

濃淡画像からのガウス曲率の復元精度向上手法

Increasing Accuracy for Gaussian Curvature from Shading Images

中川 貴規 † 岩堀 祐之 † 福井 真二 ‡ 河中 治樹 ††
Takashi Nakagawa Yuji Iwahori Shinji Fukui Haruki Kawanaka

1 はじめに

3次元形状情報である曲率情報は視点に依存しない情報であるため、物体認識、姿勢推定、特徴抽出などコンピュータビジョンの分野において重要な情報である。複数枚の濃淡画像を用いてガウス曲率を復元する手法として、Wolff, Fanらにより、3方向の異なる照明条件下で撮影された3枚の濃淡画像から物体の任意の点とその近傍点の観測画像濃度から3次元画像濃度空間でのそれらの位置関係を用いて、物体面の傾きを求めることなくガウス曲率の符号を直接求める手法を提案している [1] [2]。また、岡谷, 出口らは3方向の光源方向や物体面の反射率の知識無しで、3枚の濃淡画像から滑らかな物体面のガウス曲率の符号を求める手法 [3] を提案している。また、Angelopoulou, Wolffらは3枚の濃淡画像から任意の点と近傍点の濃淡情報からガウス曲率の符号を決定する手法 [4] を提案している。しかし、これらの手法は拡散面を対象としており、鏡面反射成分をもつ物体には適用することができない。

他方、岩堀, 福井らは、反射係数が異なる物体面を対象として、RBFニューラルネットワークを用いて複数枚の濃淡画像から局所曲面の分類およびガウス曲率の相対的な大きさ復元する手法を提案している [5] [6]。

本研究では、文献 [6] を鏡面反射成分とテクスチャのあるカラー物体にも適用できるように拡張すると共に、RBFニューラルネットワークを用いてガウス曲率の復元精度を向上する手法を提案する。本手法をもとにシミュレーション画像および実物体を対象に評価を行い、その有用性を示す。

2 ガウス曲率の相対的な大きさの近似値の復元

本研究では文献 [6] の手法を拡張してガウス曲率の相対的な大きさを復元する。そのため、背景知識として、この手法の原理について説明する。

2.1 復元対象物体の任意の点を球上への写像をするニューラルネットワーク

経験的照度差ステレオ法では形状既知物体として、復元対象物体と同じ反射特性の球をカメラを固定し、異なる3方向以上の光源の下で撮影した観測画像輝度値を用いる。この観測画像輝度値はモノクロ濃淡画像とし、このときの球の観測画像輝度値の組を $\{(e_1(x_{sph}, y_{sph}), e_2(x_{sph}, y_{sph}), e_3(x_{sph}, y_{sph}))\}$ 、球画像上の座標を (x_{sph}, y_{sph}) とする。経験的照度差ステレオ法では、観測画像輝度値から表面法線ベクトルを復元しているが、文献 [6] では、観測画像輝度値の組 e_{sph} を入力、




図1 面積値の計算手法

球画像上の座標 (x_{sph}, y_{sph}) を出力として RBF ニューラルネットワークで学習を行う。学習後の RBF ニューラルネットワークに復元対象物体の観測画像輝度値の組 $\{e_1(x_{obj}, y_{obj}), e_2(x_{obj}, y_{obj}), e_3(x_{obj}, y_{obj})\}$ を入力することにより、復元対象物体の任意の点 (x_{obj}, y_{obj}) に対応する表面法線ベクトルをもつ球上の座標 (x_{sph}, y_{sph}) に写像することができる。

$$\begin{cases} e_1(x_{obj}, y_{obj}) = e_1(x_{sph}, y_{sph}) \\ e_2(x_{obj}, y_{obj}) = e_2(x_{sph}, y_{sph}) \\ e_3(x_{obj}, y_{obj}) = e_3(x_{sph}, y_{sph}) \end{cases} \quad (1)$$

