

ニューラルネットワークを用いた物体の曲率符合抽出の一手法

村上 正充¹, 岩堀 祐之¹, Robert J. WOODHAM², 石井 直宏¹

¹ 名古屋工業大学大学院 電気情報工学専攻
〒466 名古屋市昭和区御器所町
E-mail {murakami|iwahori}@center.nitech.ac.jp

² Dept. of Computer Science, The University of British Columbia
Vancouver, B.C. Canada V6T 1Z4

本論文では、三方向での照明条件のもとで撮像した物体の各点での濃淡画像をもとに、同一照明条件での球画像にRBFニューラルネットワークによる写像を行い、その近傍5点の位置関係から曲面の分類を行なうことによって曲率符合を局所的に抽出する新しい手法を提案した。本論文の手法では、物体の反射特性の関数を仮定することなく、かつ、物体の任意の点での具体的な傾き等の値を求めることなく、濃淡情報から直接的に曲率の符合を抽出した。曲率情報は視点に依存しない物体形状の情報であり、実画像による実験では、良好な曲率符合の抽出結果が得られた。またRBFニューラルネットワークの逆変換により、対象物体の曲面分類結果に対する局所的な信頼性の評価が行なえることも示した。

照度差ステレオ, RBFニューラルネットワーク, 曲率

A Method to Recover Curvature Sign of Object Using Neural Network

Masamitsu MURAKAMI¹, Yuji IWAHORI¹, Robert J. WOODHAM² and Naohiro ISHII¹

¹ Graduate School of Dept. of Electrical and Computer Engineering,
Nagoya Institute of Technology
Gokiso-cho, Showa-ku, Nagoya 466, Japan
E-mail {murakami|iwahori}@center.nitech.ac.jp

² Dept. of Computer Science, The University of British Columbia
Vancouver, B.C. Canada V6T 1Z4

This paper proposes a new photometric method to recover the local curvature sign using neural network. RBF neural network maps the image irradiances at the neighbor pixels for the test object taken from three different illuminating directions onto the sphere images taken under the same illuminating condition. Then, the sign of curvature is determined locally from the relation of the locations on the sphere. The method is empirical and directly recovers the curvature sign without knowing the values of surface gradient. Further, the method can also get the local confidence estimate using the two step RBF neural networks for the obtained results. Results are demonstrated by the experiments for real images.

Photometric stereo, Radial Basis Function Neural Network, Curvature

1 はじめに

3次元物体の形状表現方法には、法線ベクトル、主曲率等がある。その中でも、主曲率は視点によって変わることのない3次元物体の情報であり、曲率表現は表面の領域分割・物体認識・姿勢決定・表面の再構成といったコンピュータビジョンの分野で非常に有益な情報を提供することができる。

1枚の濃度画像からの3次元物体形状の復元は情景理解において重要な目的である。しかし、1枚の濃度画像の明るさの自由度は1であるのに対して、3次元物体の形状表現方法である物体の法線ベクトルは自由度が2、曲率の自由度は3である。そのため、照度差ステレオ法 (Photometric Stereo) と呼ばれる、視点 (カメラ) を固定して複数の異なる照明条件のもとで撮影された物体の濃度画像から物体表面の局所的な傾き (法線ベクトル) を決定する手法が Woodham[1] により提案された。

この照度差ステレオ法に関して、これまで発表されてきた多くの論文が表面の反射特性に関して何らかの仮定、特に完全拡散面の仮定を用いている。しかし、このような仮定は実用性が損なわれ、その意味で照度差ステレオの原理において表面の反射特性において特別な関数を仮定することなしに物理的な入出力関係をそのまま用いるような物理ベースビジョン [3], [4] の問題として捉えることは重要である。

物理ベースビジョンに基づく照度差ステレオの実現方法の一例として、形状既知の球をキャリブレーションに用いて、3枚の球の各点の観測濃度の組と傾きの関係をルックアップテーブルとして作成し、球と同一反射特性をもつテスト物体の各点の画像濃度の組をもとにルックアップテーブルを参照することによってテスト物体の傾き分布を得る照度差ステレオが Woodham により提案されている [2]。この方法では、物体の反射特性の関数を仮定することなしに、また同時に、光源方向の情報を用いることなしに実現できるというメリットがあり、物体濃度画像から任意の点の面の傾き (p, q) とその x, y 方向の偏微分 p_x, q_x, p_y, q_y を導出し、曲率を求めている。

