

3次元高次局所自己相関特徴マスクを用いた ソリッドテクスチャの分類

鈴木 一 史†

高次局所自己相関特徴は2次元画像の認識や解析などに用いられる重要な特徴である。本研究では、3次元高次局所自己相関マスク(3×3×3)を用いて、3次元ソリッドテクスチャの特徴抽出と類似検索を行った。3次元マスクを構成するパターンは膨大な数の組合せがあるため、シミュレーションプログラムを用いて3次元マスクのパターンを計算した。実験では3次元ソリッドテクスチャのデータベースから高次局所自己相関特徴を抽出し、これを索引として3次元ソリッドテクスチャの類似検索を行った。また、3次元ソリッドテクスチャの形状パターンから得られた高次局所自己相関特徴を重回帰分析を用いることで形状パターンをシステムへ学習させ、3次元ソリッドテクスチャ領域内に含まれる形状パターンの個数を統計的に推測することを可能にした。

A Solid Texture Classification Method Based on 3D Mask Patterns of Higher Order Local Autocorrelations

MOTOFUMI T. SUZUKI†

Higher order local autocorrelation (HLAC) has been used as feature descriptors for various pattern recognition applications, including 2D image classification, recognition and detection. In this research, we have extended higher order local autocorrelation (HLAC) 2D mask patterns to 3D mask patterns so that pattern analysis software can handle not only 2D texture images but also 3D solid textures. Our experimental system can classify and look for 3D solid textures with similar patterns from a 3D solid texture database by using 3D HLAC masks. We have examined (1) similarity retrieval of 3D solid textures and (2) pattern classification of 3D solid textures by using the system.

1. はじめに

高次局所自己相関特徴は様々なパターン認識技術^{1),7),8)}に応用されてきた重要な画像特徴である。高次局所自己相関特徴は平行移動に対して不変であり、2次元画像から高速に計算できることから顔画像認識⁶⁾、ジェスチャ認識⁵⁾、マルチモーダルシステム²⁾などに応用されてきた。また、2次元画像のパターンを要約する優れた画像特徴であり、多変量解析などの手法と組み合わせることで、意匠・商標画像検索⁹⁾、絵画検索¹⁰⁾、景観画像検索¹⁸⁾、テクスチャ検索¹²⁾などに利用されてきた。近年、自己相関関数の次元を拡張した2次元テクスチャの分類に関する研究^{3),4)}、3次元物体モデルから高次局所自己相関特徴を抽出する手法¹³⁾、動画像を時系列の連続した2次元画像として扱うことで、立体マスクパターンを人物動画像認識へ応用した

手法^{15),16)}などが提案されている。

グラフィックスハードウェアの発展にともない、一般的なパーソナルコンピュータでも高速にポリゴンやボクセルといった3次元データを高速に処理できるようになってきた。その結果、3次元データは増加の傾向にあり、3次元データの認識や類似検索技術¹⁹⁾⁻²¹⁾の需要が高まっている。近年、3次元医療データを対象に、2次元画像解析で用いられてきたCo-Occurrence Matricesの3次元拡張²²⁾やRun-Length Encodingの3次元拡張²³⁾などの方法が提案されている。これらの方法では、直接3次元ボリュームデータから形状特徴を抽出するため、3次元データを連続する2次元画像へ変換してから特徴抽出を行う必要がない。また、手法の3次元拡張により、2次元画像から抽出した特徴よりも、精度の高いデータのセグメンテーションや分類を実現している。

これまでに提案されている高次局所自己相関特徴を応用した認識や検索の研究では、対象となるデータが主に2次元画像であり、3次元データから高次局所自

† 独立行政法人・メディア教育開発センター
National Institute of Multimedia Education

己相関特徴を抽出するためには、一度、3次元データを2次元画像化し画像特徴を抽出する必要があった。本研究では、3次元マスクパターンに基づく高次局所自己相関特徴(3×3×3)を利用することにより、3次元データから高次局所自己相関特徴を、直接、3次元ソリッドテクスチャから抽出する手法を提案する。また、抽出した高次局所自己相関特徴を用いてソリッドテクスチャデータベースの類似検索とソリッドテクスチャに含まれる特定のパターンの計測を行う。

