

ニューラルネットワークとイルミネーションプランニングを用いた濃淡画像からの曲面の分類

福井 真二[†] 岩堀 祐之^{††} ロバート J. ウッドハム^{†††}
岩田 彰^{††}

Classification of Surface Curvature from Shading Images Using Neural Network and Illumination Planning

Shinji FUKUI[†], Yuji IWAHORI^{††}, Robert J. WOODHAM^{†††}, and Akira IWATA^{††}

あらまし 本論文ではニューラルネットワークとイルミネーションプランニングを用いて複数枚の濃淡画像から対象物体の局所的な曲面の曲率符号を復元する新しい手法を提案している。光源方向が互いに近い場合において、球の各点の画像濃度の分布を主成分分析による特徴抽出と次元圧縮の変換を行った後、変換後の情報と座標の関係を、RBF ニューラルネットワークを用いて学習する。曲率の特徴は 6 種類存在し、それらは、テスト物体の濃淡画像上の任意の点の近傍 4 点をそれらの点と同じ画像濃度をもつ球上の点にニューラルネットワークを用いて写像したときに、各々の曲率の種類に依存して写像されるパターンの特徴を利用して、ガウス曲率の符号のみならず、濃淡画像から直接的に 6 種類の曲面に分類を行うことができる。提案する手法はイルミネーションプランニングによりテスト物体の各点ごとに cast shadow を生じない光源の組合せを考えて、3 光源照度差ステレオの問題である cast shadow 領域を取り除くことができるとともに、よりロバストな結果を得ることが可能である。本方法では、複数光源の光源方向の情報を既知とせず、かつ、面の反射特性に対する何らかの関数を仮定することなく、物理的な入出力の関係をニューラルネットワークによって直接学習し、高次のノンパラメトリック関数近似を行う照度差ステレオを採用している。本手法を計算機実験により検証・評価を行うとともに、その有効性を確認した。

キーワード 物理ベースビジョン、照度差ステレオ、曲率、RBF ニューラルネット、主成分分析、イルミネーションプランニング

1. ま え が き

3 次元物体の形状表現方法の一つに主曲率がある。主曲率は視点に依存することのない 3 次元物体の情報であり、コンピュータビジョンの分野において形状復元、形状モデリング、領域分割、物体認識、姿勢決定といった多くのアプリケーションに用いることができる重要な情報である。

shape-from-shading は Horn により定式化されて以

降、Lambert 面を対象とした照度差ステレオ [1] をもとに、より一般的な反射特性の関数を仮定することにより、shape-from-shading や照度差ステレオに関して理論的な研究がなされてきており、より現実環境に近いモデルや実用的な成果を得ることを目指した物理ベースビジョン [2], [3] のアプローチが種々提案されている。

濃淡画像から曲率情報を求めるための最近の研究において、Woodham は物体面における反射特性の関数を仮定せず、また同時に、光源方向の情報を用いる必要がない物理ベースの（経験的）照度差ステレオを提案している。インプリメントの方法としては、3 光源照度差ステレオにより得られるルックアップテーブル (LUT) を用いて物体上の任意の点の 3 枚の画像濃度の組から対応する傾き (p, q) とその x, y 方向の偏微

[†] 名古屋工業大学大学院工学研究科, 名古屋市
Graduate School of Engineering, Nagoya Institute of Technology, Gokiso-cho, Showa-ku, Nagoya-shi, 466-8555 Japan

^{††} 名古屋工業大学工学部, 名古屋市
Faculty of Engineering, Nagoya Institute of Technology, Gokiso-cho, Showa-ku, Nagoya-shi, 466-8555 Japan

^{†††} Department of Computer Science, University of British Columbia, Vancouver B.C., Canada V6T 1Z4

分 p_x, q_x, p_y, q_y を導出し、それらの情報から曲率を算出する方法を提案している [4] .

3 枚の濃淡画像を用いてガウス曲率の符号分布を得るための研究として、Wolff らは、3 方向の照明条件下で撮像された 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的に求める手法を提案している [5] .

また、岡谷、出口らは 3 方向の光源方向や物体面の反射特性の知識なしで 3 枚の濃淡画像から、各点と近傍の点の濃度値から構成される 3×3 行列の行列式の符号を求めることにより、滑らかな物体面のガウス曲率の符号を決定するための手法を提案している [6] .

他方、筆者らはニューラルネットワークを物理ベース照度差ステレオ法に用いて、物体の任意の点とその近傍点の 3 枚の画像濃度の組をニューラルネットワークにより球上に写像し、球の画像上での位置関係を用いてガウス曲率の符号のみならず局所的な曲面の分類を行う手法を提案している [7] .

照度差ステレオの応用を制限する要因は、cast shadow (投影), 内部反射, 及び照明方向の利用範囲が限定されるようなケースである . これらはトレードオフでもあり、大きく異なる光源方向は形状復元に対して良い数値的条件を与える反面、物体形状によっては cast shadow 領域も増加し、同時に共通に照明される領域も減ることになる . 特に 3 光源照度差ステレオの原理で Lambert をはじめ何らかの反射特性関数を仮定して解くような場合には、cast shadow 領域を含め、共通照明領域以外では復元を行うことができなくなる問題がある . cast shadow は物体の幾何学形状に依存して光が遮られることにより発生する影の領域であり、cast shadow 領域を含めて復元可能な領域を最大に確保するためには少なくとも 4 光源以上の光源を用いる必要がある . 言い換えれば 3 光源照度差ステレオの原理を用いる方法 [4] ~ [7] では cast shadow 領域での曲率の情報を得ることは不可能である .

このような cast shadow 問題を解決する方法として、使用する光源数を 4 光源以上とし、cast shadow が生じている領域では cast shadow を生じない光源のみを用いて形状復元をするイルミネーションプランニングが有効であり、そのような考え方に基づいて多光源を用いての形状復元の手法 [8], [9] が提案されている . そのような多光源を用いるという観点では、Woodham

の方法 [4] では、ルックアップテーブル (LUT) を用いるため、曲率を求めるためには 3 光源でも 9 次元の LUT が必要となると同時に、高次の非線形入出力補間を行うことは困難になるという問題がある . また、岡谷・出口ら、Wolff らの方法は処理時間がかからない方法ではある半面、それらの方法をそのまま多光源の環境に拡張することは困難である .

筆者らは、ニューラルネットワークが高次の非線形入出力補間問題に適していることを利用して、複数光源照明条件下で cast shadow 領域に対してその影響を極力抑えることを目的に、互いに近い方向からの複数光源照明を利用し、反面、光源方向が近いという悪条件を改善するために、主成分分析を用いたニューラルネットワークベース照度差ステレオ法 [10], [12] を提案し、更に cast shadow 領域を含めて物体の傾き分布の精度改善を目的に、イルミネーションプランニングを導入した照度差ステレオ [11] を提案した .

本論文では、照度差ステレオの応用を制限する要因として、複数光源での照明条件下で、曲率符号抽出の問題に対して cast shadow の問題を改善することを目的に、これまで提案してきた方法 [7] をベースに拡張するとともに、イルミネーションプランニングによる光源選択手法 [11] を導入し、複数枚の濃度画像から 6 種類の局所的な曲面を分類、すなわち、曲率符号を局所的かつ直接的に抽出する手法を新たに提案する .