また、Wolff, Fan らは [5][6] は、Lambert 面の反射特性である仮定した場合に限り、異なった3つの照明条件で撮像された物体濃度画像の任意の点とその近傍点の観測画像濃度の差分を用いて、物体の表面の傾きや法線ベクトルを求めることなくガウス曲率の符合を求める手法を提案している。

そこで本論文では、一旦物体の面の傾きを求めてから曲率を抽出する手法ではなく、また物体の表面が Lambert 面の反射特性の仮定を用いることなく物理ベースの方法に基づいて、ニューラルネットワークを導入し曲面の分類によって曲率符合を局所的に抽出する手法を提案する。

2 照度差ステレオ法の原理

2.1 照度差ステレオ法

物体表面上の任意の点の z 座標が右手系3次元ユークリッド空間内の $z = f(x, y)$ として表されるものとし、正の Z 軸方向に視点があるものとする。また、画像投影は直交投影を仮定し、物体上の任意の点 (面素) の法線ベクトルを (n_1, n_2, n_3) として表すものとすれば、画像照度の方程式は以下のように表すことができる。

$$E(x, y) = R(n_1, n_2, n_3) \quad (1)$$

ここで $E(x, y)$ は画像の点 (x, y) における観測画像濃度であり、 $R(n_1, n_2, n_3)$ は表面の傾きを表す点の法線ベクトル (n_1, n_2, n_3) を用いて定義される反射率地図 (reflectance map) である。一般に反射率地図は表面材質や照明条件、視点位置といった画像生成に関わる情報を表面の傾きを入力とした非線形関数の形で単純化して保持する。復元対象を各点の反射率 (反射係数) が一様な物体面とすれば、反射率 C は定数として扱うことができるため、このとき各点の画像濃度 E は反射率地図 R に依存して決まる。

照度差ステレオは視点の位置を固定し、通常3方向からの照明条件を用意することにより、以下の3つの画像照度方程式を得る。

$$\begin{aligned} E_1(x, y) &= R_1(n_1, n_2, n_3) \\ E_2(x, y) &= R_2(n_1, n_2, n_3) \\ E_3(x, y) &= R_3(n_1, n_2, n_3) \end{aligned} \quad (2)$$

(E_1, E_2, E_3) から (n_1, n_2, n_3) を決定することが照度差ステレオの本来の目的であるが、本手法では (n_1, n_2, n_3) を求めずして、各点の (E_1, E_2, E_3) から直接的に曲率符合を求めることを目的としている。

2.2 球画像と物体画像の観測濃度のマッチング

物体画像上の任意の点 (x_{obj}, y_{obj}) の3方向の照明条件での観測画像濃度を、それぞれ $E_{1obj}(x_{obj}, y_{obj})$, $E_{2obj}(x_{obj}, y_{obj})$, $E_{3obj}(x_{obj}, y_{obj})$ とする。さらに、物体を撮影した時と同じ3方向の照明条件で、球を撮影する。球画像上の任意の点 (x_{sph}, y_{sph}) の3方向の照明条件での観測画像濃度をそれぞれ $E_{1sph}(x_{sph}, y_{sph})$, $E_{2sph}(x_{sph}, y_{sph})$, $E_{3sph}(x_{sph}, y_{sph})$ とする。ここで、物体画像上のある点 (x'_{obj}, y'_{obj}) と、球画像上のある点 (x'_{sph}, y'_{sph}) との観測画像濃度が式 (3) のように3つの照明条件各々で等しい値をとるならば、式 (2) の方程式により物体上の点 (x'_{obj}, y'_{obj}) と球上の点 (x'_{sph}, y'_{sph}) が同じ法線ベクトルをもつことを意味する。

$$\begin{aligned} E_{1obj}(x'_{obj}, y'_{obj}) &= E_{1sph}(x'_{sph}, y'_{sph}) \\ E_{2obj}(x'_{obj}, y'_{obj}) &= E_{2sph}(x'_{sph}, y'_{sph}) \\ E_{3obj}(x'_{obj}, y'_{obj}) &= E_{3sph}(x'_{sph}, y'_{sph}) \end{aligned} \quad (3)$$