2. 高次局所自己相関特徴

本章では(1)2次元の高次局所自己相関特徴マスクパターン(2)3次元の高次局所自己相関特徴マスクパターン(3)高次局所自己相関特徴の抽出について述べる。

2.1 2次元の高次局所自己相関特徴マスクパターン

自己相関関数は平行移動に関して不変であることが知られており、それを高次に拡張したものが高次自己相関関数である⁸⁾。 $f(r)$ を2次元画像、 r を参照位置の座標、 a を変位方向とすると、 n 次元の高次自己相関関数は式(1)で定義される。

$$x^n(a_1, a_2, a_3, \dots, a_{n-2}, a_{n-1}, a_n) = \int f(r)f(r+a_1)\cdots f(r+a_n)dr \quad (1)$$

高次自己相関関数は、次数と変位方向によって、その組合せは無数に考えられるが、変位方向を3×3の領域に限定、次数をただか2までとして、平行移動に関して等価なマスクパターンを取り除くと、その特徴は25マスクパターンとなる²⁷⁾。また、3×3のマスクの各セルをラベル付けすると、表1に示す文字列で表現することができる。

2次元画像から特徴を抽出するためには、マスクパターンの参照点を対象となる2次元画像の各位置に合わせ、マスクパターンの移動にあわせて、画像の濃淡値の積和をとることで計算できる。得られた特徴は画像内の対象物に対して平行移動不変であり、対象物に関して加法性がある。

2.2 3次元の高次局所自己相関特徴マスクパターン

前節に示した高次自己相関関数では、変位方向を3×3の領域に限定することで、2次元画像(2次元ピクセル)からの特徴抽出を可能にしていたが、3次元高次局所自己相関マスクでは、変位方向を3×3×3の3次元領域へ拡張^{15),16)}しており、3次元データ(3次元ボクセル)からの特徴抽出を行うことができる。2次元マスクパターンの場合は、対象となる領域が3×3と限定されていたため、平行移動に関して等価な特徴

表1 高次局所自己相関特徴の2次元マスクパターン(文字列表現)
Table 1 2D mask patterns for higher order local autocorrelation features (string sequence expression).

$n=0$ (1)	e							
$n=1$ (4)	ef	ec	eb	ea				
$n=2$ (20)	def	ceg	beh	qei	cde	beg	qeh	dei
	efg	ceh	bei	aef	bde	aeg	deh	egi
	efh	cei	bef	ace				

a	b	c
d	e	f
g	h	i

(3×3)

の数は少なかったが、変位方向を3×3×3の3次元領域へ拡張すると、その数は膨大な数になる。表2はシミュレーションプログラムによって得られたマスクパターンを文字列表現したものである。

表3には3次元マスクパターンの次数と平行移動に関して等価なパターンの数を示した。たとえば、3次元マスクの中央にあるセル(表2のラベル n)は、平行移動等価なパターンが27種類ある。3次元マスクパターンの数は、高次局所自己相関関数の次元が0のときは1個、次元1のときは13個、次元2のときは237個となり、その合計は251個である(図7)。これは2次元マスクパターンの約10倍程度で、あまり大きな数ではない。したがって、一般に計算量が膨大となる3次元データの特徴を大幅に圧縮・要約することができ、高速な形状特徴比較が期待できる。表3は自己相関関数の次元に対応した同値となるマスクの個数を示している。

2.3 高次局所自己相関特徴の抽出

高次局所自己相関特徴は、3×3×3のマスクに基づいて計算を行う。マスクの中心が参照点となる。ボクセル間の距離を参照点の3×3×3の局所的な領域内に限定し、表2に示される251個の局所的なマスクパターンについて局所自己相関関数を計算する。3次元のボクセルデータに対して、ボクセルの各位置に251個のマスクの参照点をあわせ、マスクパターンが有効となっている箇所とボクセルデータの濃淡値を掛け合わせる。マスクを移動させるたびに、得られた値を足していく積和計算によって特徴値を算出できる。