[7] は 3 枚の濃淡画像を用いた曲面分類であるのに対し、今回提案する手法は多数の濃淡画像を用いるため、より精度の高い分類が期待でき、[7] では不可能であった cast shadow 領域での曲面分類も可能となる . [12] では傾き分布の抽出を目的に、観測画像濃度をもとに主成分分析を施した特徴量の組と傾きのマッピングを学習する一つのニューラルネットワークユニットを構築しているが、cast shadow 領域における傾き分布の再構成は解決されていない . cast shadow の問題を解決するためには光源の組合せ問題を考える必要がある . このため [11] では光源選択においてその組合せを決める手法としてあらかじめ必要な組合せ分だけニューラルネットワークユニットを構築しているが、本論文では更に無駄なニューラルネットワークユニットを構築しないことを目的として、必要なニューラルネットワークユニットを動的に構築することにより、実現における効率の向上を図っている . また、[8], [9] の方法は様々な方向 ([8] は大きく異なる 4 方向、[9] は 36 方向) での光源方向から照明された領域ごとに最も良好

な傾きを与える 3 光源を選択するためにイルミネーションプランニングを導入した方法であるのに対して、本手法は複数光源の方向をより近くした条件のもとで cast shadow 領域の検出とともに cast shadow の影響を与えないできるだけ多くの光源を各点ごとに選択することにより、より多くの情報が曲面分類に利用できるという利点がある。

提案する手法のコンピュータシミュレーション及び実際の物体を用いた実験によってその有効性について評価を行う。

2. 背景及び準備

2.1 経験的照度差ステレオにおける複数枚の観測画像濃度の拘束

対象物体の画像上の任意の点 (x_{obj}, y_{obj}) の p 方向の照明条件での観測画像濃度を、各々 $E_{1obj}(x_{obj}, y_{obj})$, $E_{2obj}(x_{obj}, y_{obj})$, \dots , $E_{pobj}(x_{obj}, y_{obj})$ とする。また、通常形状既知の物体を観測することによってlookupアップテーブルを作成し、実現する(経験的)照度差ステレオでは、テスト物体(対象物体)と同一の材質(反射特性)の球を用いて、テスト物体と球を同じ照明条件で撮影したもとの、球画像上の任意の点 (x_{sph}, y_{sph}) の p 方向の照明条件での観測画像濃度を各々 $E_{1sph}(x_{sph}, y_{sph})$, $E_{2sph}(x_{sph}, y_{sph})$, \dots , $E_{psph}(x_{sph}, y_{sph})$ とする。

本手法においても、経験的照度差ステレオを利用し、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(1)を満たす場合には、物体上の点 (x'_{obj}, y'_{obj}) と球上の点 (x'_{sph}, y'_{sph}) とが同じ法線ベクトルをもつことから、観測画像濃度の組の一致という条件を拘束として利用する。

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

従来の 3 光源を用いた経験的照度差ステレオ法の目的は (E_1, E_2, E_3) から各点の傾きを決定することであるが、本手法では、式(1)の制約を用いて、複数枚の画像濃度ベクトル (E_1, E_2, \dots, E_p) からニューラルネットワークを用いてテスト物体の曲率符号を直接的に求めることを目的としている。

表 1 曲面と主曲率の関係

Table 1 Relation between surface curvature and principal curvature.

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

2.2 局所曲面と曲率符号

局所的な曲面には正の楕円面、負の楕円面、双曲面、平面、正の放物面、負の放物面の 6 種類の形状があり、局所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、その局所曲面は k_1, k_2 の符号により表 1 のように分類される。更に、正の楕円面、負の楕円面、双曲面、平面、正の放物面、負の円筒面の 6 種類の曲面において、平均曲率が $M = (k_1 + k_2)/2$ 、ガウス曲率が $G = k_1 \cdot k_2$ により定義されるため、物体の各点の周りの局所曲面が、これら 6 種類の曲面のうちどの曲面に分類されるかがわかれば、ガウス曲率 (G) の符号、更にはガウス曲率が正か 0 ($G \geq 0$) の場合、平均曲率 (M) の符号を一意的に決定することができる。

2.3 RBF ニューラルネットワーク

経験的照度差ステレオにおいて、あらゆる傾きをもつ既知形状物体(球)を対象に物理的な入出力現象の学習と般化を行うために、放射状基底関数ニューラルネットワーク(radial basis function(RBF) neural network)を利用する。RBF ネットワークは特に多次元空間の補間を行うのに有効なニューラルネットワークとして提案された[13]もので、RBF ニューラルネットワークでの学習アルゴリズムは、代表的なフィードフォワードネットワークでのバックプロパゲーション学習アルゴリズム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、学習に用いるデータが多い場合に有効性を発揮し、効率的に学習が行われる。

本手法で構築した RBF ニューラルネットワークのモデルを図 1 に示す。入力ベクトルは $A = (A_1, A_2, A_3)$ であるが、これは画像濃度の組 $E_1 \dots E_p$ に主成分分析による直交変換を行った結果である(入出力ベクトルの与え方については 3. で述べる)。A が各ユニットに入力されると、各ユニットではあらかじめ定義されている c_i との差のユークリッドノルム $\|A - c_i\|$ が計算され、 $\phi(\|A - c_i\|)$ を出力する。 ϕ の具体的な関数形としては、

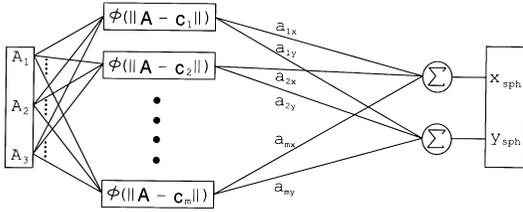


図1 RBFニューラルネットワーク
Fig. 1 RBF neural network.

$$\phi(\mathbf{x}) = \exp\left(-\frac{\mathbf{x}^2}{\sigma^2}\right) \quad \sigma \neq 0 \quad (2)$$

を用いている。

c_i は、入力ベクトルの部分集合を c_i の候補として挙げ、その中で出力への寄与の大きいものが順に選ばれる。

各ユニットから出力された $\phi(\|\mathbf{A} - \mathbf{c}_i\|)$ に重み a_i を掛けたものを足し合わせた

$$\begin{aligned} & (x_{sph}, y_{sph}) \\ & = \left(\sum_{i=1}^m a_{ix} \phi(\|\mathbf{A} - \mathbf{c}_i\|), \sum_{i=1}^m a_{iy} \phi(\|\mathbf{A} - \mathbf{c}_i\|) \right) \end{aligned} \quad (3)$$

