

ニューラルネットと2自由度の回転による3次元物体の局所曲面分類

Classification of Local Surface Using Neural Network and
Object Rotation of Two Degrees of Freedom

小島 崇 † 岩堀 祐之 ‡ 中村 剛士 † 福井 真二 § 伊藤 英則 †
Takashi Kojima Yuji Iwahori Tsuyoshi Nakamura Shinji Fukui Hidenori Ito

1 はじめに

コンピュータビジョンの分野において物体表面の局所曲面の形状情報を取得することは重要な問題の1つである。

視点を固定したままで光源の方向を変化させることにより撮影した複数枚濃淡画像から対象物体の局所的な傾き(法線ベクトル)を取得する手法としてWoodhamにより提案された照度差ステレオ法(Photometric stereo)[1]がある。この照度差ステレオの拡張としてWoodhamが提案したルックアップテーブル(LUT)を用いる手法[2]や、Iwahoriらによる放射状基底関数ニューラルネットワーク(Radial Basis Function Neural Network, RBF-NN)を用いて物体表面の局所曲面の分類手法[3]およびガウス曲率の大きさを復元する手法[4]が提案されている。他方、カラー画像を対象として対象物体の色情報を抽出する手法も提案されてきている[5]。

これらの手法では、LUTの作成やNN学習のためにキャリブレーション用の球が必要である。キャリブレーション球とは分類対象の物体(以下、分類物体)と同様の反射特性をもつ球であり、この球を分類物体と同じ光源条件下で複数の濃淡画像を撮影し、これを用いて照度差ステレオの原理より曲面の分類を行うことができるが、分類物体と同様の反射特性をもつ球を用いることは大きな制約でもある。また[6]では光源方向と反射特性を未知とするかわりに、材質の異なる形状既知物体を多数用意し、多光源のもとでBRDFを推定している。

本論文では、異なる4光源照明条件下で、分類物体を対象として、水平垂直方向の2軸で回転させながら撮影して得た画像をもとに、分類物体の反射特性を表すキャリブレーション球の仮想画像を生成する方法を提案するとともに、実際の球を用意することなしに、対象物体自身から局所曲面の分類を行う手法を新たに提案する。この際に、2自由度の回転により、特徴点の位置を計算するが、幾何学的な計算と実際の位置とのずれを修正するための手法を導入する。実画像を用いた実験により提案手法の評価を行った。

2 経験的照度差ステレオによる拘束

2.1 球座標への写像原理

経験的照度差ステレオでは、分類物体と、形状既知でかつ分類対象物体と同様の反射特性をもつキャリブレーション球に対して、異なる光源方向から照射し撮影した3枚(以上)のモノクロ濃淡画像を用いる。

対象物体画像上の任意の点(x_{obj}, y_{obj})の各方向の照明条件での画像の輝度値を各々 $e_{1obj}(x_{obj}, y_{obj})$, $e_{2obj}(x_{obj}, y_{obj})$, $e_{3obj}(x_{obj}, y_{obj})$ とする。またキャリブレーション球画像上の任意の点(x_{sph}, y_{sph})の各方向の照明条件での画像の輝度値を各々 $e_{1sph}(x_{sph}, y_{sph})$, $e_{2sph}(x_{sph}, y_{sph})$, $e_{3sph}(x_{sph}, y_{sph})$ とする。対象物体とキャリブレーション球の反射特性が同じときには、対象物体上の直接照射されて反射している点(x_{obj}, y_{obj})

において

$$\begin{cases} e_{1obj}(x_{obj}, y_{obj}) = e_{1sph}(x_{sph}, y_{sph}) \\ e_{2obj}(x_{obj}, y_{obj}) = e_{2sph}(x_{sph}, y_{sph}) \\ e_{3obj}(x_{obj}, y_{obj}) = e_{3sph}(x_{sph}, y_{sph}) \end{cases} \quad (1)$$

を満たすキャリブレーション球上の点(x_{sph}, y_{sph})が存在する。この式を満たすとき点(x_{obj}, y_{obj})での物体表面と点(x_{sph}, y_{sph})での球表面は同じ法線ベクトルをもつことになる。

この式の関係より、まず既知形状であるキャリブレーション球の($e_{1sph}, e_{2sph}, e_{3sph}$)と(x_{sph}, y_{sph})との関係をニューラルネット(NN)で学習しておき、 $e_{1obj}(x_{obj}, y_{obj})$, $e_{2obj}(x_{obj}, y_{obj})$, $e_{3obj}(x_{obj}, y_{obj})$ をもとに(x_{sph}, y_{sph})を得るNNを用いる。 (x_{obj}, y_{obj}) の情報すなわち球上に写像される位置関係により、曲面の分類を行うことができる。