3 曲面と曲率符合

3.1 曲面の種類

曲面には図1の5種類の形状があり、曲面上のある点での最大曲率を k_1 、最小曲率を k_2 とすると、その曲面は k_1, k_2 の符合により表1のように分類される。さらに、正の楕円面、負の楕円面、双曲面、円筒面、平面の5種類の曲面は、平均曲率が $M = \frac{k_1+k_2}{2}$ 、ガウス曲率が $G = k_1 \cdot k_2$ となるので、5種類の曲面の平均曲率 M の符合、ガウス曲率 G の符合は、表2のようになる。ゆえに、これら5種類の曲面を分類すればガウス曲率の符合と平均曲率の符合が決定される。物体の各点の曲面が、これら5種類の曲面のうちどの曲面に分類されるかが分かれば、ガウス曲率 (G) の符合、さらにはガウス曲率が正 ($G > 0$) の場合、平均曲率 (M) の符合を一意的に決定することができる。




図1: 5種類の曲面

表1: 曲面と主曲率の関係

| | $k_2 > 0$ | $k_2 = 0$ | $k_2 < 0$ |
|-----------|-----------|-----------|-----------|
| $k_1 > 0$ | 正の楕円面 | 円筒面 | 双曲面 |
| $k_1 = 0$ | - | 平面 | 円筒面 |
| $k_1 < 0$ | - | - | 負の楕円面 |

表2: 曲面のガウス曲率と平均曲率の符合

| | |
|-------|-------------------|
| 正の楕円面 | $G > 0, M > 0$ |
| 負の楕円面 | $G > 0, M < 0$ |
| 双曲面 | $G < 0$ |
| 円筒面 | $G = 0, M \neq 0$ |
| 平面 | $G = 0, M = 0$ |

4 RBFニューラルネットワーク

本論文では物理ベースビジョンに基づく反射率地図の学習と一般化の実現にニューラルネットワークの一つである放射基底関数ニューラルネットワーク (radial basis function (RBF) neural network) を用いている。RBF ネットワークは特に多次元空間の厳密な補間を行なうのに有効なニューラルネットワークとして知られている。[7]

また、RBFニューラルネットワークはしばしば、代表的なフィードフォワードネットワークよりも少ない学習

回数で構成することができるという特徴があるとともに学習データが多い場合に有効性を発揮し良好な学習が期待できる。RBF ネットワークは上層を隠れ層、下層を出力




図2: RBFニューラルネットワーク

層とする2層構造であり、それぞれ与えられた役割が異なる。隠れ層を構成する各ニューロンは、学習時に顕著な特徴を示していた学習データの入力空間内での位置を代表値 (center) と呼ばれる値として一つずつ保持している。ネットワークにデータが入力された際、各隠れ層ニューロンは自らが保持する代表値と入力データとの距離を伝達関数である基底関数に与え、出力を決定する。

次に、出力層を構成する各ニューロンへの入力は隠れ層からの出力と各経路に設定された荷重との積和となる。出力層のニューロンは伝達関数が線形関数であり、常に出力と教師信号との二乗和誤差が最小となるよう毎回の学習の際に2層間の荷重が最適化される。こうして得られた出力がRBF ネットワークの最終的な出力となる。

隠れ層ニューロンの基底関数には幾種類かあるが、本稿ではもっとも一般的に用いられるガウシアン関数を採用する。これにより隠れ層ニューロンは入力データと各々が保持する代表値との類似度が高ければ発火するという動作をする。

本手法では学習手続きとして直交最小二乗法 (orthogonal least squares method: OLS 法) に基づく学習法を用いる。この手法では最適な動作をするネットワークが構成されるまで、1回ごとの学習でRBFの代表値を一つずつ選択し、アルゴリズムは毎回選ばれた代表値が望まれる出力の説明された分散の増分を最大にする特性を持つ。

5 濃淡画像からの曲率符合抽出

本研究の目的は、物体画像上の任意の点がどの曲面に分類されるかによって曲率符合を決定することであり、照度差ステレオ法の原理を用いて、物体の任意の点とその近傍4点の観測画像濃度をもとにその点の曲率符合を求める。手法は以下のステップからなる。