をネットワークの出力とする。

a_i はネットワークの出力を

$$\mathbf{y} = P(\mathbf{A})\mathbf{a} + \mathbf{e} \quad (4)$$

ただし

$$P(\mathbf{A}) = \begin{bmatrix} p_1(1) & p_2(1) & \cdots & p_m(1) \\ p_1(2) & p_2(2) & \cdots & p_m(2) \\ \vdots & \vdots & \cdots & \vdots \\ p_1(N) & p_2(N) & \cdots & p_m(N) \end{bmatrix}$$

$$p_i(j) = \phi(\|\mathbf{A}(j) - \mathbf{c}_i\|)$$

$$\mathbf{y} = [y(1) \ y(2) \ \cdots \ y(N)]^T$$

$$\mathbf{a} = [a_1 \ a_2 \ \cdots \ a_m]^T$$

$$\mathbf{e} = [e(1) \ e(2) \ \cdots \ e(N)]^T$$

(N は入 (出) カベクトル数, e はモデル化誤差)

とおき、直交最小 2 乗法により得られる。

$$\mathbf{a} = (P^T P)^{-1} P^T \mathbf{y} \quad (5)$$

(詳しくは [7], [13] を参照)

3. 濃淡画像からの曲率符号抽出

3.1 イルミネーションプランニング

物体の幾何学形状に依存して物体のある領域自身が照明光による他の領域の遮蔽領域となってしまう場合に生じる投影陰影を cast shadow という。この領域の観測濃度情報から局所形状の復元に必要な情報を得ることは不可能である。

そこで、物体を照明する光源数を 4 光源以上とし、これらすべての光源下の濃度画像を入力として一度復元処理を行った後、その結果をもとに、主に cast shadow が原因で精度の悪かった点を評価基準に従って抽出し、これらの点を照明する光源のうち cast shadow となるものを各点ごとに選別・棄却し、残る光源で cast shadow 領域とみなされた各点の情報を再度復元することにより、最終的な曲率符号の復元結果の精度向上を図るものとする。

cast shadow の存在が確認される領域に対しては、近い方向からの複数光源照明を利用するため、相互の光源方向が近いと数値的の求解条件が悪条件になる。その問題を改善するために、複数光源を用いて次元圧縮と特徴抽出を行う目的で主成分分析 (PCA) をニューラルネットワーク入力の前処理として導入する [10], [12]。

3.2 処理の手順

本手法では、多光源環境下でのニューラルネットワークベースの経験的照度差ステレオの原理を用いて、物体の任意の点とその近傍点の観測画像濃度をもとに、その点の周りの局所曲面の種類を決定する。本手法による物体の濃淡画像からの曲率符号抽出のための曲面の分類の流れを図 2 に示す。手法は [step 1] の RBF ニューラルネットワークによる学習と一般化 [step 2] のイルミネーションプランニング [step 3] の曲面分類からなり、各々の処理内容を以下に示す。

[step1] RBF ニューラルネットワークによる学習と一般化

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 4 点の観測濃度が、それぞれ照明条件での球画像上のどの点の観測画像濃度に等しいかを求めればよい。これを実現する目的で、ニューラルネットワークの学習データとして、球画像の各点での観測画像濃度 $(E_1(x_{sph}, y_{sph}), E_2(x_{sph}, y_{sph}), \dots, E_p(x_{sph}, y_{sph}))$ をもとに主成分

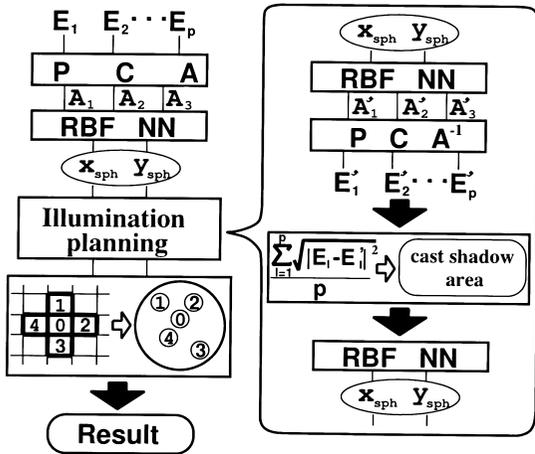


図2 曲面分類の流れ

Fig.2 Procedure to get the classification of a curved surface.

分析により直交変換を施し、3次元に次元圧縮した特徴量の組 $A = (A_1(x_{sph}, y_{sph}), A_2(x_{sph}, y_{sph}), A_3(x_{sph}, y_{sph}))$ をニューラルネットワークの入力として与え、対応する点の位置座標 (x_{sph}, y_{sph}) をニューラルネットワークの出力として与えて学習を行う。球上の何点かのこれら入出力ベクトルをデータセットとして用いることにより、RBFニューラルネットワークによる学習を行う。学習したRBFニューラルネットワークは、 $(A_1, A_2, A_3) \rightarrow (x_{sph}, y_{sph})$ という変換を行うためのものであり、このニューラルネットワークに物体画像上の任意の点 (x_{obj}, y_{obj}) の観測画像濃度の特徴量の組 $(A_1(x_{obj}, y_{obj}), A_2(x_{obj}, y_{obj}), A_3(x_{obj}, y_{obj}))$ を入力として与える。 $(A_1(x_{obj}, y_{obj}), A_2(x_{obj}, y_{obj}), A_3(x_{obj}, y_{obj}))$ を求める際、球の観測画像濃度値の組から得られた共分散行列を物体画像の観測画像濃度値ベクトル $(E_1(x_{obj}, y_{obj}), E_2(x_{obj}, y_{obj}), \dots, E_p(x_{obj}, y_{obj}))$ に適用して特徴量の組 $(A_1(x_{obj}, y_{obj}), A_2(x_{obj}, y_{obj}), A_3(x_{obj}, y_{obj}))$ を求め、得られたテスト物体の特徴量の組を入力として与えることによって、ニューラルネットワークの般化(ノンパラメトリック関数近似)が行え、同じ観測画像濃度をもつ球画像上の座標が得られる。任意の点の近傍点について学習したニューラルネットを用いて各々の点の球上での対応点を得ることができる。

[step2] イルミネーションプランニング

[step1]でのニューラルネットワークにより物体画像上の任意の点の観測画像濃度から対応する球画像上

の座標を得ることができる。しかし、学習したニューラルネットワークは球を対象としており、球に cast shadow はあり得ないため、物体の cast shadow あるいは内部反射の影響によっては、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。

本手法では、このうち cast shadow が原因で精度の悪かった点を抽出し、cast shadow となる領域を照明する光源のうち直接的に cast shadow を生じる光源を選別・棄却することによって、残りの光源で同じ点を再度復元することにより復元結果の精度向上を図る。

cast shadow 領域の検出を目的として [step1]でのニューラルネットワークとは学習データの入出力を逆にして与え学習するニューラルネットワークとして、 $(x_{sph}, y_{sph}) \rightarrow A(x_{sph}, y_{sph})$ という逆変換を行うRBFニューラルネットワークを構築し、学習したそのニューラルネットワークに [step1]で得られた球画像上の座標を入力として与えると、出力としてその点に対して推定特徴量の組 $A'(x_{obj}, y_{obj})$ が得られる。この出力結果に [step1]の直交変換の逆変換を施し、復元画像濃度の組 $(E'_1(x_{obj}, y_{obj}), E'_2(x_{obj}, y_{obj}), \dots, E'_p(x_{obj}, y_{obj}))$ を得る。

