

## 類似する画像領域の特徴解析と視覚感性のモデル化

多田 昌裕<sup>†a)</sup> 加藤 俊一<sup>††b)</sup>

Visual KANSEI Modeling based on Focal Area Analysis and Hierarchical Classification

Masahiro TADA<sup>†a)</sup> and Toshikazu KATO<sup>††b)</sup>

**あらまし** 本論文ではユーザ毎に異なる視覚感性のモデル化手法について論じる。我々は視覚感性を個人間の差異があまりない生理的レベルの感性と、各人の知識、経験によって個人差が生ずる心理的レベルの感性の2つのレベルに分けて考えている。本論文では生理的レベルの感性のモデル化手法として、視覚の知覚過程における特徴抽出機構を模した画像特徴量を定義し、画像から抽出した。また、人間の直感的な画像の分類過程を模したデータベースの階層的分類と MDL を用いた構図推定及び判別分析を組み合わせた心理的レベルの感性のモデル化手法を提案し、生理的レベルの視覚感性のモデル化手法と併せて類似画像検索システムに応用した。

**キーワード** 視覚感性, 類似画像検索, 注目領域抽出, MDL, 情報量基準

### 1. ま え が き

多種多様な画像を含むデータベースから、ユーザが提示した画像と特徴が類似したものを検索するためには、人間が感じる各画像の特徴を数量化し、機械にもその特徴を理解できるようにモデル化しなければならない。視覚感性をモデル化するためには、目が刺激を受けてから、その刺激を解析し対象を認識するまでのプロセス（視覚の知覚過程）を何らかの形で機械的に再現できるようにする必要がある。

我々は視覚感性を個人間の差異があまりない生理的レベルの感性と、各人の知識、経験によって個人差が生ずる心理的レベルの感性の2つのレベルに分けて考えている [1]。本研究では、各レベルの視覚感性をモデル化する手法を提案し、実験によりそのモデルの有効性を評価する。

### 2. 感性のモデル化

#### 2.1 生理的レベルの感性

視覚の知覚過程には、網膜に映る映像から、局所的、全域的な明暗や色彩の特徴を抽出する神経回路が存在することが知られている [2]。我々は視覚の知覚過程における特徴抽出機構を生理的レベルの感性（Objective Level KANSEI）と考えている [1]。

視覚の知覚過程の初期段階（初期視覚系）では、外界の視覚情報から局所的な明暗や色彩の対比など種々の特徴を抽出しているといわれている [2]。また、より高次の視覚の知覚過程では、初期視覚系で抽出された局所的な特徴を取りまとめ、より大局的なパターンの特徴が検出されると考えられている。

本研究では、局所的な明暗や色彩の対比の抽出機構を模して近傍画素間における3点間コントラストを定義した。この3点間コントラストに側抑制の考えを導入し、初期視覚系における特徴抽出機構をモデル化した。我々は3点間コントラストをベースとした局所的な特徴量を統合してより大局にわたる特徴量とする際（より高次の視覚の知覚過程）にも側抑制の考えを導入し、生理的レベルの感性をモデル化した。

#### 2.2 心理的レベルの感性

人間は同一の目の構造を持ち、視覚の知覚過程における特徴抽出機構の働きも同様であるにもかかわらず、

<sup>†</sup> 中央大学大学院理工学研究科 〒112-8551 東京都文京区春日 1-13-27

Graduate School of Science and Engineering, Chuo University Kasuga 1-13-27, Bunkyo-ku, Tokyo, 112-8551 Japan

<sup>††</sup> 中央大学理工学部 〒112-8551 東京都文京区春日 1-13-27

Faculty of Science and Engineering, Chuo University Kasuga 1-13-27, Bunkyo-ku, Tokyo, 112-8551 Japan

a) E-mail: m.tada@indsys.chuo-u.ac.jp

b) E-mail: kato@indsys.chuo-u.ac.jp

主観的な画像の類似度判断基準は各人各様である。これは、各ユーザの経験、知識によって画像中の注目領域や、重視する特徴が異なるからだと考えられる。

我々は特徴抽出機構により抽出された多数の特徴を統合、取捨選択し対象を分類・認識する過程を心理的レベルの感性 (Subjective Level KANSEI) と考えている [1]。心理的レベルの感性をモデル化するためには、ユーザが示す主観的な判断事例を通して特徴パラメータへの重み付けを推定する必要がある。本研究では、データベースの階層分類とクラスタリング手法及び判別分析を組み合わせた心理的レベルの視覚感性モデル化手法を提案する。

### 3. 生理的レベルの感性のモデル化手法

生理的レベルの感性をモデル化するためには、対象の特徴を数量化し多次元ベクトルとして表現する画像特徴量 (Graphical Features: GF) を設計して、特徴抽出機構の働きをシミュレートする必要がある。

カラーヒストグラムは画像全域にわたる色彩の分布をヒストグラム化したものであり、全域的な特徴を表現できるため、画像検索などでよく利用される [3]。しかし、局所的な明暗や色彩の特徴を欠いているため、人間とは異なった類似度の評価をする場合も多い (図 1)。したがって、視覚の知覚過程をシミュレートする



These two images have similar color histogram.

