

深層学習による凹凸の多い材質の双方向反射率分布関数の推定

山岸菜緒[†] スルタナレベッカ[†] 寺田望[†] 清水郁子[†]

[†]東京農工大学 知能情報システム工学科

1 はじめに

近年では様々な用途で CG が盛んに使用されるようになってきた。CG 作成に重要な反射特性は、双方向反射率分布関数 (Spatially-Varying Bidirectional Reflectance Distribution Functions, SVBRDF) により表現することができる。これまで多くのアーティストらによりたくさんの素材の SVBRDF を表すテクスチャデータが作成されてきたが、相互作用する数多くのパラメータのすべてにおいて、最もリアルに見える値を見つけ、適切に設定するのは非常に手間がかかる作業である。

近年、深層学習により SVBRDF を推定する手法が提案されている。例えば、Deschaintreら [1] は、フラッシュを照射して撮影した素材の 1 枚の入力からの推定に成功した。寺田ら [2] はこの手法を改良し、異方性のある金属のような素材に対しても推定が可能になる手法を提案した。さらに、穂苅ら [3] は光沢のある布に着目し、フラッシュを照射して撮影した画像と環境光のみで撮影した画像の 2 枚の入力を用いることで、光沢と模様情報を区別して推定可能な手法を提案した。しかし、これらの手法では、ニットのよう凹凸の多い布の推定性能向上には至っていない。

本手法では細かい凹凸が多いニットのよう素材を対象とし、フラッシュを照射して撮影した画像と環境光のみで撮影した画像の 2 枚を入力として、深層学習により SVBRDF を推定する手法を提案する。このとき、材質表面の局所的な法線の向きを表す normal マップの強度を変更することで多様性を増やしたデータセットを作成する。さらに、normal マップの代わりに材質表面の高さの情報を表す height マップを推定することでより安定な推定を行う手法を提案する。実験では、合成データと実データを用い、提案手法と従来手法により得られた結果を比較し、提案手法により凹凸の再現がよりよくできるようになり、レンダリング結果が改善していることを示す。

2 提案手法

本研究で用いる SVBRDF モデルは、寺田ら [2] が用いたデータセットを元にしており、Disney Principled BRDF と呼ばれるモデルに基づいており、anisotropic, basecolor, clearcoat, clearcoatGloss, metallic, rough-

Deep Learning Estimation of Bidirectional Reflectance Distribution Functions for Uneven Materials

Nao YAMAGISHI[†], Rebecca SULTANA[†], Nozomu TERADA[†] and Ikuko SHIMIZU[†]

[†]Faculty of Engineering, Tokyo University of Agriculture and Technology, 184-8588, Tokyo, Japan
s209099r@st.go.tuat.ac.jp

ness, sheen, sheenTint, specular, specularTint, subsurface の 11 種類のパラメータに normal, anisotropy-Angle の 2 つのパラメータを追加した 13 種類のパラメータからなる。材質は Anisotropy, Cleacoat, Fabric, Ground などの 15 種類からなる。

normal マップの多様性を増強するため、材質表面の起伏を表す normal マップを編集する。すべてのデータについて、normal マップの凹凸の強さを決めるパラメータ strength の値をデフォルトの 1.0 から 15 や 30 に変更したデータを追加してデータセットを作成した。図 1 に normal マップの strength を 15 倍、30 倍にした場合のデータの一例を示す。さらに、ニットのデータをデータセットに新たに追加した。Substance Designer というソフトでアーティストらが作成したデータを共有できる Substance Share と呼ばれるサイトのデータを用いてさらに回転等により増強して、約 10500 枚のニットのデータを追加した。

また、normal マップを、凹凸を直接表す height マップに変換して、学習や推定には height マップを用いる手法を提案する。normal マップは height マップの微分値であるため、学習や推定において直接 height マップ利用することで頑健性の向上が期待される。ただし、Disney Principled BRDF ではシェーディングの際に法線情報が必要になるため、シェーディングの前に height を normal に変換する。学習データセットのレンダリング、推定された出力 SVBRDF パラメータのレンダリング、合成入力データのレンダリングでは Blender の Cycle と呼ばれるレンダーを使用し、学習中のシェーディングでは Disney Principled BRDF の定義式を使用する。




図 1: strength を変更した場合の normal マップとレンダリング結果の一例。左が normal マップ、右が左の normal マップを使用してレンダリングした画像。