ここで、 E と E' との差分の2乗和平均を局所的な信頼性の評価値 (local confidence estimate) C として以下に定義する。また、物体の全表面中の単位点当りの C の平均 ($mean(C)$) も同様にして定義する。

$$C = \frac{\sqrt{\sum_{l=1}^p |E_l - E'_l|^2}}{p} \quad (l = 1, 2, \dots, p) \quad (6)$$

$$mean(C) = \frac{\sum_{n=1}^{N_{obj}} C(n)}{N_{obj}} \quad (7)$$

(N_{obj} : 物体領域の総ピクセル数)

[step1]で得られた座標が正確であれば元の観測濃度の組と復元画像濃度の組とはほぼ等しくなるはずであり、局所的な信頼性の評価値 C は限りなく小さくなる。cast shadow 領域では正確な座標は得られず、局所的な信頼性の評価値は大きくなる。そこで、各点での評価値 C を用いて C がある一定値以上の場合にはその点を cast shadow 領域とみなすことにより該当する領域を抽出する。

cast shadow 領域を抽出するためのしきい値は以下

のようにして決定する。

球画像の観測画像濃度の組から得られた特徴量の組を [step1] の処理を行った後の順方向ニューラルネットワーク及び [step2] で構築した逆変換ニューラルネットワークに通すことによって、球画像に対する評価値を求める。得られた評価値の平均 $mean(C)$ 、標準偏差 σ を計算する。これら平均と標準偏差の値は球画像においてはともに小さいため、ほぼすべての点において評価値は $mean(C) + 3\sigma$ 以下となる。他方、テスト物体画像上の点の特徴量の組を通した場合、それより大きい評価値を与える点があったとすれば、その点は球には存在し得ない cast shadow (あるいは内部反射等) の現象である。このような理由から $mean(C) + 3\sigma$ を cast shadow 領域抽出に対するしきい値 Th とする。

次に抽出された cast shadow 領域の各点ごとに、cast shadow を生じる光源を特定・棄却する処理を行う。

cast shadow 領域中の各点では観測画像濃度の組のうち、cast shadow を生じる光源による観測画像濃度は非常に小さくなる。そこで、小さい観測画像濃度を与える光源は cast shadow 光源の候補であるとみなし、そのような光源はその点の復元には使用しないものとして棄却する。

cast shadow を生じる光源による観測画像濃度は各点ごとに幅があるため、ある特定のしきい値を用いて棄却しようとする、しきい値が小さすぎた場合 cast shadow を生じる光源を棄却できない。また、大きすぎると必要な光源を棄却してしまい、精度の高い分類ができない。そこで、より精度の高い分類を行うために以下の処理を行う。

(1) cast shadow 領域の各点ごとに観測画像濃度値の一番小さい光源を棄却し、残りの光源を用いてそれらの光源の組合せのもとで得られる画像観測濃度の組だけを用いたニューラルネットワークを [step1] で構築し、対応する球画像上の座標を得る。

(2) 次に得られた座標から [step2] で構築した逆変換ニューラルネットワークに入力して特徴量の組を得た後、特徴量の組から直交変換の逆変換を行い得られた復元画像濃度値の組と観測画像濃度値の組をもとに式 (6) から評価値を算出する。

(3) 評価値が cast shadow 領域抽出に用いたしきい値 Th 以下になるか、cast shadow を与えない残りの光源数として必要数である 3 になるまで上記の (1)

と (2) を繰り返す。残りの光源数が 3 になった場合には、繰返しの過程の中で一番小さい評価値を与えた光源の組合せを採用する。

なお、ニューラルネットワークは各点ごとに必要な光源の組合せにより構築するが、この際ある点を対象にいったん構築したニューラルネットワークユニットは別の点を対象として必要な場合には再度構築せず、必要なニューラルネットワークユニットだけをテスト物体に対して構築する。[11] はあらかじめすべてのニューラルネットワークユニットの組合せを学習したのに対して、本手法ではこのように動的にニューラルネットワークユニットの構築を行うことにより、[11] と比べ無駄なニューラルネットワークユニットを構築しないため効率が向上している。

上記処理を行った結果を cast shadow 光源の影響を取り除いた結果として、テスト物体の近傍点の球上での写像点を求め、それらの分布に基づいて以下の [step3] により曲率符号を判定する。

[step3] 曲面の分類による曲率符号の判定

6 種類の曲面は表 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 6 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号が決定できる。ここでは 6 種類の曲面が各々球上に写像されたときに、近傍点の分布が球上でどのように分布するかという特徴と判定方法について記述する。

簡単のため、近傍点の中心点を ① とし、その真上の点を ②、そこから時計回りに ③、④ と番号付ける。6 種類の曲面のある点を中心とした近傍点の法線ベクトルには特徴があるため、これら近傍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 5 点の位置関係という情報に変換される。よって、5 点の位置関係を用いて対象物体の任意の点の曲面を分類することができる。

6 種類の曲面における各々の幾何学的な性質から、近傍点が球上にどのように写像されるかという観点で導出した特徴パターンを以下に示す。

正の楕円面：球も正の楕円面であるため、正の楕円面の近傍点を、球への写像を行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、正の楕円面の近傍点 ①～④ を球上に写像しても、①を中心とした時計回りに ①～④ が写像される。

負の楕円面：正の楕円面の近傍点の ①と③、②と④をそれぞれ入れ換えると負の楕円面になる。そのため負の楕円面の近傍点 ①～④ を球上に写像すると、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ときに比較して、180°位相がずれたものになる。

双曲面：球の場合、 k_1, k_2 が $k_1 > 0, k_2 > 0$ 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、双曲面の近傍点①～④を球上に写像すると、①を中心とした反時計回りに①～④が写像される。

平面：平面は中心点と近傍点が同じ法線ベクトルをもつため、①～④は球上の同じ位置へと写像される。

正の放物面：正の放物面は $k_1 > 0$ かつ $k_2 = 0$ であり、球上に点①～④を写像すると、①～④が同じ直線上に写像される。

負の放物面：負の放物面は $k_1 = 0$ かつ $k_2 < 0$ であり、球上に点①～④を写像すると、①～④が同じ直線上に写像されるが、正の放物面と比較して180°位相がずれたものになる。

一般にニューラルネットの出力によりパターンのひずみが生ずることはあるが、①の位置に対して①から④が位置する相対的な位置関係の特徴が規則性をもっている限り、任意の局所曲面は上の6種類のいずれかに分類可能である。また、近傍点の数が4点以上であっても時計回りあるいは反時計回り、直線、あるいは点といった個々の写像点による特徴が保持される限り、アルゴリズムはそのまま拡張可能である。

複数枚の濃淡画像を用いてニューラルネットワークとイルミネーションプランニングを導入した本手法では、複数枚を用いる効果と主成分分析による効果を加えて、cast shadow 領域については、更にイルミネーションプランニングによってニューラルネット選択効果が作用することによって、球上に写像される座標をより正確なものとするのが可能である。各点ごとの局所的な曲面の種類は上に示した近傍点の位置情報の特徴を用いて分類・判定し、cast shadow 領域については全く改善できない従来の3光源の結果[7]を改善することが可能である。

4. 実験

本手法に基づいて計算機シミュレーション及び実画像を用いた実験を行った。

4.1 シミュレーション画像を用いた実験

テスト物体として式(8)で示すような2次元 sinc 関数を対象に計算機シミュレーションを行った。

$$f(x, y) = 3 \cdot \frac{\sin x}{x} \cdot \frac{\sin y}{y} \quad (-2\pi < x, y < 2\pi) \quad (8)$$

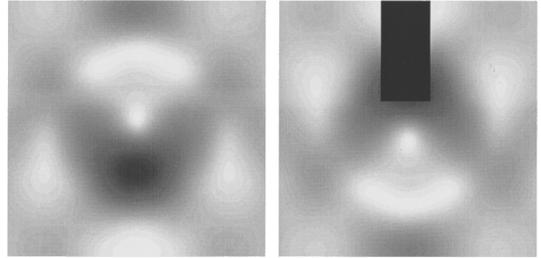


図3 sinc 関数画像
Fig.3 Images of sinc function.

