基づき等方性および異方性のパラメータセットを生成して作成した。パラメータセット約 2000 個を生成し、これらの各データを 9 回ずつランダムに回転クロープして、計 20000 個の BRDF データを用意した。各 BRDF を 3 回ずつ異なる照明条件でレンダリングし、対応する BRDF データのペアで構成された計 60000 個のレンダリングされた画像データセットを作成した。

実験では、バッチサイズ 8 で学習を行い、固定学習率 0.00002 の Adam オプティマイザを使用した。なお、GTX1080Ti GPU を用いて収束までにおよそ 4 日程度要した。以下では、従来手法 [1] のネットワーク構造で学習を行った場合 (改良前) と提案手法の改良を行ったネットワーク構造で学習を行った場合 (改良後) の結果を示す。

合成データに関しては、異方性のデータを与えた際はどちらもうまく推定できているが、図 3 のような途中で異方性のハイライトが途切れるような入力等を与えた際、改良を行わないと異方性のパラメータ付けがあいまいになる傾向が確認された。

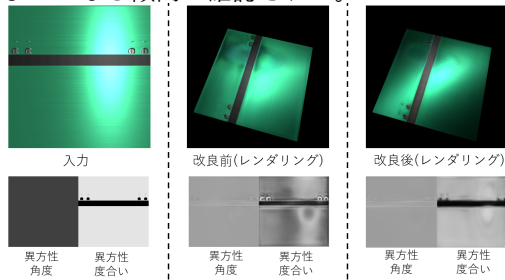


図 3: 合成データにおけるネットワークの改良前と改良後の出力の比較例

図 3 では、紙面の都合上推定した 13 種のパラメータの中から異方性に直接関連する異方性角度及び異方性度合いに関するパラメータマップのみを示している。改良前は異方性であると推定できているものの、異方性度合いのパラメータが入力のハイライトに強く影響されてしまっており、レンダリング結果の異方性があいまいなものとなっていることが確認できる。改良後は、異方性は推定できているが、角度が 45 度程度傾いていることが確認できる。

実データに関しては、提案手法でかなり頑健性が向上していることがわかった。図 4 のような明らかな異方性のある材質の画像を入力とした場合、改良前は異方性を推定できない場合が多かったが、改良を行うと異方性度合いに関して推定できるようになるものが多かった。なお、異方性角度に関しては、やはりうまく推定できていないため、ハイライトの伸びる方向は入力と異なっている。




図 4: 実データにおけるネットワークの改良前と改良後の出力の比較例

最後に、入力の異方性ハイライトが非常に強い場合の改良後ネットワークによる結果を図 5 に示す。異方性度合いのパラメータがかなり汚れた感じではあるが、有効になっていることから異方性であることは理解していると考えられるが、ベースカラーにかなり強く異方性ハイライトが残ってしまっており、レンダリングした結果が不自然である。




図 5: 強い異方性ハイライト

4 まとめ

本稿では、一枚の画像から深層学習により異方性に対応する Disney Principled BRDF モデルのパラメータ推定を行う手法を提案した。U-Net の改良を導入することにより実データに対する頑健性の向上が可能であることを示した。

参考文献

- [1] V. Deschaintre, et al, “Single-Image SVBRDF Capture with a Rendering-Aware Deep Network,” ACM Trans. Graph. 37, 4, Article 128, 15 pages (2018).
- [2] N. Ibtehaz, et al., “Multiresunet : Rethinking the u-net architecture for multimodal biomedical image segmentation,” Neural Networks, 121, pp.47–87 (2020).