2.2 主曲率と局所曲面の定義

ここでは局所曲面分類の定義について述べる。ある点の最大曲率を k_1 、最小曲率を k_2 とする。この k_1, k_2 の符号によって局所曲面は以下の6種類存在する。

表1 主曲率と曲面の関係

	$k_2 > 0$	$k_2 = 0$	$k_2 < 0$
$k_1 > 0$	convex	convex parabolic	hyperbolic
$k_1 = 0$	—	plane	concave parabolic
$k_1 < 0$	—	—	concave

RBF-NNはノンパラメトリックで多次元空間における非線形写像を実現する。キャリブレーション球上の各点における($e_{1sph}, e_{2sph}, e_{3sph}$)を入力、(x_{sph}, y_{sph})を出力としてNN学習し、学習したNNに、同じ照明条件下で撮影された分類対象物体の濃淡画像の組より得られる任意の(e_1, e_2, e_3)を入力すれば対応した(x_{sph}, y_{sph})がOutputされる。対象物体上の任意の点における近傍4点の(e_1, e_2, e_3)をNNに入力することで、出力される(x, y)によって表1に示すように局所的な曲面分類を行うことができる[3]。

3 仮想球の生成方法とニューラルネット学習

2自由度セルフキャリブレーションを用いて分類対象物体と同様の反射特性をもつ仮想球の作成方法について述べる。水平方向と垂直方向に位置した回転テーブルからなるプラケット上に物体をおき、2軸の各々の回りに180度回転させながら物体を撮影する。特徴点を定めておいて、その特徴点の位置を算出しながら対応する画素の観測画像濃度を用いて、仮想球の状態を作成し、対応する画素をつなぎ合わせることにより仮想球画像を作成するものとする。本論文ではこのようにして得られる仮想球を用いることで、従来の曲面分類手法で用いていた実際の球を使わないで局所曲面の分類を行うことができる。

3.1 撮影条件

回転台に対象物体を固定しその正面にカメラを配置する(図1)。照明は4方向に固定して配置する、この際にはcast

† 名古屋工業大学, Nagoya Institute of Technology

‡ 中部大学, Chubu University

§ 愛知教育大学, Aichi University of Education

shadow(物体自身の凹凸によりできる影)が少なくなる方向が望ましい。また、任意の特徴点の面の向きをカメラの光軸と垂直に設定し、かつ、カメラ側から見たときに水平垂直両方向の回転軸が交わる位置になるように物体の特徴点の位置を調整する(図2)。水平垂直方向に180度回転させたとき、この特徴点の軌跡は半球面を描く。撮影した複数枚の画像上の特徴点の箇所の画素を抽出しつなぎ合わせることにより、仮想的な球を生成することができる。

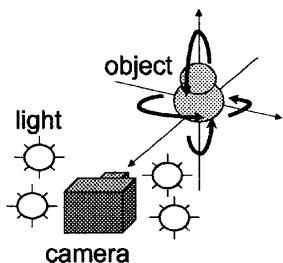


図1 撮影環境

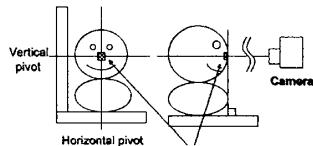


図2 マーカ位置

実画像取得については分類対象物体を上記の配置で固定し、その回転台を、まず垂直方向を0度にし、水平方向に0度から180度を5度間隔(0,5,10,···,175,180度)で回転させ撮影し37枚の仮想球生成のための画像データを得る。さらにこれを垂直方向に5度動かして同様に水平方向に動かしながら37枚撮影と、垂直方向でも0度から180度まで5度ずつ動かしながら撮影する。特徴点がカメラのレンズの延長線上にあるとき水平垂直方向ともに回転角が90度である。以上を各光源ごとに行い、 37×37 を4光源分(計5476枚)の画像を撮影し、これを球生成用画像とする。

さらに、特徴点の位置の精度を高めることを目的として、対象物体の特徴点の位置に印(マーカ)を付ける(図3)。特徴点の位置は、学習用球仮想球生成の画素抽出位置となるが、このようにして得られる仮想球画像から特徴点の位置をより正確に得るために、のちに述べるNNでの修正を加えることを目的としてマーカを付けた対象物体も撮影する。15度間隔回転(0,15,30,···,165,180度)として球生成用画像と同様に撮影し 13×13 枚のマーカ画像を得ておく。