表2 RBF ニューラルネットワークの学習条件 (sinc 関数)

Table 2 Learning condition of RBF neural network. (sinc function)

learning data		number of learning epoch	spread constant
Input	Output		
A	(x_{sph}, y_{sph})	50	150
(x_{sph}, y_{sph})	A	50	40

光源は、天頂角 30° で、方位角を 0° から、45° ずつ位相をずらした 8 個と、天頂角 20° で、方位角を -22.5° から 45° ずつ位相をずらした 8 個、計 16 個を用いて、球と 2 次元 sinc 関数とも各々 16 枚の濃淡画像を生成し、使用した。2 次元 sinc 関数の画像の例を図 3 に示す^(注1)。濃淡画像の大きさは 512 × 512 ピクセルで、各点の濃淡レベルは 256 階調とした。512 × 512 の画像中で、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。データ点数は球物体画像が 531 点、テスト物体画像が 16384 点である。また、テスト物体画像のデータ点中の曲面分類可能点数は 15376 点であった。これは、曲面分類をする際、近傍 4 点を用いるため、近傍点が存在しない物体の周囲の点では分類ができないためである。また、図 3 の右側の画像のように、擬似的に cast shadow 領域を付加した画像を 5 枚作成している。

RBF ニューラルネットワークの学習条件を表 2 に示す。表中の spread constant は式(2)の σ に相当する値である。

実験結果から生成した評価画像を図 4～図 6 に示す。

主成分分析とニューラルネットワークアーキテクチャにより抽出した cast shadow 領域を図 4 に示す。

(注1): ここで、2 次元 sinc 関数と球の画像を生成するにあたっては、反射特性として Lambert モデルを用いたが、経験的照度差ステレオでは、テスト物体である sinc 関数と球とが同一の反射特性でありさえすればよい。

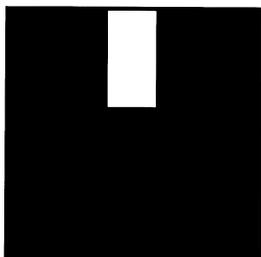


図4 cast shadow 領域 (sinc 関数)
Fig.4 Cast shadow area. (sinc function)

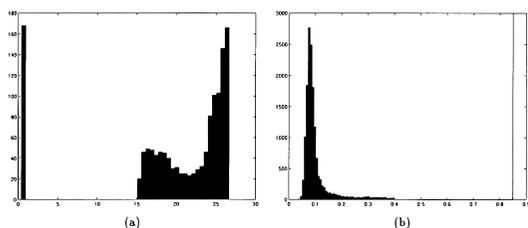


図5 評価値ヒストグラム (sinc 関数)
Fig.5 Histogram for local confidence. (sinc function)

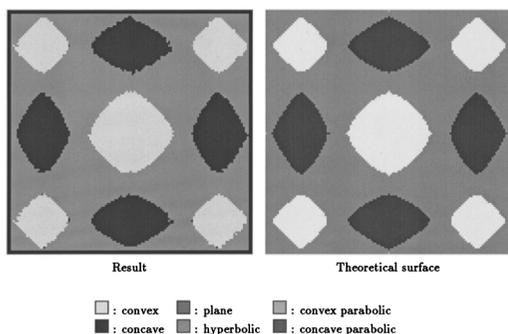


図6 曲面分類結果画像 (sinc 関数)
Fig.6 Result for 2-D sinc function.

cast shadow 領域が的確に抽出されていることが確認できる。cast shadow 領域抽出のためのしきい値は、球の画像濃度の組から得られた局所的な信頼性の評価値の平均が 0.1819、標準偏差が 0.2207 であったため、0.8494 となり、抽出点数は 1152 点であった。

テスト物体の局所的な信頼性の評価値のヒストグラムを図 5 に示す。(a) は全体のヒストグラム (ただしグラフを見やすくするために評価値が 0.4 以下のものは削除してある)、(b) は (a) の 0 近辺のヒストグラムを拡大したものである。球の画像濃度の組から得

表3 実験結果
Table 3 Result for 2-D sinc function.

	Theoretical	Result	number of corrected points	corrected %
convex	3205	3286	3163	98.6895
concave	3121	3028	3007	96.3473
hyperbolic	9050	9062	8928	98.6519
total	15376	15376	15098	98.1920

表4 実験結果 (cast shadow 領域のみ)
Table 4 Result for 2-D sinc function. (only cast shadow area)

	Theoretical	Result	number of corrected points	corrected %
convex	103	120	102	99.0291
concave	577	566	563	97.5737
hyperbolic	472	466	456	96.6102
total	1152	1152	1120	97.3090

られた評価値の平均と標準偏差から得られたしきい値により cast shadow 領域が適切に得られていることが確認できる。

図 4 に示されている領域中の各点において cast shadow を生じる光源の可能性の高い、低い観測画像濃度値を与える光源を棄却し、残りの光源を用いてそれらの光源の組合せのもとで得られる観測画像濃度の組だけを用いたニューラルネットワークを構築した。構築されたニューラルネットワーク数は 6 個であった。cast shadow 領域中の各点において cast shadow 光源として棄却された光源は cast shadow 光源のみであることを確認し、本手法で的確に cast shadow 領域を抽出し、cast shadow 光源を特定できることが確認できた。

本手法による曲面分類結果と 2 次元 sinc 関数の理論的な (幾何学的な) 分布を図 6 に示す。曲面分類結果の理論的な分布に対する正解率を評価した結果、表 3 に示すように、約 98% の正解率が得られた。約 2% の誤認識は、ガウス曲率が 0 の付近で起きている。このことは、入力画像の濃度分解能が 8 ビットであることによって、ニューラルネットワークの出力がほとんど同じになり、その結果、近傍 4 点の画像濃度の組が球上のほとんど同じ点に写像されるため、ガウス曲率が 0 付近での境界での判定が困難な場合があり得ることを意味している。

また、本手法の cast shadow 領域での復元結果の正解率を表 4 に示す。約 97% の正解率が得られている。局所的な信頼性を示す評価値の平均も、イルミネー

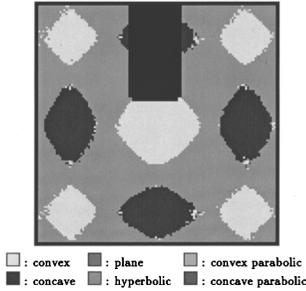


図7 3光源照明での方法による実験結果画像

Fig. 7 Result for 2-D sinc function by 3 light source method.