図 1 カラーヒストグラムの類似した画像例  
Fig. 1 Images of Similar Color Histograms

ためには、画像から全域的な色彩の分布情報だけではなく、近傍画素間の局所的な関係を表現する局所の特徴量も同様に設計・抽出する必要がある。

局所の特徴量としては、自己相関関数を高次に拡張した高次自己相関特徴がよく知られている [4]~[6]。しかし、高次自己相関特徴は輝度値の積に着目した特徴量であるため、ダイナミックレンジが広く、またノイズや画像撮影時の環境光の影響を受けやすい。

画像中のノイズや撮影時の環境光の違いによって画

像特徴量の値が大きく変動するようでは、様々な画質の画像を含んだ画像検索に利用することは難しい。そのため、画像特徴量はノイズや環境光の変化に強い設計であることが望ましい。

#### 3.1 3点間コントラスト

外界景色では周囲の照度レベルが変化しても、背景と対象のコントラストは変化しないことが知られている [7]。また、視覚の知覚過程の初期段階 (初期視覚系) では、外界の視覚情報から局所的な明暗や色彩の対比などを抽出しているといわれている [2]。そこで本研究では背景と対象の局所コントラストに着目し、局所的な明暗や色彩の対比の抽出機構の数理モデルとして 3点間コントラストを次式で定義した。

$$\text{Cont}^{(i)}(\mathbf{a}_1^{(i)}, \mathbf{a}_2^{(i)}, \mathbf{r}) = \frac{\{f(\mathbf{r} + \mathbf{a}_1^{(i)}) - f(\mathbf{r})\} + \{f(\mathbf{r} + \mathbf{a}_2^{(i)}) - f(\mathbf{r})\}}{|f(\mathbf{r} + \mathbf{a}_1^{(i)})| + |f(\mathbf{r} + \mathbf{a}_2^{(i)})| + 2|f(\mathbf{r})|}. \quad (1)$$

ここで、 $\mathbf{r}$ ,  $(\mathbf{a}_1^{(i)}, \mathbf{a}_2^{(i)})$ ,  $f(\mathbf{r})$  はそれぞれ参照点、変位、参照点  $\mathbf{r}$  の色彩であり、(1) 式の分母は視神経への刺激の強度、分子は刺激の差分である。3点間コントラストは刺激強度で正規化している為、刺激強度に対してスケール不変であり、またノイズに強いという特性をもつ。

画像平面  $P$  上の参照点  $\mathbf{r}$  と参照点周りの  $N$  個の変位  $(\mathbf{a}_1, \dots, \mathbf{a}_N \in R^2)$  との関係を測定する方法は無数にあるが、画像データでは一般に近接画素間の関係の方が重要であると考えられる。したがって本研究では局所の特徴量の測定範囲を参照点  $\mathbf{r}$  周りの局所的な  $3 \times 3$  画素の領域に限定する。また、変位を  $N=2$  ( $\mathbf{a}_1, \mathbf{a}_2 \in R^2$ ) とすることで画像の直線的な変化の方向性だけでなく曲線の変化にも対応できるようにした。図 2 に本研究で採用したコントラストを測定するパターン (全 28 種) を示す。図中の “+” は参照点  $\mathbf{r}$ , “\*” は変位  $\mathbf{a}_1^{(i)}, \mathbf{a}_2^{(i)} \in R^2$  ( $i = 1, \dots, 28$ ) を示す。

ところで、視覚の知覚過程には、ある点が刺激を受けて興奮作用を起こすと、その周辺の点が逆に抑制作用を起こす機構 (側抑制と呼ぶ) があることが知られている [2]。側抑制は様々な明るさの背景の下で、注目点の近傍のコントラストを局所並列的に強調するメカニズムであると考えられる。また、興奮点が  $n$  個ある場合には、各抑制効果の加算性が成り立つことが示されている。我々はこの側抑制の仕組みを画像特徴量に導入することを考え、(2) 式および (3) 式を定義した。