併せて仮想球生成用に5476枚+マーカの画像169枚からなる画像データを撮影する。

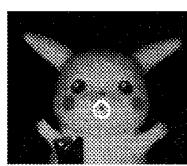


図3 マーカ画像(図中、円の中の点)



図4 実物体の撮影例

図5に撮影データの一部を示す。実際は 37×37 枚である。

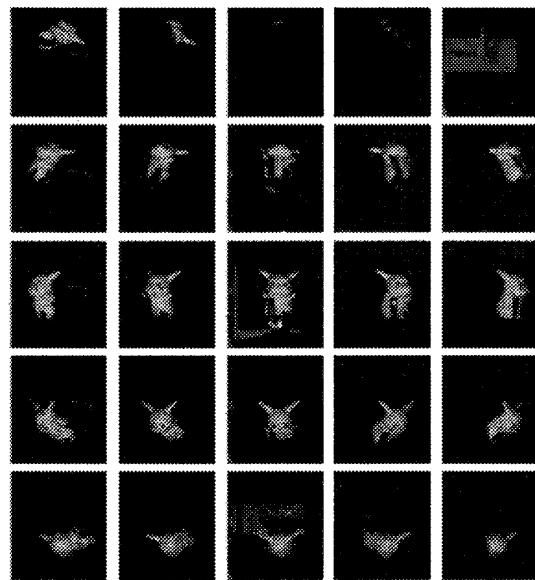


図5 撮影データの一部

3.2 球画像生成

仮想球生成画像から各々の光源での特徴点に対応する座標の画素を幾何学的に算出し、算出した画素での観測画像濃度とともに仮想球を作成する。

ここで、マーカ座標推定方法について説明する。特徴点の位置をより正確におさえることを目的として、マーカ(特徴点)の位置の座標を推定する方法として、幾何学的な計算から推定する方法と、さらに、ニューラルネットの学習とそのNNによる補正を利用して特徴点の位置の改善を行う方法を導入する。

方法1 マーカの回転半径(回転軸とマーカ箇所との距離)を割り出し、球生成用画像データ各々の水平垂直の回転角度から幾何学的に算出する方法。

垂直方向の回転角が90度(正面向き)で水平の回転角が60度と120度(それぞれ正面向きから左右に30度回転時)の画像上のマーカがついている箇所の座標を実測(*)しその距離を求める。観測の投影モデルは直交投影とする。このとき水平の回転軸と60度のマーカ位置と120度のマーカ位置との3点は正三角形を作る。60度のマーカ位置と120度のマーカ位置との距離が回転軸と各マーカ位置との距離と等しくなりこれが回転半径 r となる(図6)。

(*ここで実測とは画像閲覧ソフトでマーカ画像を表示させて、マーカの位置に実際にマウスをあわせそのとき表示される座標を得ることとする)

この回転半径 r と球生成用画像データ各々の、物体の垂直及び水平方向の回転角度から抽出画素に相当する座標を算出する。

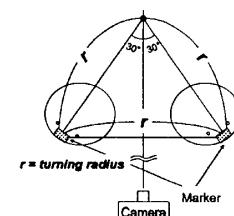


図6 マーカの回転半径

方法2 15度間隔回転で撮影したマーカ画像のマーカの座標をNN学習することにより5度間隔回転の座標を補正する方法。

- マーカ画像上のマーカの座標を実測し、 13×13 個の座標データを得る。方法1では直交投影の仮定による

誤差が生じることとその誤差を実測環境において効率的に補正することを目的としてNNを導入する。

- 入力を水平、垂直方向の回転角度、出力を実測して得たX, Y座標としNNに学習させる(図7)。学習データの組数は169組である(但しマーカが隠れるなどで実測できないデータがあればこれより少なくなる)。
- 学習したNNに垂直水平方向0度から180度を5度間隔(0,5,10,...,175,180度)で入力すれば抽出画素のX,Y座標が出力される。

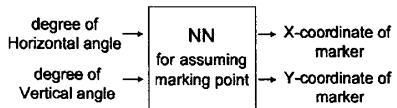


図7 マーカ座標推定NN

マーカ画像から推定したマーカの位置座標をもとに 37×37 枚の球生成用画像データ各々から特徴点を追跡し、抽出した画素を図8のように球状になるよう写像し球画像とする。