表5 3光源照明での方法による実験結果

Table 5 Result for 2-D sinc function by 3 light source method.

	Theoretical	Result	number of corrected points	corrected %
convex	3054	3094	2948	96.5291
concave	2478	2364	2329	98.2608
hyperbolic	8452	8305	8305	93.9871
other	0	28	0	0
total	13984	13984	13582	97.1253

シヨンプランニング前の cast shadow 領域での評価値の平均が 16.3756 であるのに対して、イルミネーションプランニング後では 0.1575 となっている。評価値は低いほど局所的な信頼性が高いことを示しており、この結果からも本手法でのイルミネーションプランニングは cast shadow 問題に有効な方法であるといえる。

比較のため、3光源照明での方法 [7] での結果を図 7 に示す。3枚の濃淡画像のうち、1枚に対して図 3 の右側の画像のように、擬似的に cast shadow 領域を付加した画像を用いている。

3光源照明での方法では、cast shadow 領域での分類は不可能であるので、図 7 では cast shadow 領域は分類不可能領域として黒く表示している。

3光源照明での方法による分類結果の正解率を表 5 に示す。表 3 と比較すると、今回提案した手法は cast shadow 領域以外の領域についても復元結果を改善していることが確認できる。

次に、主成分分析の効果を見るために光源条件を変えて実験を行った。光源は、天頂角 10° で、方位角をそれぞれ 0° から 210° まで、 15° ずつ位相をずらした 16 個を用いて、球と 2 次元 sinc 関数とも各々 16 枚の濃淡画像を生成し、使用した。また、擬似的に cast shadow 領域を付加した画像を 3 枚作成している。

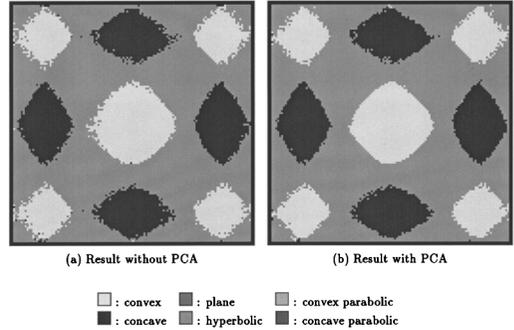


図8 曲面分類結果画像 (sinc 関数)

Fig. 8 Results for 2-D sinc function.

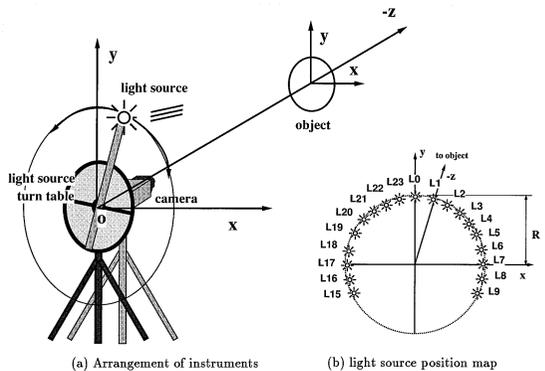


図9 撮影環境

Fig. 9 Environment for taking images.

実験結果を図 8 に示す。主成分分析を施さない (a) は、ニューラルネットは球の各点の 16 光源の観測画像濃度の組を入力とし、対応する球画像上の座標を出力とする学習を行った結果である。主成分分析を施した (b) の方が分類結果が良く、正解率を比較すると (a) が 95.1678% であるのに対し、(b) が 96.4490% となっており、主成分分析が光源が近いという悪条件を緩和していることがわかる。

4.2 実物体を用いた実験

実際の物体を撮像した濃淡画像を用いて曲面分類の実験を行った。

実験に用いた物体は、球物体、テスト物体 (以下 cook と呼ぶ) の 2 種類である。2 種類の物体の撮影環境を図 9 に示す。cook を曲率符号抽出の対象物体として用い、球物体画像は cook の曲率符号を求めるときの、同じ観測画像濃度をもつ点への写像を行うためのデータとして用いた。

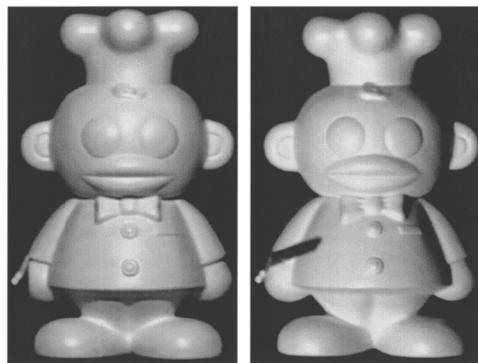


図 10 cook の濃淡画像
Fig. 10 Original images of cook.

z 軸上の原点 $(0, 0, 0)$ に設置した CCD カメラで $(0, 0, -200)$ に設置した物体を撮影した。光源は z 軸上の $(0, 0, +30)$ を通って z 軸に垂直な平面内で $(0, 0, +30)$ を中心に半径 $R = 100$ の円周上の点で、 y 軸上の点を L0 とし、続いて 15° ずつ位相をずらし、L1, L2, L3, L4, L5, L6, L7, L8, L9, L15, L16, L17, L18, L19, L20, L21, L22, L23 (L10~L14 はカメラの三脚と重複するため除外) の 19 個設置した。 z 軸と、各円周上の光源からの光源方向と z 軸のなす角は 23.5° である。

以上の照明条件で各光源につき濃淡画像を各 1 枚ずつ撮影し、球物体, cook それぞれ 19 枚, 計 38 枚撮影した。また、反射特性は球, cook とともに、同一の反射特性を実現するため、ともに白塗料で塗装を施した^(注2)。

cook の濃淡画像の例を図 10 に示す。cook は右手に箸を持っているため、右腕のあたりに cast shadow が生じている。濃淡画像の大きさは 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 の濃淡画像中で、球は 6 ドットおきに、cook は 2 ドットおきにそれぞれの物体上の点を抽出し実験データとして用いた。データ点数は球物体画像が 650 点、テスト物体画像が 19325 点である。また、テスト物体画像のデータ点中の曲面分類可能点数は 16506 点であった。

RBF ニューラルネットワークの学習条件を表 6 に示す。

実験結果から生成した評価画像を図 11~ 図 14 に示す。

表 6 RBF ニューラルネットワークの学習条件 (cook)
Table 6 Learning condition of RBF neural network. (cook)

learning data		number of learning epoch	spread constant
Input	Output		
A	(x_{sph}, y_{sph})	60	300
(x_{sph}, y_{sph})	A	60	50



図 11 cast shadow 領域 (cook)
Fig. 11 Cast shadow area. (cook)