[step1] 物体画像のある点とその点の近傍4点の計5点をとりだし、それら5点の観測画像濃度が等しい球画像上の点を求め球上への写像を行なう。

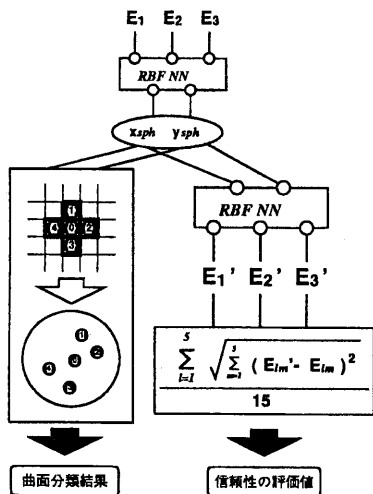


図 3: 曲率符合抽出のながれ

[step2] step1 の逆変換を行なうことにより得られた値から、球上に写像された近傍 5 点の評価値を求める。

[step3] 球上に写像されたそれら 5 点の位置関係により、その点の曲面が図 1 に示す 5 種類の曲面のうちのどれに分類されるかを決定することにより、ガウス曲率・平均曲率の符合を求める。

本手法による物体の濃淡画像からの曲率符合抽出のながれを、図 3 を示す。以下に、[step 1] のニューラルネットワークによる球画像とのマッチング部、[step 2] のニューラルネットワークによる信頼性評価部、[step 3] の曲面分類による曲率符合判定部についてそれぞれ詳しく述べる。

[step1] RBFニューラルネットワークによる物体画像と球画像の観測画像濃度のマッチング 物体画像上の任意の点 (x_{obj}, y_{obj}) の曲面がどの曲面に分類されるかを知るためには、物体画像上の任意の点 (x_{obj}, y_{obj}) を中心とする近傍 5 点が、それぞれ球画像上のどの点の傾きと等しいか、つまり、3 方向の照明条件での観測画像濃度が等しいかを求めればよい。これを実現するために、学習データとして、球画像の各点での観測画像濃度 $(E_1(x_{sph}, y_{sph}), E_2(x_{sph}, y_{sph}), E_3(x_{sph}, y_{sph}))$ を入力、その点の座標 (x_{sph}, y_{sph}) を出力とする RBFニューラルネットワークを設計した。この RBFニューラルネットワークは、 $(E_1, E_2, E_3) \rightarrow (x_{sph}, y_{sph})$ という変換を行なうものである。これに物体画像上の任意の点 (x_{obj}, y_{obj}) の観測画像濃度 $(E_1(x_{obj}, y_{obj}), E_2(x_{obj}, y_{obj}), E_3(x_{obj}, y_{obj}))$ を入力として与えると、出力としてそれと同じ観測画像濃度をもつ球画像上の座標が得られる。RBFニューラルネットワークの学習に用いる球画像の座標は画像内のピクセル値が用いられるため整数値で与えられる。しかし、RBFニュー

ラルネットワークの補間機能により、球画像による学習の後に対象物体の任意の点の 3 方向の照明条件における観測画像濃度 $(E_1(x_{obj}, y_{obj}), E_2(x_{obj}, y_{obj}), E_3(x_{obj}, y_{obj}))$ を入力として与えると、それに対応する球画像座標は実数値として得られる。

[step2] RBFニューラルネットワークによる信頼性評価 前述の物体画像と球画像の観測画像濃度のマッチングを行なう RBFニューラルネットワークにより、 $(E_1, E_2, E_3) \rightarrow (x_{sph}, y_{sph})$ という変換を行なうネットワークを設計した。このネットワークに、物体画像上の任意の点の観測画像濃度を入力として与えることにより、それと同じ観測画像濃度をもつ球画像上の座標が出力として得られる。しかし、対象物体の形状は未知であり、その画像には球のような完全な凸状の形状ではありえない、投影陰影 (cast shadow)・内部反射といった問題が生じてくる。cast shadow とは、複雑な形状の物体において、その物体の周囲の突起部により影が生じ、実際よりもカメラに反射する光の量が少なくなり、その結果観測画像濃度が実際より低い値でしか得られない点が生じてしまうことである。また、物体の表面上で凹状の形状をもつ点では、周囲の点の 2 次反射以上の影響によってのみカメラに反射する光の量が決定されてしまう場合がある。これを内部反射と呼ぶ。これらの現象により、対象物体画像の観測画像濃度に誤りがでてくる場合がある。そのため、 $(E_1, E_2, E_3) \rightarrow (x_{sph}, y_{sph})$ という変換を行なうネットワークに対象物体画像の観測画像濃度を入力しても、必ずしも同じ観測画像濃度をもつ球画像上の座標 (x_{sph}, y_{sph}) が出力されるわけではない。