図 2 3 点間コントラストを測定するパターン  
Fig.2 Local Mask Patterns of Graphical Features

$$\gamma(i, \mathbf{r}) = \frac{\text{Cont}^{(i)}(\mathbf{a}_1^{(i)}, \mathbf{a}_2^{(i)}, \mathbf{r})}{\sum_{i=1}^{n(I)} |\text{Cont}^{(i)}(\mathbf{a}_1^{(i)}, \mathbf{a}_2^{(i)}, \mathbf{r})|}. \quad (2)$$

$$\gamma'(i, l, \mathbf{r}) = \delta_{i,l,r} \gamma(i, \mathbf{r}), \quad (3)$$

$$\delta_{i,l,r} = \begin{cases} 1 & \text{if } \gamma(i, \mathbf{r}) \in \lambda_l \\ 0 & \text{otherwise} \end{cases} \quad (4)$$

ここで、 $n(I)$  は参照点  $\mathbf{r} \in P$  で計測される 3 点間コントラスト  $\text{Cont}^{(i)}(\mathbf{a}_1^{(i)}, \mathbf{a}_2^{(i)}, \mathbf{r})$  のパターン数 (本研究では 28 種) である。ある  $\text{Cont}^{(i)}(\mathbf{a}_1^{(i)}, \mathbf{a}_2^{(i)}, \mathbf{r})$  の値が大きくても、参照点  $\mathbf{r}$  周りで大きな値をとる 3 点間コントラストのパターンが多ければ  $\gamma(i, \mathbf{r})$  の値は相対的に小さく、大きな値をとるパターンが少なれば相対的に大きくなる。また (3) 式は、 $\gamma(i, \mathbf{r})$  のうち、ある幅  $\lambda_l (l = 1, \dots, 3)$  の値をとるものだけに選択的に反応する。本研究では画像平面  $P$  上の局所領域 ( $3 \times 3$  画素) で定義される (3) 式を初期視覚系における特徴抽出機構の数理モデルとする。

側抑制の仕組みは知覚過程の様々な神経節にあることが分かっている [2] ため、初期視覚系において抽出された多数の特徴の取捨選択や強調にも有効なメカニズムだと考えられる。そこで、本研究では初期視覚系のモデル化 (局所領域からの特徴抽出) の際のみならず、より高次の視覚の知覚過程 (局所領域から抽出した特徴量を統合し、より大局的なパターンの特徴を検出) のモデル化の際にも側抑制の考えを導入することを考えた。我々はこの考えに基づき (5) 式を定義した。

$$g(i, l, P_k) = w_l \frac{\int_{P_k} \gamma'(i, l, \mathbf{r}) d\mathbf{r}}{\sum_{i=1}^{n(I)} \int_{P_k} |\gamma'(i, l, \mathbf{r})| d\mathbf{r}}. \quad (5)$$

ここで、 $P_k$  は画像平面  $P$  上の画像領域であり、 $\bigcup_{k=1}^K P_k = P$  である。(5) 式は、局所領域 ( $3 \times 3$  画素) で定義される (3) 式を取りまとめ、より広い領

域中でどの特徴が相対的に優勢であるかを表現する。また、(5) 式における重み  $w_l$  は、

$$w_l = \frac{\sum_{i=1}^{n(I)} \int_{P_k} \delta_{i,l,r} d\mathbf{r}}{\sum_{l=1}^L \sum_{i=1}^{n(I)} \int_{P_k} \delta_{i,l,r} d\mathbf{r}}, \quad (6)$$

で定義する。

本稿では、明暗と色の独立性を考慮して明度  $I$ 、及び色差  $R-G, Y-B$  を色空間の軸とする。色空間を構成する 3 軸上で  $g(i, l, P_k)$  を測定し、局所の特徴量とする。

また、画像平面  $P$  上の画像領域  $P_k$  における平均色と色の分散を測定し、全域の特徴量とする。この全域の特徴量と局所の特徴量を併せて生理的レベルの感性における特徴量ベクトル  $\mathbf{x}$  とする。

### 3.2 複数解像度からの画像特徴量の抽出

ユーザが画像の類似度判定の際に着目する特徴は対象によって異なる。また、同一画像上であっても、画像のある部位においてはオブジェクトの形状に着目し、別の部位においてはオブジェクトや背景のテクスチャに着目するということも少なくない。ユーザが同一画像上で異なる大きさのオブジェクトや背景に着目していた場合、何らかの方法を用いて特徴量を抽出するための解像度を一意に決めたととしても、単一解像度の画像から抽出した特徴量のみではユーザの視覚感性を十分に表現しえない可能性が高い。

そこで本研究では、複数の解像度からそれぞれ独立に画像特徴量を抽出し、解像度ごとにユーザの視覚感性を数理的にモデル化する。解像度ごとに独立に構築したモデルを組み合わせ、画像の部位に応じてモデルを使い分けることで、ユーザの視覚感性をより正確にモデル化しえると期待できる。