2.2 ガウス曲率の相対的な大きさの近似値の算出

復元対象物体の任意の点とその近傍4点を2.1節の手法を用いて RBF ニューラルネットワークにより球上に写像する。その近傍4点に囲まれた四角形の面積 S がガウス曲率の相対的な大きさとなる。

曲面 $z = f(x, y)$ のガウス曲率の値は式 (2) により求めることができる。

$$G = \frac{1}{1 + f_x^2 + f_y^2} \begin{vmatrix} f_{xx} & f_{xy} \\ f_{yx} & f_{yy} \end{vmatrix} \quad (2)$$

ここで、 $f_x = \partial z / \partial x$, $f_y = \partial z / \partial y$, $f_{xy} = f_{yx}$ である。

一方、復元対象物体の近傍4点を球上に写像したときの近傍4点を作る四角形の面積は図 1(a) のように球上の点を平面に射影したときの面積値を考える。この四角形の作る面積 S は図 1(b) としたとき、① → ③ を結ぶ直線を a 、② → ④ を結ぶ直線を b とする。このとき、四角形の面積 S の計算式は式 (3) のようになる。

$$\begin{aligned} S &= \frac{1}{2} |a||b| \sin \theta \\ &= \frac{1}{2} |a \times b| \\ &= \frac{1}{2} (4\delta x \delta y) (f_{xy}^2 - f_{xx} f_{yy}) \end{aligned} \quad (3)$$

式 (2) と式 (3) の間には、相対的な関係があることがわかる。これより、任意の点の近傍4点を球上に写像したときにできる四角形の面積が、ガウス曲率の相対的な大きさの近似値を表す。

† 中部大学 Chubu University

‡ 愛知教育大学 Aichi University of Education

†† 愛知県立大学 Aichi Prefectural University




図2 復元対象物体の任意の点を球上に写像する RBF-NN

3 鏡面反射成分を持つテクスチャのあるカラー画像への拡張

文献 [6] の手法では 3 枚 (3 光源) のモノクロ濃淡画像からガウス曲率の相対的な大きさ情報を取得している。学習には RBF ニューラルネットワークを用い、入力データを復元対象物体と同じ反射特性の球の観測画像輝度値の $\{e_1(x_{sph}, y_{sph}), e_2(x_{sph}, y_{sph}), e_3(x_{sph}, y_{sph})\}$ とし、出力データを球上の対応する座標の (x_{sph}, y_{sph}) として与えていた。本研究では復元対象物体を鏡面反射成分を持つカラー物体としている。経験的照度差ステレオ法は鏡面反射成分を持つ物体に対して適用を行うと復元精度が低下する。また、カラー画像化による復元精度の低下も考えられるため、本研究では異なる 4 光源の条件下で撮影された 4 枚の画像を用いることとする。

本手法ではカラー画像を式 (4) によりグレースケール変換を行う。

$$e = 0.2989 \times e_R + 0.5866 \times e_G + 0.1145 \times e_B \quad (4)$$

しかし、このままでは反射率 ρ の影響を受けるため、復元対象物体の任意の点を球上の座標に正しく写像できず、ガウス曲率の値を復元することができない。

観測画像輝度値 e は視点と光源方向を固定された状態のとき式 (5) で表せる。

$$e = \rho R(n) \quad (5)$$

このときの R は物体の反射特性を、 $n = (n_x, n_y, n_z)$ は表面法線ベクトルを示す。これより、方向が異なる 4 つの光源の下で撮影すると、

$$\begin{bmatrix} e_1 \\ e_2 \\ e_3 \\ e_4 \end{bmatrix} = \begin{bmatrix} \rho R_1(n) \\ \rho R_2(n) \\ \rho R_3(n) \\ \rho R_4(n) \end{bmatrix} \quad (6)$$