よって、局所的な信頼性を評価するため、 $(x_{sph}, y_{sph}) \rightarrow (E_1, E_2, E_3)$ という、逆変換を行なう RBFニューラルネットワークを設計した。これは、RBFニューラルネットワークの学習データとして、球画像上の任意の点の座標 (x_{sph}, y_{sph}) を入力、その点の観測画像濃度 (E_1, E_2, E_3) を出力として用いたものである。これを、前述の $(E_1, E_2, E_3) \rightarrow (x_{sph}, y_{sph})$ という変換とあわせると、 $(E_1, E_2, E_3) \rightarrow (x_{sph}, y_{sph}) \rightarrow (E_1', E_2', E_3')$ という変換ができることになる。

物体画像上のある点 (x_{obj}, y_{obj}) の観測画像濃度を $(E_1(x_{obj}, y_{obj}), E_2(x_{obj}, y_{obj}), E_3(x_{obj}, y_{obj}))$ とする。これを、 $(E_1, E_2, E_3) \rightarrow (x_{sph}, y_{sph}) \rightarrow (E_1', E_2', E_3')$ という変換を行なうことにより得られた出力を、 $(E_1'(x_{obj}, y_{obj}), E_2'(x_{obj}, y_{obj}), E_3'(x_{obj}, y_{obj}))$ とすると、その点の結果に対する局所的な信頼性の評価値 $C(x_{obj}, y_{obj})$ は式 (4) で表される。

$$C(x_{obj}, y_{obj}) = \frac{\sqrt{\sum_{i=1}^3 |E_i(x_{obj}, y_{obj}) - E_i'(x_{obj}, y_{obj})|^2}}{3} \quad (4)$$

本手法では、任意の点 (x_{obj}, y_{obj}) だけではなく、その点を中心とした近傍 5 点の点を用いるので、最終的な点

(x_{obj}, y_{obj}) の信頼性の評価値は式 (5) に示すように、それらの平均値 $C_m(x_{obj}, y_{obj})$ で表される。

$$C_m(x_{obj}, y_{obj}) = (C(x_{obj}, y_{obj}) + C(x_{obj} + 1, y_{obj}) + C(x_{obj} - 1, y_{obj}) + C(x_{obj}, y_{obj} + 1) + C(x_{obj}, y_{obj} - 1)) / 5 \quad (5)$$

[step3] 曲面分類による曲率符合の判定 5種類の曲面は図1に示され、これらの曲面は表1のような主曲率の性質をもつ。対象物体のある点の曲面が、これらの5種類の曲面のうち、どの曲面であるかを分類すればその点の曲率符合が決定できる。

簡単のため近傍5点を、中心点を①とし、その真上の点を②、そこから時計回りに③、④と番号付けする。5種類の曲面のある点を中心とした近傍5点の法線ベクトルには特徴があるため、これら近傍5点の法線ベクトルの特徴は、同じ法線ベクトルをもつ球上の点へと写像することにより、それらの5点の位置関係という情報に変換される。

そこで対象物体の任意の点の曲面の分類法として、その点の近傍5点を球上の同じ観測画像濃度をもつ点、つまり同じ法線ベクトルをもつ点に写像し、それら5点の位置関係を用いて曲面の分類を行なう。

5種類の曲面の近傍5点が、球上にどのように写像されるかを以下に示す。

正の楕円面 正の楕円面は図1(a)に示すような形状である。球も正の楕円面であるため、正の楕円面の近傍5点を、球への写像を行なってもそれらの位置関係は写像前と同じに保たれる。そのため、正の楕円面の近傍5点①～④を球上に写像しても、図4に示すように、①を中心とした時計回りに①～④が写像される。




図4: 正の楕円面の近傍5点の球上への写像

負の楕円面 負の楕円面は図1(b)に示すような形状である。正の楕円面の近傍5点の任意の点の法線ベクトルを (n_1, n_2, n_3) とすると、その主曲率の絶対値が同じである負の楕円面の法線ベクトルは、 $(-n_1, -n_2, n_3)$ となる。そ

のため、負の楕円面の近傍5点①～④を球上に写像すると、図5に示すように、①を中心とした時計回りに①～④が写像されるが、正の楕円面の写像の時に比較して、180°位相がずれたものになる。