3. ソリッドテクスチャの解析

本章では(1)3次元ソリッドテクスチャ(2)3次元ソリッドテクスチャの類似検索(3)3次元ソリッドテクスチャのパターン認識について述べる。

表 2 高次局所自己相関特徴の 3 次元マスクパターン (文字列表現)
Table 2 3D mask patterns for higher order local autocorrelation features (string sequence expression).

n=0 (1)	n					
n=1 (13)	mn	kn	jn	en	dn	bn
	an	ln	fn	cn	hn	gn
	in					
n=2 (237)	mno	kln	jkn	mnr	efn	den
	mnx	bcn	abn	mnA	jmn	knq
	knr	ehn	dgn	ben	adn	knz
	knA	jln	jno	jnp	jnq	jnr
	ein	dhn	jnu	bfm	aen	jnx
	jny	jnz	jnA	dmm	bkn	ajn
	enw	enx	enz	enA	dfn	din
	dno	bln	akn	dnr	dny	dnw
	dnx	dny	dnz	dnA	bhn	bin
	amn	bnq	bnr	bnt	bnu	bnw
	bnx	bnz	bnA	acn	afn	agn
	ahn	ain	aln	ano	anp	anq
	anr	ans	ant	anu	anv	anw
	anx	any	anz	anA	kmm	lnq
	lnr	fhm	egm	cen	bdn	lnz
	lnA	knp	fm	cfm	kny	emn
	ckn	bjn	fmw	fmz	fnA	
	cln	env	eny	chn	cin	bm
	cnq	cnr	cnt	cnu	cnw	cnx
	cnz	cnA	bgn	bnp	bns	bnv
	bnv	nop	nov	noy	lmn	lnp
	lns	lnv	lny	fgn	fmn	fnp
	fnv	fny	cdn	cgm	cjn	cmn
	cnp	cns	cnv	cny	npr	npz
	npA	hin	ghm	mnu	gmm	ekn
	djn	hnw	hnz	hnA	gin	
	gno	eln	dkn	gnr	gnv	gnw
	gnx	gny	gnz	gnA	ent	enu
	dln	dns	dnt	dnu	hmn	fkn
	ejn	inw	inx	inz	inA	fln
	hnv	hny	fmt	fnu	ens	nrz
	nry	nos	imm	inp	inv	iny
	fjn	fns	nqt	nqu	nps	npt
	npu	hkn	hln	hnt	hnu	gjn
	gkn	gln	gns	gnt	gnu	nrt
	nru	nqs	ikn	ilm	int	inu
	hjn	hns	nrs	ijn	ins	nvx
	nvA	ntz	ntA	nsu	nsx	nsy
	nsz	nsA	nuz	nuA	nty	nxy
	nuv	nuy	nyA			

a	b	c	j	k	l	s	t	u
d	e	f	m	n	o	v	w	x
g	h	i	p	q	r	y	z	A

(3 × 3 × 3)

3.1 3次元ソリッドテクスチャ

3次元マスクパターンに基づく高次局所自己相関特徴の有効性を検証するため、3次元ソリッドテクスチャを対象に類似検索とパターン計測の実験を行った。3次元ソリッドテクスチャは、2次元画像テクスチャと異なり、テクスチャパターンが3次元空間で定義され

表 3 高次局所自己相関特徴の 3 次元マスクパターン数
Table 3 Number of 3D mask patterns for higher local autocorrelation.

	n=0	n=1	n=2
1	NA	NA	4
2	NA	NA	36
3	NA	NA	6
4	NA	NA	108
6	NA	NA	36
8	NA	4	32
9	NA	NA	3
12	NA	6	12
18	NA	3	NA
27	1	NA	NA
Total	1	13	237



図 1 3次元ソリッドテクスチャの例
Fig.1 3D solid textures.