からなる画像照度方程式が成り立つ。この式を変形すると、

$$e_1 + e_2 + e_3 + e_4 = \rho(R_1 + R_2 + R_3 + R_4) \quad (7)$$

となるので、

$$e'_i = \frac{e_i}{e_1 + e_2 + e_3 + e_4} \quad (i = 1, 2, 3, 4) \quad (8)$$

となり、観測画像輝度値を式 (4) でグレースケール化した後に、式 (8) の変換を行うことにより、反射率 ρ を消去することができる。

図 2 のように、入力データを e' の組、出力を球の座標 (x, y) とするニューラルネットワークを構築することにより、復元対象物体がカラー物体のときでもその物体の任意の点を球上の座標に写像でき、ガウス曲率の相対的な大きさの近似値を復元することができる。




図3 基底関数のガウス曲率




図4 基底関数を作成する RBF-NN

図5 評価値 C を求める RBF-NN

4 修正ニューラルネットワーク

本節では文献 [6] の手法により求めたガウス曲率の相対的な大きさの近似値の復元精度を向上させるニューラルネットワークとして修正ニューラルネットワークを提案する。

ガウス曲率の相対的な大きさの近似値は、復元対象物体の任意の点を球上に写像するときの誤差や、面積値を計算する際の誤差などが含まれている。このような誤差を改善し、ガウス曲率の復元精度を向上するために RBF ニューラルネットワークについて述べる。

ここでは様々なガウス曲率を学習することを目的として、式 (9) の基底関数 $f(x, y)$ を導入する。

$$f(x, y) = \alpha(\cos x \times \cos y) \quad \left(-\frac{\pi}{2} < x, y < \frac{\pi}{2}\right) \quad (9)$$

基底関数の $\alpha = 1, 10$ のときのガウス曲率の真値を図 3 に示す。ガウス曲率の符号 (ならびに局所曲面分類) 文献 [5] の手法により分類することができるが、復元されるガウス曲率の値は面積値であるため、ガウス曲率の値はその絶対値として取り扱うことになる。この基底関数は図 3 のように α の値を変化させることによりさまざまなガウス曲率の値をとることができる。ここでは $\alpha = 0.5, 1, 5, 10, 15$ の時の基底関数を用いて修正ニューラルネットワークの学習点の作成を行う。

この基底関数についても復元対象物体の座標を球上の座標に写像する際の誤差を修正することを考えると、復元対象物体と同じ反射特性である必要がある。同時に、復元対象物体と同じ光源方向での画像が必要である。これらの条件を満たす基底関数の画像を作成するために、復元対象物体の任意の点を球上の座標に写像するニューラルネットワークで学習に用いた球画像から、球の表面法線ベクトルを入力、球の観測画像輝度値 e を出力とする図 4 に示す RBF ニューラルネットワークを構築した。学習後の RBF ニューラルネットワークに基底関数の法線ベクトルを入力することにより、復元対象物体と同じ反射特性、同じ光源方向の画像を作成した。このニューラルネットワークの学習条件は学習回数を 200 回、スレッド定数は観測画像輝度値が 0~1 の範囲に正規化し

であるため, 0.4 とした. 基底関数の α の値を大きくすると, 本来, 影となる領域ができ, そこではニューラルネットワークで輝度値 e を正しく生成できないことがある. それらの点においては, 輝度値 e をもとに, 式 (8) により, 反射率を消去した e' に変換し, 復元対象物体の任意の点を球上の座標 (x_{sph}, y_{sph}) に写像する図 2 のニューラルネットワークを用いても, 間違った球上の点に写像してしまう. このような点は修正ニューラルネットワークの学習点としてふさわしくない.