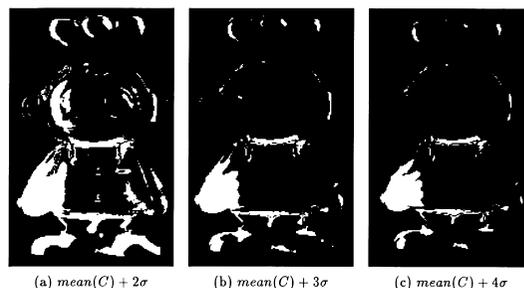


図 12 しきい値の違いによる cast shadow 領域の変化
Fig. 12 Cast shadow area for each threshold.

cast shadow 領域として抽出する評価値のしきい値は、球の画像濃度の組から得られた局所的な信頼性の評価値の平均が 1.0949 であり、標準偏差が 1.0857 であったため、4.352 となった。実験において曲面分類可能な領域中の cast shadow 領域として抽出された領域を図 11 に示す。近傍に 4 点存在しない点を除いて対象となった物体領域中の点数は 2206 点であった。物体の頭部の周辺においては傾きが大きいため、相対的に評価値が大きくなる傾向があり、その結果若干で

(注 2) : 反射特性に関して何らかの (例えば Lambert や Phong に代表されるような) 関数形は仮定していないので、反射特性が双方の物体に対して同一条件でありさえすればよい。

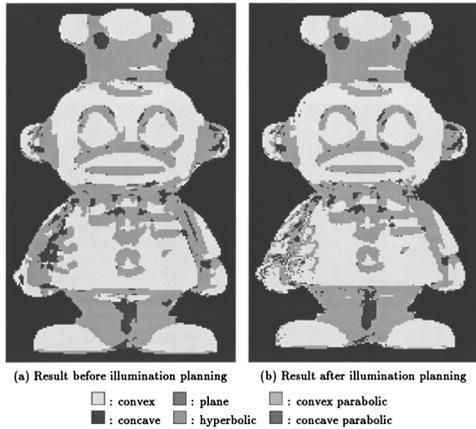


図 13 曲面分類結果画像 (cook)
Fig. 13 Results for cook.

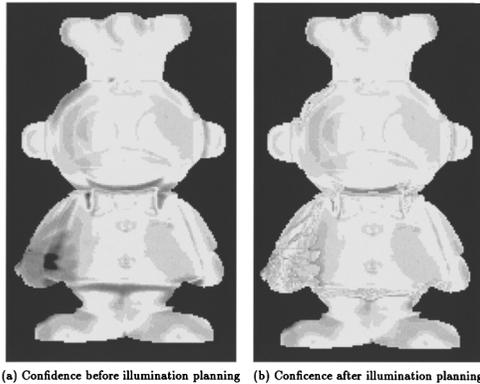


図 14 局所的信頼性画像 (cook)
Fig. 14 Images of local confidence. (cook)

あるが cast shadow 領域として抽出されてしまうことがある。

cast shadow 領域以外に傾きの大きな点で信頼性の低い点が存在するので評価値のヒストグラムは双峰的にはならない。そこで、しきい値の違いによる抽出される領域の変化を図 12 に示す。右手の箸による cast shadow 領域ではほとんど変化していないことがわかる。これは cast shadow は球に存在し得ない現象であるので cast shadow 領域中の点は評価値がかなり大きいためである。

図 12 において (a) と (b) とは抽出された領域にかなり相違が見られるが、(b) と (c) ではあまり相違が見られなくなることから cast shadow 領域を抽出するため

のしきい値は 3.2 で示したように $mean(C) + 3\sigma$ 程度の値であれば cast shadow 領域以外の点も多少抽出されてしまうものの、それらの点においても 3.2 での反復処理の過程でより信頼性のある結果を出力するので特に問題は生じない。このことから、cast shadow 領域を抽出するためのしきい値は球の評価値の分布をもとに $mean(C) + 3\sigma$ 程度と決めることが妥当であると判断できる。

なお、構築されたニューラルネットワークユニットの数は 1367 個であった。[11] では、15 個の光源を用いた場合に、cast shadow を生じる光源として最大 5 光源棄却するとして用意しなければならないニューラルネットワークユニット数が約 5000 個であったので、本手法では無駄なニューラルネットワークユニットを構築しないためニューラルネットワークユニット数が抑えられていることがわかる。

図 13 (a) はイルミネーションプランニング前、(b) はイルミネーションプランニング後の結果である。cast shadow 領域である右腕の部分は (a) ではほとんど双曲面と分類されているが、(b) では正の楕円面と判定されている部分が多くなっている。図 10 からわかるように、右腕の部分は正の楕円面であるので、cast shadow の影響を取り除いていることがわかる。

図 14 は各点における局所的な信頼性を示す評価値 C を画像化したものである。白い方が評価値が低く復元精度の高い領域で、黒くなるほど精度の低い領域となる。(a) と (b) を比較すると cast shadow 領域でかなりその影響が取り除かれていることがわかる。実際に数値で見ると、イルミネーションプランニング前には 12.4308 であった cast shadow 領域での評価値の平均がイルミネーションプランニング後は 4.2705 となり、65.6%の改善が見られた。

次に、主成分分析の効果を見るために光源条件を変えて実験を行った。光源は、 z 軸上の $(0, 0, +30)$ を通って z 軸に垂直な平面内で $(0, 0, +30)$ を中心に半径 $R = 64$ の円周上の点で、 x 軸上の点を L_0 とし、続いて 10° ずつ位相をずらし、 $L_1, L_2, L_3, L_4, L_5, L_6, L_7, L_8, L_9, L_{10}, L_{11}, L_{12}, L_{13}, L_{14}, L_{15}, L_{16}, L_{17}, L_{18}$ の 19 個設置した。 z 軸と、各円周上の光源からの光源方向と z 軸のなす角は 15.55° である。

実験結果を図 15 に示す。(a) ではボタンや目の周りで分類結果が間違っていることが確認でき、主成分分析が光源が近いという悪条件を (b) では緩和している

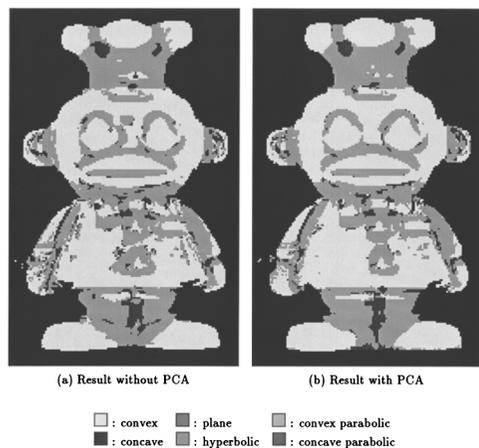


図 15 曲面分類結果画像 (cook)
Fig. 15 Results for cook.

