

参照画像を用いた霧パラメータの推定に関する一検討

新重 俊樹^{1,a)} 土橋 宜典^{1,b)}

概要: CG を用いて霧を表現するためには、消散係数や散乱アルベド等のパラメータを適切に設定する必要がある。しかし、ユーザが望む外観の霧を得るためには、パラメータを設定してレンダリング結果を確認しながら調整していくという試行錯誤が避けられない。CG 画像の生成は計算コストが高いため、この作業には多大な手間と時間を要する。特に、霧などの関与媒質 (participating media) は内部での複雑な散乱現象を計算する必要がある。そこで本研究では、所望の外観の霧を得るための霧パラメータを自動的に求める手法の開発を目指す。本稿では、霧パラメータを指定してレンダリングした CG 画像を参照画像として、その霧パラメータを区間推定により推定を行う。これにより、区間推定による霧パラメータ推定の有効性を調査する。

キーワード: 霧, 関与媒質, インバースレンダリング

Abstract: In order to render realistic fog using CG, it is necessary to choose parameters such as attenuation coefficient and scattering albedo appropriately. Moreover, a tedious trial-and-error process is inevitable to produce the desired effect of fog; we need to render an image with different parameter settings until the desired result is obtained. Due to the high computational cost for generating CG images, this process requires much time and effort. The computational cost is prohibitive when considering the complex scattering phenomena inside the participating media, such as fog. This study aims to develop a method to automatically calculate fog parameters to obtain a fog with the desired appearance. This paper estimates the fog parameters by interval estimation using a CG image rendered with the fog parameters specified as a reference image. In this way, we investigate the effectiveness of fog parameter estimation by interval estimation.

Keywords: fog, participating media, Inverse Rendering

1. まえがき

コンピュータグラフィックス (CG) において、雲や霧などの空間中で光と相互作用を起こす物質を関与媒質 (participating media) とよぶ。このような関与媒質はリアルで雰囲気のある CG 映像を作成するのに重要な役割を果たし、薄明光線などの美しい大気光学現象を表現する際にも必要となる。本研究では関与媒質のうち、霧について扱う。

CG で霧を表現するには、消散係数や散乱アルベド、位相関数等のパラメータを調整することで霧の外観を定める。よって、ユーザが望んでいる外観の霧を得るためには、レンダリング結果を逐一確認しながら霧のパラメータを調整していく必要がある。一方で、霧に入射した光は内部で散乱を繰り返すため、リアルな霧を表現するためには

この複雑な散乱過程を正確に計算する必要がある。これは計算コストが非常に大きいため、霧のパラメータを調整するために毎回レンダリングを行うには多大な時間と労力を要する。

我々はこの課題を解決するため、適切な霧のパラメータを自動的に決定する手法について研究を行っている。本稿では1枚の参照画像から霧パラメータの推定を行い、目的の外観を再現する実験を行った報告をする。

2. 関連研究

靄や霞、霧などのヘイズの密度推定と、関与媒質のレンダリングパラメータの推定に関する関連研究について議論する。

画像から霧などのヘイズを除去する Dehazing という研究が広く行われており、この Dehazing の精度を上げるためにヘイズの密度を推定する手法がいくつか提案されている。Choi らは画像の統計的特徴を用いてヘイズの密度を予測するモデルを提案した [1]。また、Zhang らは CNN