そこで, このような点を学習点から除外するために, 復元対象物体の任意の点を球上の座標に写像するニューラルネットワークの逆変換を行うニューラルネットワークを構築した. つまり, 球上の座標 (x_{sph}, y_{sph}) を入力, 式 (8) を用いて反射率 ρ を消去した e' を出力として RBF ニューラルネットワークで学習を行った. このニューラルネットワークは $(x_{sph}, y_{sph}) \rightarrow e'$ という変換を行う. 図 5 のように, e' の組から球上の座標 (x_{sph}, y_{sph}) を得るニューラルネットワークと, その逆変換を行うニューラルネットワークを 2 段結合した $(e'_1, e'_2, e'_3, e'_4) \rightarrow (x_{sph}, y_{sph}) \rightarrow (e''_1, e''_2, e''_3, e''_4)$ の変換を行う. 基底関数の任意の点に対して, この 2 段結合ニューラルネットワークを用いて得られる e'' を用いて, 局所的な信頼性の評価値 C を式 (10) により評価した.

$$C(x_{kitei}, y_{kitei}) = \sum_{i=1}^4 |e'_i(x_{kitei}, y_{kitei}) - e''_i(x_{kitei}, y_{kitei})| \quad (10)$$

信頼性の評価値 C が 0.1 以上のときには, 信頼できない点とし, 任意の点およびその近傍四点の中で面積値を計算する際に一つでも信頼できない点を参照する場合には修正ニューラルネットワークの学習点から除外した.

基底関数の画像サイズは 256×256 で, $\alpha = 0.5, 1, 5, 10, 15$ の 5 種類の基底関数の値を用いるため, 学習点は $256 \times 256 \times 5$ の 327,680 組得られるが, 実際には学習に用いるサンプルデータの取り方が重要である. 図 3 より, ガウス曲率の値が大きくなるほど, 学習点を得られる数が少ないことがわかる. そのため, 修正ニューラルネットワークで用いる学習点が不均一にならないように, サンプルングを行った. まず, 学習点をガウス曲率の真値でソートした. ガウス曲率の真値が 0.7 未満の時は, すべての基底関数から学習点を得られ, 学習点の密度が非常に高いため, 60 点間隔で, 0.7 以上 3.0 以下のときは $\alpha = 5, 10, 15$ の 3 つの基底関数から学習点を得られるため 4 点間隔で, それより大きいときは学習データが非常に少ないのですべての点を学習点としてサンプルングを行った. その結果, 学習点の数は 2225 点となった. このとき, 選ばれた学習点を横軸にガウス曲率の相対的な大きさを, 縦軸にガウス曲率の真値を取ってプロットしたものを図 6 に示す.

復元したガウス曲率の相対的な大きさとガウス曲率の真値との間には図 6 のような関係があることがわかる. この関係は, パラメトリック曲線を仮定して, その近似曲線を求めることができるが, パラメータ付のモデルを仮定する必要があることや, そのモデルによる誤差が発生する問題がある. そのため, 本手法ではノンパラメトリックな手法のニューラルネットワークを用いてガウス曲率値の修正を行った. 基底関数のガウス曲率の相対的な値を入力, ガウス曲率の真値を出力として学習を行




図 6 修正 NN の学習点




図 7 修正 NN

う. 学習後の RBF ニューラルネットワークに復元対象物体のガウス曲率の相対的な大きさを入力とすることにより, より精度の高いガウス曲率の情報が得られる.

5 実験

5.1 シミュレーション実験

シミュレーション実験では復元対象物体を式 (11) で表される曲面 $g(x, y)$ とし, この曲面の α を 0.5, 1, 1.5 と変化させてシミュレーション実験を行った.

$$g(x, y) = \alpha \left(\frac{\sin x}{x} \times \frac{\sin y}{y} \right) \quad (-2\pi < x, y < 2\pi) \quad (11)$$

このとき, この曲面 $g(x, y)$ は Phong のモデルで作成した. また, カラー画像に拡張できることを示すために, 作成したシミュレーション画像を 4 分割し, それぞれ異なる反射率 ρ をかけた. シミュレーション実験において, 復元対象物体の任意の点を球上の座標に写像する RBF ニューラルネットワークの学習条件は学習回数 200 回, スプレッド定数を学習の入力データが式 (8) により 0~1 に正規化されているため 0.4 とした.