る。したがって、図 1 のように、任意の部位を切り取っても模様が連続的であり、コンピュータグラフィックスで自然な画像を生成するために利用されている。


3次元ソリッドテクスチャの生成には3次元空間で定義される関数を用いることで、乱数の揺らぎを応用して、大理石、木目、波などの模様を作り出すことができる²⁵⁾。本研究では、3次元ソリッドテクスチャのデータを作成するため、代表的なノイズ関数として知られる Perlin ノイズ関数²⁴⁾を利用した。Perlin ノイズ関数は、式 (3) で表すことができる。この関数は自己相似性があり関数を半分にしたものを足し合わせてランダムなノイズを生成する。

$$F_{noise}(f) = \sum_{i=0}^k \frac{Noise(2^i f)}{2^i} \quad (2)$$

実験では図 2 に示す 4 種類のソリッドテクスチャを Perlin ノイズ関数のパラメータを変化させることで、それぞれ 500 個生成した。生成した各ソリッドテクスチャの解像度は 128×128×128 であり、ソリッドテクスチャはモノクロームで濃淡値は 0 から 255 の値をとるようにした。なお、図は 128×128×128 のソリッドテクスチャの一部をスライスし、128×128 の 2次元画像にしたものである。

3.2 3次元ソリッドテクスチャの類似検索

高次局所自己相関特徴を用いた 2次元画像の認識では、画像の解像度を変化させることで認識率が向上し、



Marble Wood Cloud Turbulence
 図 2 Perlin ノイズ関数によるソリッドテクスチャ (スライスされた 2 次元画像)
 Fig. 2 Solid textures based on Perlin's noise functions (Sliced 2D images).

複数の解像度の画像から特徴を統合¹¹⁾すると良い認識結果が得られる場合がある。そこで、生成した各ソリッドテクスチャに対して、複数の解像度を用意した。複数の解像度のソリッドテクスチャの生成には、ソリッドテクスチャを重ねりのない小領域に分割し、各小領域をその濃淡値の平均で置き換える操作を繰り返した。実験では、128×128×128, 64×64×64, 32×32×32, 16×16×16, 8×8×8 の解像度を用意した。そして、解像度の異なる各ソリッドテクスチャから 3次元マスクを用いて高次局所自己相関特徴を抽出し、各ソリッドテクスチャから得られた 251 個の特徴を多次元空間に広がる点としてとらえ、各点のユークリッド距離を比較した。検索キーと他のデータを比較し、距離の差が小さいものを類似しているとシステムが判断する。

実験では、生成した 2,000 個 (4 種類のソリッドテクスチャ × 500 個のデータ) のデータが、高次局所自己相関特徴によって検索・分類できるか適合率と再現率を調べた。適合率の計算には式 (4)、再現率の計算には式 (3) を用いた。ただし、 q はデータベースへの検索で、上位 k 個を検索解としたとき、 D_q は検索 q に対して適合しているデータとする。 n 個のデータがデータベース中にあるとき、検索データは $(d_0, d_1, d_2, \dots, d_{n-3}, d_{n-2}, d_{n-1})$ のようにソーティングできる。このとき、 d_i が検索 q に対して正解であるとき R_i は 1、不正解であるとき R_i は 0 として計算を行う。

$$Recall(k) = \frac{1}{D_q} \sum_{i=0}^k R_i \quad (3)$$

$$Precision(k) = \frac{1}{k} \sum_{i=0}^k R_i \quad (4)$$

適合率・再現率の計算では、ランダムにデータベースから検索キーとなるソリッドテクスチャを 30 回選択し、検索キーに対して類似検索を行った。そして、検索キーとなるソリッドテクスチャの種類と検索システム検索結果のソリッドテクスチャの種類が一致した

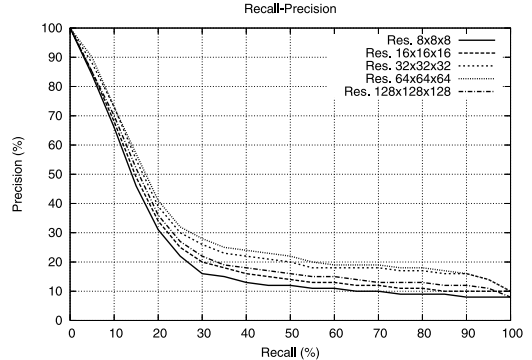


図 3 類似検索の解像度の違いによる比較 (適合率・再現率)
 Fig. 3 Comparisons of similarity retrieval results with different resolutions (Recall-Precision graphs).