¹ 北海道大学
Hokkaido University

a) shinju@ime.ist.hokudai.ac.jp

b) doba@ime.ist.hokudai.ac.jp

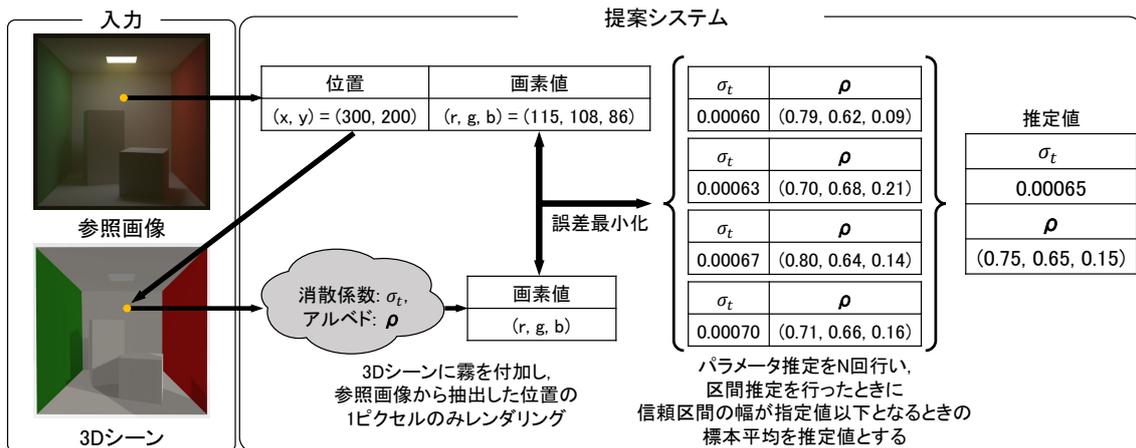


図 1: 提案法の概要

ベースの深層学習によってヘイズ密度を推定する手法を提案した [2]. しかし, これらの手法は人間が知覚したときのヘイズ密度を推定するものであり, この密度をレンダリングパラメータとして用いることはできない.

画像から反射率やジオメトリ, 照明などを推定する問題を Inverse Rendering とよぶ. その内, 画像から関与媒質のレンダリングパラメータを推定する手法がいくつか提案されている. Dobashi らは参照画像の外観に近い雲のレンダリングパラメータを推定する手法を提案した [3]. また, Adolf らは厚く均質な半透明物体における反射率特性の推定を行う手法を提案した [4]. Che らは半透明物体の反射率特性の推定に深層学習を用いることで, 完全に未知の形状と照明を持つ画像に対しても高精度な推定結果を得ることに成功した [5]. しかし, これらの手法は雲や半透明物体のレンダリングパラメータを推定するものであり, 霧に着目したものではない.

3. 提案法の基本的考え方

提案法の概要を図 1 に示す. 本研究の目的は霧を含む画像が与えられた場合に, 霧の光学パラメータを推定することである. このとき, 霧以外の情報 (物体の 3 次元形状や反射率あるいはカメラパラメータなど) は与えられるものとする. ユーザは, 霧のない画像に画像処理やペイント操作などによって目的の霧の効果を付与することを想定するが, 本稿では, その事前調査として, 真の光学パラメータが既知の場合についてのみ実験を行っている. 霧の密度は一樣でその散乱特性は等方性を仮定し, 散乱アルベドと消散係数を推定する. 散乱アルベドは RGB に対応する波長でサンプルし, 消散係数は波長に依存しないものとする.

提案法では, 霧の光学パラメータを設定して作成した画像 (以下, CG 画像と呼ぶ) と入力画像との誤差を最小とする最適化問題を解く. このとき, CG 画像と入力画像の誤差として, 全ピクセルの平均二乗誤差が多く用いられている. しかし, この場合, パラメータを設定するたびに,

CG 画像の全てのピクセルの輝度値を計算しなければならず, 極めて計算コストが高い. そのため, できるだけ少ないピクセルのみを用いて光学パラメータを推定できれば計算コストの削減につながる. そこで本稿では, 1 ピクセルのみを用いた光学パラメータの推定可能性について調査する. 具体的には, 選択するピクセルの位置に応じた推定精度の変化を調査する.

3.1 霧のレンダリング

関与媒質内を伝わる光は光輸送方程式によって記述される. 媒質に入射した光はその内部で多重の散乱を繰り返す. 本研究では密度分布は均一で等方散乱を仮定している. このとき, 媒質の外部に放出された光が再び媒質に入らないと仮定すると, 光輸送方程式は次のように書ける.

$$dL(x, \vec{\omega}) = -\sigma_t L(x, \vec{\omega}) \quad (1)$$

ここで, $L(x, \vec{\omega})$ は媒質内の点 x において特定の方向 $\vec{\omega}$ に向かって入射する光の放射輝度を表し, σ_t は消散係数を表す. 消散係数は, 次式に示すように, 単位距離あたりに吸収される光の割合である吸収係数 σ_a と単位距離あたりに散乱される光の割合である散乱係数 σ_s の和で表すことが出来る.

$$\sigma_t = \sigma_a + \sigma_s \quad (2)$$

一方, 散乱アルベド ρ は次式で定義される.

$$\rho = \frac{\sigma_s}{\sigma_t} \quad (3)$$

提案法では, 上述した消散係数 σ_t と散乱アルベド ρ を推定する.