修正ニューラルネットワークの学習条件は学習回数 100 回, 入力データのガウス曲率の相対的な大きさは 0~12612 を取るため, スプレッド定数は最大値の約 1/2 の 6000 とした.

本実験の誤差評価は平均誤差 ϵ_1 を式 (12) より, 相対誤差 ϵ_2 を式 (13) より求めた. このとき, ニューラルネットワークの出力データとガウス曲率の真値は共に 0 から 1 の範囲で正規化を行った.

$$\epsilon_1 = \frac{1}{N} \sum_{i=1}^N |T_i - R_i| \quad (12)$$

$$\epsilon_2 = \frac{1}{N} \sum_{i=1}^N \left| \frac{T_i - R_i}{T_i} \right| \times 100[\%] \quad (13)$$

ただし, T_i はガウス曲率の理論値, R_i は復元したガウス曲率の相対的な大きさを示す. 復元したガウス曲率の値を Y 軸方向に平均誤差 ϵ_1 を取って二次元プロットしたものを図 8 に示す. 図中の before は修正ニューラルネットワーク適用前の適用前, after は修正ニューラルネットワーク適用後の値を示している. また, 誤差評価を行った結果を表 1 にまとめた.

表 1 および図 8 より, sinc 関数の α が 0.5, 1, 1.5 のすべての場合において相対誤差および相対誤差が少なくなっていることがわかる. 修正ニューラルネットワークを用いることにより, ガウス曲率の相対的な大きさの復元精度が向上することが確認された. また, テクスチャのあるカラー物体を対象に適用可能なことも確認できた.

表1 ガウス曲率の復元精度評価

		$\alpha = 0.5$	$\alpha = 1.0$	$\alpha = 1.5$
修正 NN 適用前	ϵ_1	0.0165	0.0305	0.0356
	ϵ_2 [%]	18.2	35.3	43.8
修正 NN 適用後	ϵ_1	0.0119	0.0112	0.0055
	ϵ_2 [%]	14.8	13.6	8.8

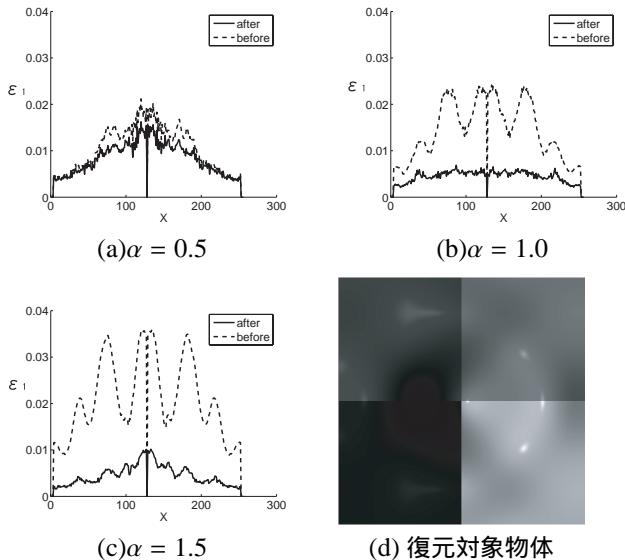


図8 ガウス曲率の平均誤差

5.2 実物体への適用

次に、本手法を実物体に対して適用を行った。復元対象物体は鋭い鏡面反射成分を持つテクスチャのあるカラー物体として、図9(a)に示す物体を用いた。シミュレーション画像はモデルを用いて生成したものの、実際の物体ではモデルはとくに仮定する必要はなく同じ照明条件(光源条件)のもとで4枚ずつカラー画像を撮影した。また、学習用の球と、復元対象物体は同じ反射特性である必要があるため、復元対象物体と球とは塗料で塗装を施し、球は白の塗料で塗装を施した。

また、復元対象物体と背景は容易に分離できるものとし、撮影した4光源分画像を 3×3 のメディアンフィルタに通した後に、4光源のうち1光源でも0.08(輝度値は0~1に正規化されている)以下の場合、背景とし、それ以外を物体として背景との分離を行った。