画素の抽出もとである球生成用画像の水平方向と垂直方向の回転角から、その画素が球上のどの位置に写像されるかを算出する。

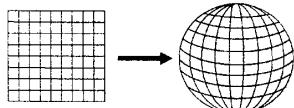


図8 各撮影データから得た画素の球への写像

3.3 カラー画像の処理

カラー画像は輝度値0から255の範囲でグレースケール化する[3]。画像の輝度値 e は $e = \rho R$ で表現される。ただし ρ は反射係数、 R は反射率地図を表す。ここで色による輝度値の違いは ρ に影響される。異なる照明による4枚の球画像上の (x, y) における光源 j での輝度値を $e_j(x, y)$ 、反射率地図を $R_j(p, q)$ とすれば、画像の照度方程式は以下のように表される。

$$\begin{cases} e_1(x, y) = \rho(x, y)R_1(p, q) \\ e_2(x, y) = \rho(x, y)R_2(p, q) \\ e_3(x, y) = \rho(x, y)R_3(p, q) \\ e_4(x, y) = \rho(x, y)R_4(p, q) \end{cases} \quad (2)$$

ρ を共通の定数であるとして式(3)で扱うことにより、 ρ の影響を取り除いた(e'_1, e'_2, e'_3, e'_4)を用いてNN学習に用いる。

$$e'_j = \frac{e_j}{\sqrt{e_1^2 + e_2^2 + e_3^2 + e_4^2}} \quad (j = 1, 2, 3, 4) \quad (3)$$

3.4 キャリブレーション球のニューラルネットワーク学習

仮想球画像を用いてNN学習を行う。学習に用いるデータの組は入力が輝度値 $(e'_{1sph}, e'_{2sph}, e'_{3sph}, e'_{4sph})$ 、出力がその点に応する球画像上の座標 (x, y) である(図9)。 $(e'_{1sph}, e'_{2sph}, e'_{3sph}, e'_{4sph})$ は $(e_{1sph}, e_{2sph}, e_{3sph}, e_{4sph})$ を式(1)に通して得られる値である。またデータ組のうち、入力の輝度値の e_1, e_2, e_3, e_4 のどれか1つでも光が当たっていない点は(つまり輝度値0ならば)学習には用いない。

4 実験結果

4.1 仮想球出力

NN学習に用いるために生成した仮想球を図10-13に示す。

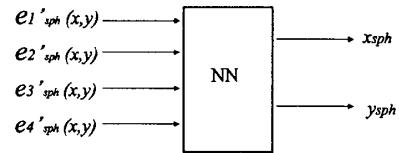


図9 NN学習

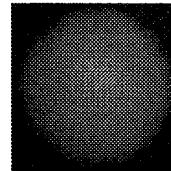


図10 生成した仮想球1(照
明、正面)

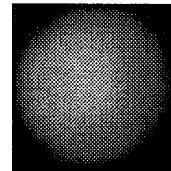


図11 生成した仮想球2(照
明、やや左)

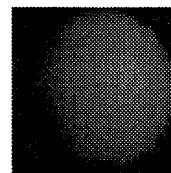


図12 生成した仮想球3(照
明、右)

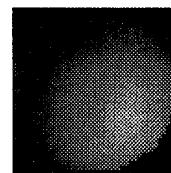


図13 生成した仮想球4(照
明、右下)

4.2 分類結果出力

3.2の方法2で生成した球画像で学習したNNに物体画像(図14-19)を入力し得られる曲面分類の結果を図4.2-19に示す。曲面の種類を凸面、凹面、双曲面、平面、凸放物面、凹放物面の6種に濃淡別で表示している。図14は物体を正面から左に60度、図16は右に30度回転させた図である。

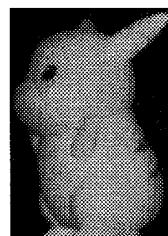


図14 分類対象物
体1

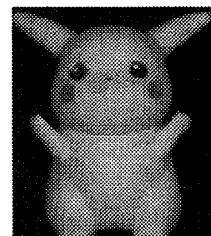


図15 分類対象物
体2

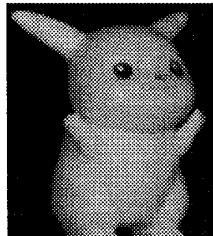


図16 分類対象物
体3

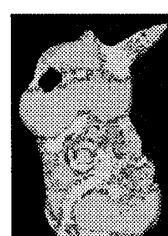


図17 分類結果1

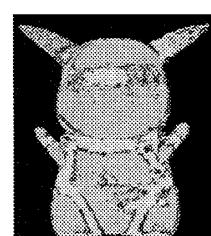


図18 分類結果2

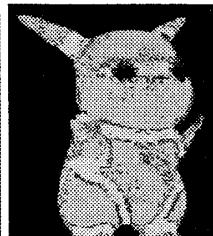


図19 分類結果3

■凸 □平	■凹 ■面	■双曲面 ■面	■凸放物面 ■凹放物面
----------	----------	------------	----------------