場合に正解として計算を行った。図 3 は類似検索の解像度による適合率・再現率の比較である。図 3 のグラフに示されるように、32×32×32 や 16×16×16 の解像度で形状特徴を計算した方が、粗い解像度 8×8×8 や高精細な解像度 64×64×64 や 128×128×128 よりも高い適合率・再現率となった。これは、高次局所自己相関特徴が局所的な特徴であり、解像度が細かすぎると極端に局所的な特徴しか抽出できず、また、解像度が粗すぎても抽出できる特徴が限定されてしまうためであると考えられる。多くの高次局所自己相関特徴を利用した 2 次元画像検索の研究でもこれと同様に、非常に高い解像度が類似度を判別するのに最適とは限らない結果となっている。図 4 は類似検索の結果の例である。図では 3 次元ソリッドテクスチャの一部をスライスし、2 次元画像にしている。アルファベットはソリッドテクスチャの種類 (M) Marble (W) Wood, (C) Cloud (T) Turbulence を示している。

構築した実験検索システム環境 (Linux Kernel 2.6.0, Pentium4-3.2 GHz, 1,024 MB main memory) で 2,000 個の各データから 251 個の高次局所自己相関特徴に基づく形状特徴を抽出した。そして、データベース中のデータと検索キーの形状特徴を比較し、類似度距離を求め、Quick ソート³⁰⁾を行った。表 4 に形状特徴抽出、形状特徴比較、類似度距離のソートに必要であった時間を示す。検索の前処理となる形状特徴の抽出では、128×128×128 のような高精細な解像度の場合、膨大な計算時間を必要とする。しかし、高次局所自己相関特徴を各データから抽出後、索引として保存しておけば、検索システムは形状特徴を比較するだけでよく、高速な検索が可能である。表に示すように、データの解像度にかかわらず 251 個の高次局所自己相関特徴が抽出されるため、形状特徴比較と類似




図 4 類似検索の結果の例
Fig. 4 Examples of similarity retrievals.

表 4 検索に必要な時間
Table 4 Time required for retrieving data.

	8^3	16^3	32^3	64^3	128^3
Feature Extraction (Hours)	1.06	7.32	36.35	130.98	210.98
Feature Comparison (Seconds)	1.01	1.01	1.02	1.00	1.01
Quick Sort (Seconds)	0.56	0.57	0.56	0.56	0.56

度距離に必要な時間は一定となる。また、各データの形状特徴が 251 個と大幅に要約されるため、システムが必要とする検索時間は約 1 秒から 2 秒程度と高速である。

3.3 3次元ソリッドテクスチャのパターン認識

高次局所自己相関の 3 次元マスクパターンを用いて、3 次元ボクセル内に含まれる大小 2 種類の粒子を計測する問題の実験を行った。これは文献 1) の“2 次元画像から 2 種類の直径の異なる粒子の個数を同時に計測する問題”を 3 次元ボクセルデータの計測へ応用したものである。図 5 は実験に用いた入力ボクセルデータの例である。

実験では、図 5 と同様のソリッドテクスチャを 500 個、粒子パターン学習用のデータとして生成した。大小の球の内部は Marble のソリッドテクスチャ、球の外部 ($64 \times 64 \times 64$) は Turbulence のソリッドテクス




図 5 粒子数の計測
Fig. 5 Pattern counting of spheres.