復元対象物体の任意の点を球上に写像するニューラルネットワークの学習条件は学習回数200回、スプレッド定数をシミュレーション実験と同様の理由より0.4とした。また、修正ニューラルネットワークの学習条件は学習回数100回、学習の入力データが復元したガウス曲率の相対的な大きさの値が0~12612を取るため、6000とした。

図9に実物体に対して本手法を適用し、復元したガウス曲率の値を0~1に正規化し、画像化したものを示す。ガウス曲率の高いところは白く、低いところは黒く示されている。図9(b)に、修正ニューラルネットワークを適用する前の結果を、図9(c)に修正ニューラルネットワークを適用した後の結果を示す。これより、修正ニューラルネットワークを適用することでノイズが抑えられ、より安定した結果が得られていることが確認でき、実物体に対して本手法が有用であることを示した。

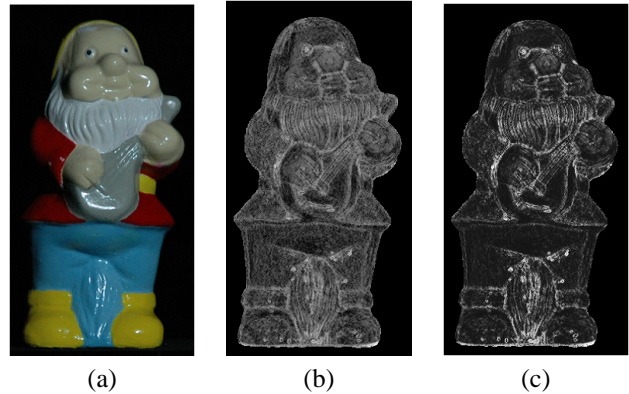


図9 ガウス曲率の復元結果 (a) 復元対象物体 (b) 修正 NN 適用前 (c) 修正 NN 適用後

6 まとめ

本論文では鏡面反射成分を持つカラー物体に対して、ガウス曲率の相対的な大きさを復元する手法を提案した。また、ガウス曲率の相対的な大きさの復元精度を向上するための手法として修正ニューラルネットワークを提案し、シミュレーション実験により、ガウス曲率の相対的な大きさの復元精度を向上することを示した。本手法を鋭い鏡面反射成分を持つテクスチャのあるカラー物体に対して適用することにより、本手法の有用性を示した。

謝辞

本研究は中部大学研究費、堀情報科学振興財団及び科学研究費補助金若手研究(B)(19700176)による成果の一部である。ここに感謝申し上げる。

参考文献

- [1] J. Fan and Lawrence B. Wolff: "Surface Curvature from Integrability", in *Proc. of CVPR 1994*, pp.520-525, 1994.
- [2] Lawrence B. Wolff and J. Fan: "Segmentation of surface curvature using a photometric invariant", in *Proc. of CVPR 1994*, pp.23-30, 1994.
- [3] 岡谷 貴之, 出口 光一郎: "複数の画像間の陰影差に基づく曲面のガウス曲率符号の決定", 情報処理学会論文誌, vol.39, No.5, pp. 1965-1972, 1998.
- [4] Elli Angelopoulou, Lawrence B. Wolff: "Sign of Gaussian curvature from curve orientation in photometric space", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol.E81-D, pp. 889-900, 1998.
- [5] Y. Iwahori, S. Fukui, R. J. Woodham, A. Iwata: "Classification of Surface Curvature from Shading Images Using Neural Network", *IEICE Trans. on Information and Systems*, Vol.E81-D, No.8, pp. 889-900, 1998.
- [6] Y. Iwahori, S. Fukui, C. Fujitani, Y. Adachi, R. J. Woodham: "Relative Magnitude of Gaussian Curvature from Shading Images Using Neural Network", *Lecture Notes in Computer Science 3681*, pp.813-819, KES2005, 2005.