図5: 負の楕円面の近傍5点の球上への写像

双曲面 双曲面は図1(c)に示すような形状である。最大曲率・最小曲率をそれぞれ k_1, k_2 とすると、球の場合 $k_1 > 0, k_2 > 0$ になるのに比べ、双曲面では $k_1 > 0, k_2 < 0$ となる。そのため、双曲面の近傍5点①～④を球上に写像すると、図6に示すように、①を中心とした反時計回りに①～④が写像される。




図6: 双曲面の近傍5点の球上への写像

平面 平面は、図1(d)に示すような形状である。平面は明らかに近傍5点が同じ法線ベクトルをもつため、近傍5点①～④は、図7に示すように球上の同じ位置へと写像される。




図7: 平面の近傍5点の球上への写像

円筒面 円筒面は図1(e)に示すような形状である。円筒面は、ガウス曲率 $G \geq 0$ つまり、 $k_1 = 0$ 又は $k_2 = 0$ であり、図8に示すように、球上に近傍5点①～④を写像すると、①～④が同じ直線上に写像される。

6 実験

6.1 シミュレーション

ここでは、式(6)で与えられる2次元 sinc 関数(図6.1(a))を曲率符合抽出の対象物体として使い、sinc 関数





図 8: 円筒面の近傍 5 点の球上への写像

と同一観測画像濃度の写像を行なう球の表面は同じ理想 Lambert 面の反射特性を持つものとして本手法の性能評価を行なった。

$$f(x, y) = 3 \cdot \frac{\sin x}{x} \cdot \frac{\sin y}{y} \quad (-2\pi < x, y < 2\pi) \quad (6)$$



(a) sinc 関数の形状 (b) sinc 関数の濃度画像
図 9: 2次元 sinc 関数

Lambert 面の反射特性は $\cos(\theta_i)$ に比例することが知られており、 θ_i は、面の傾きと光源方向とがなす角度である。(注: Lambert 面の仮定は本手法において重要ではなく、例えば Phong モデルのような光沢面を用いたとしても問題はない。これは、本手法では物理ベースの解法を用いており、球と対象物体が同じ反射特性をもつならば、その反射特性関数の形を問わないためである。)

以上により得られた 3 方向の照明条件での sinc 関数の濃度画像を図 (6.1) (b) に示す。これらの画像の 3 方向の光源と物体との位置関係は、局所座標系で E_1 が $(30^\circ, 0^\circ)$ 、 E_2 が $(30^\circ, 120^\circ)$ 、 E_3 が $(30^\circ, 240^\circ)$ で、物体と光源との距離は十分離れているとする。

シミュレーションで作成した濃度画像の大きさは 512×512 ピクセルで、各点の濃淡値は 256 階調グレイスケールで表す。 512×512 の濃度画像中で、ある一定間隔で物体上の点を抽出し実験データとして用いた。また、曲面分類の際、対象物体画像中で近傍 4 点に 1 つでも欠落のある点についてはその点についての曲率符合は求めず棄却した。球物体画像、sinc 関数のそれぞれのサンプリング間隔、抽出点数、曲面分類の対象点数を表 3 に示す。

また、濃度画像中の物体部分と背景部分との分離のために閾値を設定し、任意の点について 3 方向の照明条件全ての観測画像濃度が 10 以上であれば物体部分、10 未満であれば背景部分であるというような閾値処理による分離を行なった。また、RBF ニューラルネットワークを入出力補

表 3: サンプリング間隔と抽出点数と曲面分類対象点数

| | サンプリング間隔 | 抽出点数 | 曲面分類対象点数 |
|---------|----------|-------|----------|
| 球画像 | 16pixel | 558 | — |
| sinc 関数 | 4pixel | 16383 | 15371 |


表 4: RBF ニューラルネットワークの学習条件

| | 学習回数 | スプレッド定数 |
|--------------|------|---------|
| 観測画像濃度のマッチング | 100 | 50 |

間を用いており、これらの学習条件を表 7 に示す。最終的な実験結果である、sinc 関数の各抽出点における曲面分類結果を図 10(a) に示す。sinc 関数の各抽出点での正確な曲面分類 (理論値) を図 10(b) に示す。

sinc 関数の、本手法による曲面分類結果の点数、sinc 関数の正確な曲面分類結果の点数、それらを比較した正解率を表 5 に示す。表 5 の正解点数とは、本手法による曲面分類結果のうち理論値と一致した点数である。