Solid textures	Sample 1	Sample 2	Sample 3
Num of large spheres	4	3	4
Predicted number of large spheres	4.012	2.998	4.134
Number of small spheres	1	3	4
Predicted number of small spheres	0.912	3.398	3.908

図 6 粒子数の計測例
Fig. 6 Examples for counting sphere particles

チャで埋めた。大小の球は乱数により 1~10 個生成し、球の中心位置も乱数によって決定した。ただし、各球は接触・包含しないように中心位置を決定した。そして、粒子パターン学習用のソリッドテクスチャから解像度 $32 \times 32 \times 32$ の高次局所自己相関特徴を計算し、これを説明変数、大小の球のそれぞれの個数を目的変数として重回帰分析を行った。重回帰分析によって得られる重回帰式によって、ソリッドテクスチャに含まれている大小の球の個数を推測することができる。粒子パターン学習用データと同様のソリッドテクスチャを 50 個生成し、重回帰式で球の数を推定したところ、正答率の平均値は、大きい球で 92%、小さい球は 89%であった。図 6 は粒子数の推定結果の例である。重回帰式から推定された値は浮動小数値であり、これを整数値に変換したものが大小の粒子数となる。

表 5 決定係数 R^2 と自由度調整済み決定係数 $Adj.R^2$
Table 5 R^2 and $Adj.R^2$.

Radius L	Radius S	R^2	$Adj.R^2$
10.0	5.0	0.936	0.936
9.0	5.0	0.946	0.893
8.0	5.0	0.831	0.827
7.0	5.0	0.748	0.746
6.0	5.0	0.650	0.632
5.0	5.0	0.559	0.554
4.0	5.0	0.506	0.501
3.0	5.0	0.555	0.554
2.0	5.0	0.656	0.652
1.0	5.0	0.753	0.749

学習用データ 500 個からの高次局所自己相関特徴の抽出には約 8.89 時間 (解像度 $32 \times 32 \times 32$), 重回帰式の構成には約 35 秒かかった。実験データからの高次局所自己相関特徴 (解像度 $32 \times 32 \times 32$) 抽出は 1 データあたり平均で 61 秒かかった。高次局所自己相関特徴の値を重回帰式へ代入し, 大小の球の数を推測する計算に必要な時間は平均で 0.2 秒であった。

表 5 は大小の球の半径を変化させたときに得られた重回帰分析の決定係数 R^2 と自由度調整済み決定係数 $Adj.R^2$ の値である。自由度調整済み決定係数 $Adj.R^2$ の値は重回帰式のデータに対する適合度の指標となる数値である。1 つの球の半径は固定, もう一方の球の半径を 1 から 10 まで変化させた。大小の球を同時に計測しているので, 大小の球のサイズがまったく同じとき以外は自由度調整済み決定係数 $Adj.R^2$ の値は重回帰式で球の個数を推定するのに有効な値となっている。2 つの球の半径の差が大きいくほど, 重回帰式の適合度が高くなっており, 大小の球数判別の正答率も高かった。高次局所自己相関特徴を利用した計測では, 個々の対象となる粒子の特定パターンの切り分け計算をするのではなく, 高次局所自己相関特徴の加法性を応用した和算・積算に基づく計算を行っており高速な計測が可能である。

4. おわりに

本研究では 3 次元高次局所自己相関特徴のマスク ($3 \times 3 \times 3$) をもちいて 3 次元ソリッドテクスチャから形状特徴の抽出を行った。3 次元ソリッドテクスチャのデータ量は多いが, 高次局所自己相関特徴を用いることで, その特徴は比較的コンパクトに要約することができた。そして, 得られた特徴を, ソリッドテクスチャのデータベース検索に应用することで高次局所自己相関特徴を利用した類似検索が可能であること示した。また, 高次局所自己相関特徴と重回帰分析を組み合わせると, ソリッドテクスチャ内に含まれる特定のバ

ターンを学習させ, 高次局所自己相関特徴の加法性を利用して, パターンの計測ができることを示した。一般的に 3 次元データの処理には時間がかかるが, 高次局所自己相関特徴の計算は並列計算性が高く, また特徴圧縮・要約にすぐれているので, 様々な 3 次元データの認識・解析に対して有効な特徴になると考えられる。