ことが確認できる。

抽出された cast shadow 領域は 662 点であり，光源条件が良い場合と比べて減少している．これは，光源条件を悪くすると cast shadow 領域が減少することを示している．その逆に，光源条件を良くすれば（半径 R を相対的に大きくとれば）各画像間の相関が減少し，主成分分析の効果は小さくなるが，その反面 cast shadow 領域が増加し，イルミネーションプランニングの効果が大きくなる．逆に光源条件を悪くすれば（半径 R を相対的に小さくとれば）cast shadow 領域が減少し，イルミネーションプランニングの効果は小さくなるが，主成分分析が相対的に効いてくる．しかしながら，光源条件がどの程度良いとか悪いとかを適切に評価してシステムが自動的に判断することは困難であるため，本手法のように主成分分析とイルミネーションプランニングの双方を導入することにより，結果が光源の条件に敏感に影響されにくいという利点もある．

5. む す び

本論文では物理ベースビジョンのアプローチの一つとして，ニューラルネットワークベース照度差ステレオにおいてイルミネーションプランニングを導入して複数枚の濃淡画像から局所的な曲面の分類を行う方法を新たに提案した．

従来の 3 光源照度差ステレオでは適用不可能であった cast shadow の問題に対して，複数光源照明条件下

での主成分分析と RBF ニューラルネットワークによる cast shadow の検出方法及び各点ごとに cast shadow を生じる光源を特定・棄却した上で残りの光源の組合せによるニューラルネットワークを学習しておくことにより，cast shadow 領域の点については，テスト物体の近傍点の観測画像情報を入力としたときに，対応する光源の組合せのニューラルネットワークを用いて般化を行い，より正確な位置関係を得ることにより局所的な曲面の分類を行う手法を導入し，その有効性について述べた．

手法は，経験的照度差ステレオの原理により，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号を抽出することができる．濃淡画像から曲面の分類を行う際には，各点での面の傾きパラメータの値は必要としないため，経験的照度差ステレオでのキャリブレーション処理は不要であるという特徴がある．

また，複数光源下でのイルミネーションプランニングの導入により cast shadow 領域の復元を可能にしたほか，領域全体においても先に提案した 3 光源の場合と比較しても対象領域全体にわたり，復元結果の精度向上が見られた．

今後の課題としては，曲率符号のみではなく，ニューラルネット等の導入で局所的な曲率の値を濃淡画像から直接推定する方法や，内部反射の問題を物理ベースの方法で解決する方法等を検討することが挙げられる．

謝辞 本研究の一部は（財）堀情報科学振興財団の支援を受けて行われた．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る．

文 献

- [1] R.J. Woodham, "Photometric method for determining surface orientation from multiple images," *Opt. Eng.*, pp.139-144, 1980.
- [2] 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.
- [3] G. Healey and R. Jain, "Physics-based machine vision," *J. Opt. Soc. Am., A*, vol.11, p.2922, 1994. (Introduction to special issue).
- [4] R.J. Woodham, "Gradient and curvature from the

photometric-stereo method, including local confidence estimation,” J. Opt. Soc. Am. A, pp.3050-3067, Nov. 1994.

- [5] E. Angelopoulou and L.B. Wolff, “Sign of Gaussian curvature from curve orientation in photometric space,” IEEE Trans. PAMI, vol.20, no.10, pp.1056-1066, Oct. 1998.
- [6] 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の符号の決定,” 情報学論, vol.39, no.6, pp.1965-1972, 1998.
- [7] Y. Iwahori, S. Fukui, R.J. Woodham, and A. Iwata, “Classification of surface curvature from shading images using neural network,” IEICE Trans. Inf. & Syst., vol.E81-D, no.8, pp.889-900, Aug. 1998.
- [8] F. Solomon and K. Ikeuchi, “Extracting the shape and roughness of specular lobe objects using four light photometric stereo,” 1992 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, pp.466-471, June 15-18, 1992.
- [9] F. Solomon and K. Ikeuchi, “An illumination planner for convex and concave lambertian polyhedral objects,” Workshop on Physics-Based Modeling in Computer Vision, pp.100-107, June 18-19, 1995.
- [10] Y. Iwahori, R.J. Woodham, and A. Bagheri, “Principal components analysis and neural network implementation of photometric stereo,” Proc. IEEE Workshop on Physics-based Modeling in Computer Vision, pp.117-125, (MIT, MA) June 1995.
- [11] Y. Iwahori, W. Kato, Md.S. Bhuiyan, R.J. Woodham, and N. Ishii, “Neural network based photometric stereo using illumination planning,” Proc. of IJCAI-97, vol.2, pp.1496-1501, 1997.
- [12] Y. Iwahori, R.J. Woodham, M. Ozaki, H. Tanaka, and N. Ishii, “Neural network based photometric stereo with a nearby rotational moving light source,” IEICE Trans. Inf. & Syst., vol.E80-D, no.9, pp.948-957, Sept. 1997.
- [13] S. Chen, C.F.N. Cowan, and P.M. Grant, “Orthogonal least squares learning algorithm for radial basis function networks,” IEEE Trans. Neural Networks, vol.2, no.2, pp.302-309, 1991.
- [14] J. Fan and L.B. Wolff, “Surface curvature from integrability,” Proc. of CVPR 1994, pp.520-525, 1994.
- [15] S. Chen, S.A. Billings, and W. Luo, “Orthogonal least squares methods and their application to non-linear system identification,” Int. J. Contr., vol.50, no.5, pp.1873-1896, 1989.
- [16] A. Björck, “Solving linear least squares problems by Gram-Schmidt orthogonalization,” Nordisk Tidskr. Informations-Behandling, vol.7, pp.1-21, 1967.

(平成11年2月8日受付, 7月27日再受付)



福井 真二 (学生員)

平8名工大・知能情報システム卒・平10同大大学院博士前期課程電気情報工学専攻了。現在,同大学院博士後期課程在学中。ニューラルネットワーク,コンピュータビジョンに関する研究に従事。



岩堀 祐之 (正員)

昭58名工大・情報卒,昭60東工大大学院修士課程・電気・電子工学専攻了。昭63同大大学院博士課程了。工博。同年名工大・情報処理教育センター・助手。平4同大・助教授,現在に至る。この間カナダブリティッシュコロンビア大学客員研究員。コンピュータビジョン,ニューラルネットワーク,パターン認識に関する研究に従事。情報処理学会,IEEE各会員。



ロバート J. ウッドガム

昭46ウェスタンオンタリオ大・数学卒。昭49MIT電気工学専攻修士課程了。昭52MIT電気工学及び計算機科学専攻博士課程了。Ph.D.昭53MIT博士研究員。同年ブリティッシュコロンビア大学(UBC)講師。昭59より平6Canadian Institute for Advanced Research(CIAR)人工知能・ロボティクス部門フェロー。現在UBC計算機科学科教授・学科長。コンピュータビジョン(照度差ステレオ,オプティカルフロー,形状表現)に関する研究に従事。IEEE会員。



岩田 彰 (正員)

昭48名大・工・電気卒。昭50同大大学院修士課程了。同年名工大・情報・助手。昭57年4月より昭58年10月まで,ドイツ連邦共和国ゲーゼン大学医学部医用情報工学研究所客員研究員。昭60名工大・情報・助教授。平5名工大・電気情報・教授,現在に至る。医用情報処理,ニューラルネットワーク,遠隔診断支援システムなどに関する研究に従事。工博。平5本学会論文賞,平10情報処理学会Best Author賞受賞。平11郵政省電気通信管理局長表彰。情報処理学会,日本ME学会,神経回路学会,計測自動制御学会,IEEE各会員。