表 5 によると、本手法でのシミュレーション上での正解率は全体として 95.69% という良好な結果が得られた。また、4.31% のほとんどの点は曲面と曲面の境界上に位置する点であり、曲面の境界では若干ながら間違った結果を示す傾向がある。また、sinc 関数の右上と右下に 10 数ヶ所ほど円筒面に分類されている点がある。これは sinc 関数が原点から遠い点ほど平面、つまり近傍 5 点が似通った観測画像濃度をもつため、そのため RBF ニューラルネットワークの出力に誤差が生じたためであると考えられる。



(a) 本手法 (b) 理論値
□ : 正の楕円面 ■ : 平面
▨ : 円筒面 ■ : 負の楕円面
▩ : 双曲面

図 10: sinc 関数画像の曲面分類の結果

表 5: sinc 関数の曲面分類結果

| | 理論値 | 本手法 | 正解点数 | 正解率 (%) |
|-------|-------|-------|-------|---------|
| 正の楕円面 | 3192 | 3321 | 3050 | 95.55 |
| 負の楕円面 | 3052 | 3003 | 2864 | 93.84 |
| 双曲面 | 9127 | 9013 | 8794 | 96.35 |
| 円筒面 | 0 | 12 | 0 | 0 |
| 分類不可能 | — | 21 | — | — |
| 総点数 | 15371 | 15371 | 14708 | 95.69 |

6.2 実画像を用いた実験

実際の物体を撮像した濃淡画像を用いて曲率符合抽出実験を行った。実験に用いた物体は、球物体、人の顔の形をした物体（以下 doll-face）の2種類である。これらは同じ材質・反射特性をもつ。doll-faceを曲率符合抽出の対象物体として使い、球物体画像は doll-faceの曲率符合を求めるときの、同じ観測画像濃度をもつ点への写像を行なうためのデータとして用いた。

また、doll-faceに関しては、視点・光源を固定し、正面（doll-face1）、正面から左に約12°回転（doll-face2）回転の2通りの姿勢を、それぞれ同じ3方向の照明条件で撮像された画像を用いた。これらの濃度画像の例を図11に示す。対象物体 doll-faceの眼球部分は、穴が空いているため実験対象外とした。実験で使用した濃度画像の大きさは512×512ピクセルで、各点の濃淡値は256階調グレイスケールで表す。512×512の濃度画像中で、ある一定間隔で物体上の点を抽出し実験データとして用いた。また、曲面分類の際、対象物体画像中で近傍4点に1つでも欠落のある点についてはその点についての曲面は求めず棄却した。球物体画像、doll-faceそれぞれのサンプリング間隔、抽出点数、曲面分類の対象点数を表6に示す。

また、濃度画像中の物体部分と背景部分との分離のために閾値を設定し、任意の点について3方向の照明条件全ての観測画像濃度が50以上であれば物体部分、50未満であれば背景部分であるというような閾値処理による分離を行った。また、RBFニューラルネットワークを入出力補間に用いており、これらの学習条件を表7に示す。対象物

表6: サンプリング間隔と抽出点数と曲面分類対象点数


| | サンプリング間隔 | 抽出点数 | 曲面分類対象点数 |
|------------|----------|------|----------|
| 球物体画像 | 8 pixel | 654 | — |
| doll-face1 | 4 pixel | 3955 | 3230 |
| doll-face2 | 4 pixel | 4015 | 3358 |

表7: RBFニューラルネットワークの学習条件

| | 学習回数 | スプレッド定数 |
|--------------|------|---------|
| 観測画像濃度のマッチング | 50 | 50 |
| 信頼性の評価 | 50 | 10 |


体画像からの曲面分類の結果13を詳しく見ると、鼻の頭・頬・額の部分は正の楕円面、唇の周り、眉間の部分は負の楕円面、鼻筋・目の周りの部分は双曲面、顔の側面・唇は円筒面というようになっている。また、どの曲面にも分類されなかった点が数点であるが、これは cast shadow や観測画像濃度写像を行なうRBFニューラルネットワークの誤差によるものと思われる。これらは、図11に示されている濃度画像から曲面を予測できるが、それと比較して満足できる結果であるといえる。