また画像サイズは図14が 226×320 、図15が 280×320 、図16が 280×330 [ピクセル]となっている。また分類時の近傍4点[3]は上下左右に7ピクセル横の点とした。この近傍点の距離は、小さいと分類時にノイズが多くなり、大きいと異なる種類の曲面の境界で不正確な分類結果が多くなる。実験においては結果があまり変化しない妥当なピクセル数を採用した。

4.3 仮想球生成手法の比較

3.2の方法1で生成した仮想球と方法2で生成した仮想球とで出力される分類結果の違いを比較する。図20-21における矩形A,B,Cの箇所を拡大した結果を図22-27に示す。



図20 方法1による分類結果

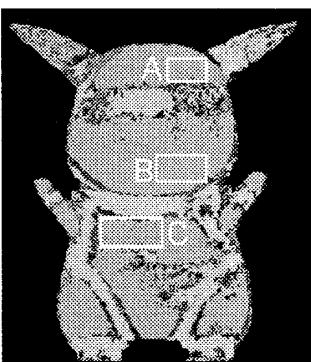


図21 方法2による分類結果



図22 方法1分類結果矩形A



図23 方法2分類結果矩形A



図24 方法1分類結果矩形B



図25 方法2分類結果矩形B



図26 方法1分類結果矩形C



図27 方法2分類結果矩形C

4.4 結果検証

方法1を補正することを目的とした方法2では改善効果が現れている。方法1では直交投影の仮定により実際のマーカ座標のずれが生じるため、誤差が大きくなり生成される球の形が悪くなることがある。他方、方法2ではマーカの画像を余分に取得する分だけ、データ計測の手間はかかるが、補正NNにより位置ずれの誤差を吸収でき仮想球の生成精度を高めることができる。

5 おわりに

本論文では対象物体の局所曲面の分類を行うことを目的に、対象物体自身から、2軸回転によるセルフキャリブレーションを行う手法を開発した。従来手法として対象物体と同一反射特性のキャリブレーション物体(球)を必要としていたが、球を用いることなしに、対象物体自身から仮想球を生成し、ある点の近傍4点の4光源分の画像情報からニューラルネットワークで仮想球上の座標に写像することによって、曲面分類を行う方法を提案した。また、仮想球上の代表点を取得するために、2軸回転の際に、回転半径をもとにした幾何学計算によって球上の点の座標を取得する方法に比べて、マーカ追跡においていくつかのサンプル点の座標を実際に計測し、幾何学計算の位置ずれをNNで補正する手法を導入した。この補正ニューラルネットワークを用いることで、より精度の高い仮想球を作成することができ、その結果、分類結果の精度を向上させることができた。

今後の課題としては、離散的な静止画からなるデータの場合、強い鏡面反射の物体については、鏡面反射を起こす点を撮影時に落としてしまう可能性があるため、それらの点を捉えることができる程度に、連続的な動画像のデータをもとに仮想球を生成することがあげられる。

謝 辞

本研究の一部は中部大学研究費及び堀情報科学振興財団のサポートによる。ここに感謝申し上げる。

参考文献

- [1] R. J. Woodham: "Photometric method for determining surface orientation from multiple images.", *Optical Engineering*, Vol. 19, pp.139-144, 1980.
- [2] R. J. Woodham: "Gradient and curvature from the photometric stereo method, including local confidence estimation.", *Journal of the Optical Society of America A*, Vol.11, pp.3050-3068, 1994.
- [3] Yuji Iwahori, Shinji Fukui, Robert J. Woodham and Akira Iwata: "Classification of Surface Curvature from Shading Images Using Neural Network", *IEICE Transactions on Information and Systems*, Vol.E81-D, No.8, pp.889-900, Aug. 1998.
- [4] Yuji Iwahori, Shinji Fukui, Chie Fujitani, Yoshinori Adachi and Robert J. Woodham: "Relative Magnitude of Gaussian Curvature from Shading Images Using Neural Network", *Lecture Notes in Computer Science (Knowledge-Based Intelligent Information & Engineering Systems)*, LNAI 3681, pp.813-819, Sep. 2005.
- [5] 河中治樹, 岩堀祐之, ロバートJ.ウッドハム, 舟橋健司: "ニューラルネットワークによるカラー照度差ステレオと仮想画像生成", 電子情報通信学会論文誌, Vol.J89-D-II, No.2, pp.381-392, Feb. 2006.
- [6] Aaron Hertzmann, Steven M. Seitz: "Example-Based Photometric Stereo: Shape Reconstruction with General, Varying BRDFs", *IEEE Trans. on Pattern Analysis and Machine Intelligence* Vol.27, No.8, pp.1254-1264, Aug. 2005.