謝辞 論文の改訂にあたり貴重なコメントをいただいた査読者の方々に感謝いたします。

参 考 文 献

- 1) 大津展之, 栗田多喜夫, 関田 徹: パターン認識 (理論と応用), 朝倉書店 (1996).
- 2) 長谷川修, 坂上勝彦, 速水 悟: 実世界視覚情報を対話的に学習・管理する人間型ソフトウェアロボット, 信学論 (D-II), Vol. J82-D-II, No.10, pp.1666-1674 (1999).
- 3) 豊田崇弘, 長谷川修: 高次局所自己相関特徴の拡張, 画像電子学会誌, Vol.34, No.4, pp.390-397 (2005).
- 4) Toyoda, T. and Hasegawa, O.: Proposal of Extended HLAC and Its Application to Texture Analysis, *11th Korea-Japan Joint Workshop on Frontiers of Computer Vision*, pp.7-12 (2005).
- 5) Kurita, T. and Hayamizu, S.: Gesture Recognition Using higher order local autocorrelation features of PARCOR, *IEICE Trans. Info. and Syst.*, Vol.E86-D, No.4, pp.719-726 (2003).
- 6) Goudail, F., Lange, E., Iwamoto, T., Kyuma, K. and Otsu, N.: Face Recognition System using Local Autocorrelations and Multi-scale Integration, *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol.18, No.10, pp.1024-1028 (1996).
- 7) Popvici, V. and Thiran, J.P.: Higher Order Autocorrelations for Pattern Classification, *Proc. International Conference on Image Processing* (2001).
- 8) MacLaughlin, J.A. and Raviv, J.: Nth-Order Autocorrelations in Pattern Recognition, *Information and Control*, Vol.12, pp.121-142 (1968).
- 9) 加藤俊一, 下垣弘行, 藤村是明: 画像対話型商標・意匠データベース TRADEMARK, 信学論 (D-II), Vol. J72-D-II, No.4, pp.535-544 (1989).
- 10) 栗田多喜夫, 加藤俊一, 福田郁美, 坂倉あゆみ: 印象語による絵画データベースの検索, 情報処理学会論文誌, Vol.33, No.11, pp.1373-1383 (1992).
- 11) Kurita, T., Otsu, N. and Sato, T.: A face recognition method using higher order local autocorrelation and multivariate analysis, *Proc. 11th IAPR International Conference on Pattern Recognition*, pp.213-216 (1992).