霧のレンダリングには, 最も単純なパストレーシング法を用いる. まず, 視点から各ピクセルと通過するレイを生成する. このレイ上において, 光の散乱を生じる位置を消散係数をもとにして確率的に決定する. 次に, その点において, 散乱方向をやはり確率的に決定し, 新たなレイを生

成する。ただし、できるだけ光源方向に向けたレイが生成されるような確率分布を設定する。また、散乱アルベドに応じて光のエネルギーは減少する。この処理を繰り返し、レイが光源に交差するか、指定された散乱回数に達するまで繰り返す。以上の方法によって、視点から各ピクセルを通過する多数のパスを生成し、その輝度の平均値を求める。計算精度は、各ピクセルに生成するパスの数によってコントロールできる。

3.2 目的関数の最小化

提案法では、次の目的関数 O を最小化するパラメータを探索する。

$$O = (I_{usr}(p) - I_{cg}(p, \sigma_t, \rho))^2 \quad (4)$$

ここで、 I_{usr} は入力として与えた参照画像、 I_{cg} はレンダリングによって生成される画像、そして p は指定した画素を表す。ただし、今回推定するのは消散係数と散乱アルベドの RGB 成分の 4 変数であり、これらをグリッドサーチにより全組み合わせを探索するのは計算コストが非常に大きく現実的ではない。そこで、消散係数に関する最小化と散乱アルベドに関する最小化を交互に繰り返す。ただし、本稿では、複数回の繰り返しを行っても改善はみられなかったため、繰り返し回数は 1 回のみとした。また、消散係数の推定では I_{usr} と I_{cg} の値をグレースケール (CIEXYZ 表色系の Y 値) に変換して最小化を行い、散乱アルベドについては RGB の成分ごとに最小化を行う。

3.3 区間推定によるパラメータ推定

パストレーシングの特性上、目的関数の最小化により得られるパラメータにはバラつきがある。1 ピクセル当たりのサンプル数を大きくすることでこのバラつきは小さくなり推定精度を上げることができるが、その分計算コストが高くなる。よって、ユーザにより指定される推定精度を満たす最小限のサンプル数で推定を行うことが望ましい。本研究では、区間推定を用いた手法について検討する。ユーザは信頼区間の幅を指定することで推定精度を制御し、その精度を満たすできるだけ少ないサンプル数でパラメータの推定を行う。

母分散が未知の場合に母平均の区間推定を行う場合、その信頼区間は次式となる。

$$\bar{x} - t_{\frac{\alpha}{2}}(n-1)\sqrt{\frac{s^2}{n}} \leq \mu \leq \bar{x} + t_{\frac{\alpha}{2}}(n-1)\sqrt{\frac{s^2}{n}} \quad (5)$$

ただし、 μ は母集団の平均、 \bar{x} は標本平均、 s^2 は不偏分散、 n はサンプルサイズ、そして $t_{\frac{\alpha}{2}}(n-1)$ は自由度が $n-1$ の t 分布において上側確率が $\frac{\alpha}{2}$ となる値を示す。ここでは目的関数の最小化によるパラメータ推定を n 回行い、そのパラメータに関して区間推定を行う。ユーザは信頼区間の幅



図 2: 実験に使用した参照画像 左:薄い霧 右:濃い霧

$2t_{\frac{\alpha}{2}}(n-1)\sqrt{\frac{s^2}{n}}$ を指定し、求めた信頼区間がこの幅未満になるまで 1 ピクセル当たりのサンプル数を増やしながら区間推定を繰り返す。そして、条件を満たしたときの標本平均をパラメータの推定値とする。これにより、ユーザが精度を制御したパラメータ推定が可能となる。

4. 実験

提案法を用いた実験の結果を示す。実験には Intel Core i7-9750H 2.60GHz を搭載した計算機を使用した。目標となる参照画像として、コーネルボックスのシーンに対して消散係数と散乱アルベドを指定した霧を付加してレンダリングした画像を用いた。このとき画像サイズは 100×100 である。本実験では、目的関数を最小化する際に用いるピクセルの位置の計算精度に対する影響を調査した。区間推定を行う際のサンプルサイズは $n = 100$ として 95%信頼区間を計算し、その信頼区間の幅が指定値以下になるまで 1 ピクセル当たりのサンプル数を 50 ずつ増やしながら区間推定を繰り返した。信頼区間の幅は、消散係数の推定時は 0.0001、アルベドの推定時は 0.1 と指定した。