ネットワークは寺田ら [2] が提案したものを、穂苅ら [3] が入力画像の枚数を 2 枚に変更したのを使用する。ただし、穂苅ら [3] の論文で触れられている環境光に重きを置いた損失関数の追加は行っていない。このネットワークは U-net をベースとした構造であり、同じ層のエンコーダ・デコーダ間に ResPath と呼ばれるスキップ接続を導入することで、詳細な局所的情報も再現できるようにしている。また、大域特徴サブネットワークを導入することで、大域的な情報を伝播でき

らなっている。ネットワークへの入力は穂苅らと同様、フラッシュありの画像1枚と環境光のみの画像1枚の計2枚とする。出力は13枚のSVBRDFパラメータマップとなるが、データセットに使用されているのがnormalマップの場合はnormalマップを出力し、heightマップの場合はheightマップを出力する。

3 実験

normalマップの凹凸を大きくしたデータを追加して増強したデータセット、ニットのデータを追加したうえでnormalマップをheightマップに置き換えたデータセットについてそれぞれ学習を行い、評価した結果を示す。また、heightへの変換は行わずにニットのデータを追加しただけのデータセットの学習も行い比較した。図2と図3に評価用の実入力データ1と実入力データ2を示す。



図 2: 実入力データ 1



図 3: 実入力データ 2

凹凸のstrengthの値を大きくしたデータを追加して学習させたモデルと穂苅ら [3] のモデルの結果を比較した結果を図4と図5に示す。なお、結果は同じ照明条件下で2枚ずつレンダリング画像を作成している。また、それぞれのレンダリング画像の右に推定されたnormalマップを示す。提案手法の方がハイライトが強く出ていないことから、推定結果が平面ではなく、より凹凸が表れていることが分かる。また、normalマップを比較しても細かい部分の起伏が提案手法の方がより詳しく推定できている。一方で、入力データと比較するとハイライトは強く出ており、特に提案手法の方は反射の見た目が金属に近くなっている。これは異方性金属に着目して作成された寺田ら [2] のデータセットを使用しているため、金属の割合が高いデータセットになっており、さらにその割合を変えないままデータセットを3倍の大きさにしたため、布のデータと金属のデータの枚数の差が大きくなってしまったことが原因であると考えられる。

次に、データセットにニットのデータを追加したうえで、normalをheightに置き換えて学習させた場合の結果を図6と図7に示す。normalマップのまま学習した場合よりもheightに置き換えて学習したことにより細かい凹凸が表現できるようになり、強いハイライトが抑えられるようになった一方で、大きな高さの変化が表現できていないことが分かる。

4 おわりに

ニット特有の表現の難しさとして、材質表面に大きな凹凸から細かい凹凸まで様々な起伏が存在するという点があるが、2つの提案手法のそれぞれで1つずつ問題を解決することができた。データセットのnormalマップのバリエーションを増やすことでより凹凸の深さや高さを正確に推定できるようになった。また、heightマップを推定することで、より細かく詳細な凹凸まで推定できるようになった。提案手法ごとに推定性能の向上がみられたが、凹凸の深さや高さを正確に推定すること、詳細な凹凸まで推定することが一つのモデル




図 4: 実データによる比較 1. 上段が穂苅らの手法, 下段が提案手法.




図 5: 実データによる比較 2. 上段が穂苅らの手法, 下段が提案手法.




図 6: 実データによる比較 1. 上段が normal による推定結果, 下段が height による推定結果.




図 7: 実データによる比較 2. 上段が normal による推定結果, 下段が height による推定結果.

で両立できていないため、凹凸を大きくしたデータを追加したうえでheightに変換して学習を行うなど、推定方法とデータセットの見直しが必要であると考えられる。

また、データセットの金属の割合が依然として高く、推定パラメータのレンダリング結果の反射の様子が金属に近くなってしまうことから、金属と布のデータの割合も考慮すべきであると考えられる。

参考文献

- [1] V. Deschaintre, M. Aittala, F. Durand, G. Drettakis, and A. Bousseau, "Single-Image SVBRDF Capture with a Rendering-Aware Deep Network", *ACM Trans. Graph.* Vol. 37, No. 4, 2018.
- [2] Nozomu Terada, Ikuko Shimizu, "One-shot SVBRDF Estimation Including Anisotropic material", *ACM SIGGRAPH European Conference on Visual Media Production*, 2021.
- [3] 穂苅彩音, 寺田望, 清水郁子, "深層学習による光沢のある布の双方向反射率分布関数の推定", 情報処理学会全国大会, 2023.