- 12) Kobayashi, Y. and Kato, T.: The Stir System: Subjective Texture Image Retrieval System, *Proc. 2001 IEEE International Conference on Multimedia and Expo*, p.272 (Aug. 2001).
- 13) Suzuki, M.T., Yaginuma, Y. and Osawa, N.: A Similarity Evaluation Method for 3D Models by Using HLAC Mask Patterns, *The World Scientific Engineering Academy and Society Transaction on Computers*, Issue 3, Vol.3, pp.713-718 (Feb. 2004).
- 14) Suzuki, M.T., Yaginuma, Y., Osawa, N. and Sugimoto, Y.Y.: Classification of 3D Solid Textures Using 3D Mask Patterns, *Proc. IEEE International Conference on Systems, Man and Cybernetics (SMC2004)*, pp.6342-6347 (Oct. 2004).
- 15) Kobayashi, T. and Otsu, N.: Action and Simultaneous Multiple Persons Identification Using Cubic Higher-order Local Autocorrelation, *Proc. ICPR*, Vol.4, pp.741-744 (Aug. 2004).
- 16) 小林 匠, 大津展之: 立体高次局所自己相関特徴を用いた行動・個人認識, 電子情報通信学会全国大会論文集, D12-124 (Mar. 2004).
- 17) 南里卓也, 大津展之: 複数人動画像からの異常動作検出, 信学会技報, PRMU2004, Vol.104, No.291, pp.9-16 (2004).
- 18) 柴田滝也, 加藤俊一: 街路の景観画像データベースのイメージ語による検索, 信学論 (D-I), Vol.J82, No.1, pp.174-183 (1999).
- 19) Funkhouser, T., Min, P., Kazhdan, M., Chen, J., Halderman, A., Dobkin, D. and Jacobs, D.: A Search Engine for 3D Models, *ACM Trans. Graphics*, Vol.22, No.1, pp.83-105 (2003).
- 20) Ohbuchi, R., Minamitani, T. and Takei, T.: Shape-similarity search of 3D models by using enhanced shape functions, *International Journal of Computer Applications in Technology*, Vol.23, No.3/4/5, pp.70-85 (2005).
- 21) 鈴木一史, 加藤俊一, 大津展之: 同値類に基づく回転不変特徴量を用いた 3 次元物体モデルの類似検索, 信学論 (D-II), Vol.J86-D-II, No.8, pp.1234-1243 (2003).
- 22) Kurani, A., Xu, D.H., Furst, J.D. and Raicu, D.S.: Co-occurrence matrices for volumetric data, *The 7th IASTED International Conference on Computer Graphics and Imaging, CGIM 2004, USA* (2004).
- 23) Xu, D.H., Kurani, A., Furst, J.D. and Raicu, D.S.: Run-length encoding for volumetric texture, *The 4th IASTED International Conference on Visualization, Imaging and Image Processing, VIIP 2004*, 452-131, Marbella (2004).
- 24) Perlin, K.: An image synthesizer, *Computer Graphics (Proc. SIGGRAPH 1985)*, Vol.19, pp.287-296 (1985).
- 25) Ebert, D.S., Musgrave, F.K., Peachey, D., Perlin, K. and Worley, S.: *Texturing and Modeling, A Procedural Approach*, ISBN 0-12-228760-6, Academic Press (1994).
- 26) Fu, K.S. and Lu, S.Y.: Computer generation of texture using a syntactic approach, *Computer Graphics (Proc. SIGGRAPH 1978)*, Vol.12, pp.147-152 (1978).
- 27) Otsu, N. and Kurita, T.: A new scheme for practical flexible and intelligent vision systems, *Proc. IAPR Workshop on Computer Vision*, Tokyo, pp.431-4352 (1998).
- 28) Hotta, K. Kurita, T. and Mishima, T.: Scale Invariant Face Detection Method using Higher-Order Local Autocorrelation Features extracted from Log-Polar Image, 3rd IEEE International Conference on Automatic Face and Gesture Recognition, pp.70-75 (1998).
- 29) 栗田多喜夫, 堀田一弘, 三島健稔: 画像の高次局所自己相関特徴を用いた大きさに不変な顔画像の認識, 信学論 (D-II), Vol.J80-D-II, No.8, pp.2209-2217 (1997).
- 30) Smith, H.F.: *Data structures (Form and Function)*, Harcourt Brace Jovanovich Publishers (1987).




図 7 3次元高次局所自己相関特徴のマスクパターン
 Fig. 7 Mask patterns for 3D higher order local autocorrelations.

付 録

A.1 3次元高次局所自己相関特徴のマスクパターン
 図 7 に, 3次元高次局所自己相関特徴のマスクパターンを示す.

(平成 18 年 6 月 1 日受付)
 (平成 18 年 12 月 7 日採録)



鈴木 一史 (正会員)

1994 年米国ユタ州立大学コンピュータサイエンス学部卒業 (BS). 1997 年筑波大学大学院理工学研究科修士課程修了. 2000 筑波大学連携大学院 (電子技術総合研究所) 工学研究科博士課程修了 (工学博士). 2000 年文部科学省大学共同利用機関・メディア教育開発センター研究開発部助手. 2004 年独立行政法人・メディア教育開発センター研究開発部助手. 2005 年同センター助教授. 画像電子学会, 電子情報通信学会, ACM, IEEE 各会員.