図 2 左に示す薄い霧のかかった CG 画像を参照画像とした場合について、提案法による推定値と真値の二乗誤差を図 3 に、推定値の不偏分散を図 4 に示す。推定値の不偏分散は、1 ピクセル当たりのサンプル数を 100 に固定し、目的関数の最小化を用いてサンプルした 100 個の推定値の不偏分散を求めた。図 3 を見ると、消散係数の推定では直接光が当たっている部分のピクセルを選んだときは推定精度が良く、影となっている部分や間接光が当たっている部分のピクセルを選んだときは推定精度が悪くなる傾向がみられる。またアルベドの推定では、アルベドの R 成分を推定する際は赤色の壁に対応するピクセルでの推定精度が悪くなり、アルベドの G 成分を推定する際は緑色の壁に対応するピクセルでの推定精度が悪くなっている。これらのことから、推定するアルベドの色成分が背景色に近いとき推定精度が悪くなる傾向がみられる。また、図 4 から、推定値の不偏分散についても同様の傾向がみられることがわかる。

次に、図 2 右に示す濃い霧のかかった CG 画像を参照画像とした場合の実験結果を図 5 および図 6 に示す。全体的

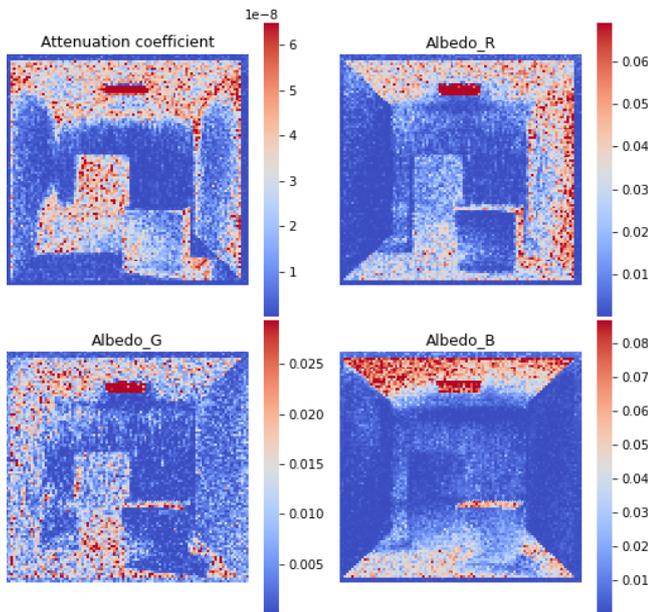


図 3: 薄い霧画像での推定値と真値の二乗誤差

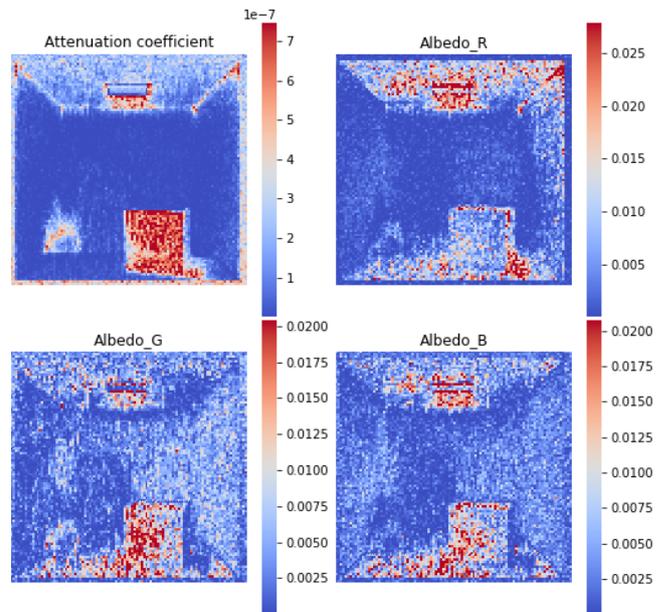


図 5: 濃い霧画像での推定値と真値の二乗誤差

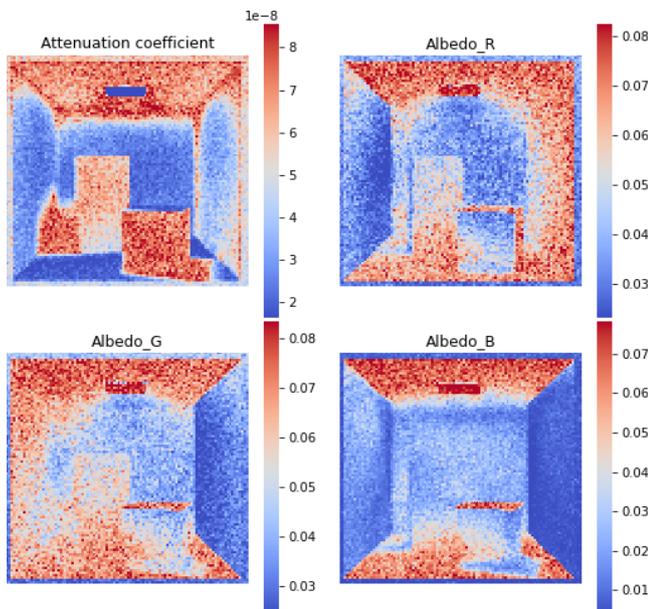


図 4: 薄い霧画像での推定値の不偏分散

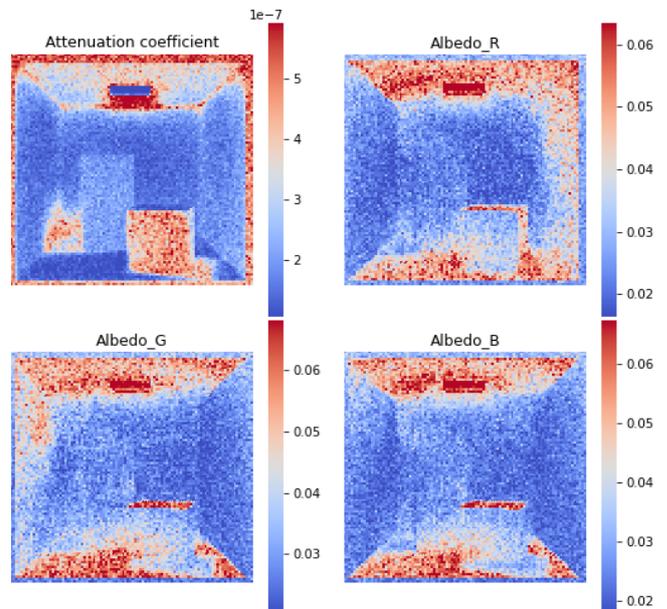


図 6: 濃い霧画像での推定値の不偏分散

な傾向は薄い霧の場合と同じだが、霧による減衰のため、背景色の影響が弱まることから、背景色が推定精度に与える影響が小さくなっていることが分かる。

5. 考察とまとめ

本稿では、参照画像に示された所望の外観の霧を再現するために、霧の光学パラメータである消散係数と散乱アルベドの推定に関する実験を行った。その結果、推定に用いるピクセル位置によって推定精度が変化することが確認された。

今後の課題として、目的関数を最小化する際の最適化手法の改善や、異方性散乱を表現するために位相関数もパラメータに加えた手法の開発が必要である。また、入力とし

て用いる参照画像を簡易的な画像処理によって作成する方法についても検討したい。

参考文献