また、曲率情報は視点に依存しない物体形状の情報であ




(a) doll-face1 (b) doll-face2

図11: 実験に用いた対象物体の濃度画像



(a) doll-face1 (b) doll-face2

図12: 対象物体画像の信頼性



(a) doll-face1 (b) doll-face2
 □ : 正の楕円面 ■ : 平面
 ▨ : 円筒面 ■ : 負の楕円面
 ▩ : 双曲面

図13: 対象物体画像の曲面分類の結果

るため、doll-face1,2は、同一の物体を異なった姿勢で撮像したものであるが、上に述べた顔の各部位での曲面について対応がとれていることが分かる。また、図12に対象物体画像の結果に対する信頼性を示す。これは、暗くなっている部分ほど信頼性が低いことを示している。首の部分は正の楕円面又は円筒面となるはずであるが、額の cast shadow が原因で、信頼性が低くなっていることがわかる。また、額の部分には微妙な凹凸があったため、正の楕円面になるはずであるが、所々双曲面に分類されている点がある。

7 まとめ

本論文では、物体画像の各点での3枚の観測画像濃度をもとに、同じ3種類の光源条件で撮像した球画像にニューラルネットワーク写像を行ない、その近傍5点の位置関係から曲面の分類を行なうことによって曲率符合を抽出する手法を新たに提案した。

本手法では、物体表面の反射特性に関して、何らかの関数の仮定を用いることはなく、かつ、物体の任意の点での具体的な面の傾き法線ベクトルといったパラメータの値を求めることなく、物理ベースの方法で濃淡情報から直接的に曲率の符合を抽出することができるという特徴がある。

本手法を実際に評価した結果、2次元 sinc 関数を対象としたシミュレーションでの正解率は95.69%という良好な結果が得られた。また、実際に同一の物体を異なる姿勢で撮像した実画像を用いた曲面分類の結果からも、各々の曲率符合がうまく抽出されていることを示した。曲率情報は視点に依存しない物体形状の情報であるが、本研究での曲面分類結果は、物体の各部位での曲面について物体が回転した画像間においても対応がとれており満足できる結果が得られた。

さらに、RBFニューラルネットワークを順方向のみでなく、逆方向においても近傍5点の情報を球を対象に学習させることにより、テスト物体の曲面分類結果における局所的な信頼性をも評価が行なえる方法を開発した。

今後の課題としては、円筒面にも正負の円筒面があるため、これらの分類も行なえるように改良することや、さらには、曲率符合のみではなく、局所的な曲率の値をも濃淡画像から直接推定するような物理ベースの方法を検討することが挙げられる。

謝辞

本研究の一部は(財)人工知能研究振興財団の援助を受けて行われた。また Woodham の研究支援は IRIS (the Institute for Robotics and Intelligent Systems) 及び NSERC (the Natural Sciences and Engineering Research Council of Canada) により与えられた。ここに深い感謝の意を表す。

参考文献

- [1] Robert J. Woodham: "Photometric method for determining surface orientation from multiple images." in *Optical Engineering* pp 139-144, 1980
- [2] Robert J. Woodham: "Gradient and curvature from the photometric-stereo method, including local confidence estimation." in *Journal of the Optical Society*

of America A pp 3050-3067, November 1994

- [3] G. Healey, S. Shafer, and L. Wolff, eds., *Physics-Based Vision: Principles and Practice (Vol. 1 Radiometry, Vol. 2 Color and Vol. 3 Shape Recovery)*. Boston, MA: Jones and Bartlett Publishers, Inc., 1992.
- [4] G. Healey and R. Jain, "Physics-based machine vision," *Journal of the Optical Society of America, A*, vol. 11, p. 2922, 1994. (Introduction to special issue).
- [5] Lawrence B. Wolff and Joel Fan: "SEGMENTATION OF SURFACE CURVATURE USING A PHOTOMETRIC INVARIANT" in *Proc. of CVPR 1994* pp 23-30, 1994
- [6] Joel Fan and Lawrence B. Wolff: "Surface Curvature from Integrability" in *Proc. of CVPR 1994* pp 520-525, 1994
- [7] S. Chen, C.F.N. Cowan, and P.M. Grant: "Orthogonal least squares learning algorithm for radial basis function networks." in *IEEE Transactions on Neural Networks*, vol. 2, no. 2, pp. 302-309, 1991
- [8] S. Chen, S.A. Billings, and W. Luo: "Orthogonal least squares methods and their application to nonlinear system identification." in *Int. J. Contr.* vol. 50, no. 5, pp. 1873-1896, 1989
- [9] A. Björck: "Solving linear least squares problems by Gram-Schmidt orthogonalization." in *Nordisk Tidsskr. Informations-Behandling* vol. 7, pp. 1-21, 1967