- [1] Lark Kwon Choi, Jaehee You, and Alan Conrad Bovik. Referenceless prediction of perceptual fog density and perceptual image defogging. *IEEE Transactions on Image Processing*, Vol. 24, No. 11, pp. 3888–3901, 2015.
- [2] Jiahe Zhang, Xionghuo Min, Yucheng Zhu, Guangtao Zhai, Jiantao Zhou, Xiaokang Yang, and Wenjun Zhang. Hazdesnet: An end-to-end network for haze density prediction. *IEEE Transactions on Intelligent Transportation Systems*, pp. 1–16, 2020.
- [3] Yoshinori Dobashi, Wataru Iwasaki, Ayumi Ono, Tsuyoshi Yamamoto, Yonghao Yue, and Tomoyuki Nishita. An inverse problem approach for automatically

adjusting the parameters for rendering clouds using photographs. *ACM Trans. Graph.*, Vol. 31, No. 6, November 2012.

- [4] Adolfo Munoz, Jose I. Echevarria, Francisco Seron, Jorge Lopez-Moreno, Mashhuda Glencross, and Diego Gutierrez. BSSRDF estimation from single images. *Computer Graphics Forum*, Vol. 30, pp. 455–464, 2011.
- [5] Chengqian Che, Fujun Luan, Shuang Zhao, Kavita Bala, and Ioannis Gkioulekas. Towards learning-based inverse subsurface scattering. In *2020 IEEE International Conference on Computational Photography (ICCP)*, pp. 1–12, 2020.