## 4. 心理的レベルの感性のモデル化手法

### 4.1 データベースの階層的分類

2.2 節で論じたように、心理的レベルの感性をモデル化するためには、教示されたユーザの主観的な類似度判断基準から、ユーザが注目する画像領域や画像の特徴を推定する必要がある。

本研究では、ユーザの主観的基準ののちで画像を段階的、階層的にグループ分けすることで教示を行う。この階層分類の結果には、ユーザが自らの経験や知識に基づいて画像中の様々な大きさのオブジェクトや背景に着目し、それらを総合的に評価することで下した画像の主観的な類似度評価が反映されていると考

えられる。そこで本研究では、画像の階層分類によって示されたユーザの主観的な類似度判断基準を複数解像度を用いて解析することで、ユーザが画像中のどのような大きさのオブジェクトや背景に着目して画像を分類したのかを推定し、ユーザの心理的レベルの感性をモデル化する。

ただ、主観的な類似度判断基準の教示のためにデータベース内の全ての画像を階層分類するとなると、ユーザに課せられる負担は相当なものとなる。そこで、本研究ではデータベースから無作為に抽出した教示用画像群を階層的に分類することで教示を行い、心理的レベルの感性の数理モデルを構築する。そして構築した数理モデルを階層的判別分析によりデータベース全体に適用することで、データベースを自動的に階層分類する。

本論文で提案する手法を採用する利点としては、次の3点が挙げられる。

(1) ユーザが画像類似度を判断する際に着目する特徴は対象となる画像によって異なり、一律な基準で表現することは困難であると考えられる。提案手法では、ユーザは自らの主観的判断に基づき、画像の分類をその類似度に応じて順次細分化していくため、各分類レベルにおけるユーザの判断基準をそれぞれ独立にモデル化することができる。これらのモデルを組み合わせることで、対象画像に応じて変化するユーザの判断基準に対応することができる。

(2) データベース全体を検索対象とせず、例示画像に最も類似した画像群を判定し、その画像群のみを検索対象とするため、計算量を低減することができる。

(3) 階層的な分類では教示用画像の全集合に対して一律の判断基準を与えるわけではなく、部分集合単位で判断基準を与えていく。そのため、ユーザの興味の変化に伴い、ある部分集合における判断基準の重要度が変化しても、該当する部分集合内でのみ分類の再教示を行うことで、モデルを修正再構築することができる。

以上の理由により、本研究ではデータベースの階層的な分類によるユーザの主観的な類似度判断基準の教示を採用する。

#### 4.2 心理的レベルの感性のモデル化概略

既存の内容型検索システムの多くは、画像特徴量の値の分布が画像平面全域にわたって同じであるという前提のもとに、画像平面全域から抽出した画像特徴量ベクトル集合に統計手法を適用して視覚の数理モデル

を構築している[3]。しかし、多くの画像は画像平面全域が同じ模様で構成されているわけではないため、画像部位によって画像特徴量の分布は異なる。また、ユーザが重視する画像特徴やその細かさも画像部位によって異なると考えられる。したがって、画像特徴量の値の分布が画像平面全域にわたって同じであるとの前提で構築された数理モデルでは、ユーザの主観的な類似度判断基準を十分に説明しえないと考えられる。

そこで本研究では、まず階層分類された画像群ごとに、画像平面中で画像特徴量の値の分布が同じであると考えられる領域(注目画像領域: Focal Area)を情報量基準を用いたクラスタリング手法により抽出する。そして、抽出された各群の注目画像領域ごとにユーザが重視する特徴を推定し、各ユーザの主観特徴空間(Subjective Feature Space)を生成する(図3の※A)。我々は画像特徴量の値の分布が各々異なる領域が集まって構図を形作っていると考える。本研究における注目領域の抽出は、構図の推定に相当すると考えられる。こうして得られた各群の注目画像領域及び各領域に対応する主観特徴空間を総称して注目領域モデル(Focal Area Model)と呼ぶ。

ところで、3.2節で論じたように、ユーザが同一画像上で異なる大きさのオブジェクトや背景に着目していた場合、単一解像度から抽出した画像特徴量のみでは、ユーザの視覚感性を十分にモデル化しえない可能性が高い。そこで、本研究では低解像度及び高解像度の画像特徴量集合からそれぞれ注目領域モデルを独立に構築し、ユーザが画像の類似度を判定する際に画像のどの領域のどの大きさ(解像度)のオブジェクトや背景に着目したのか(注目度: Relative Attention Factor)を推定する。推定した注目度を用いて複数の解像度から構築した注目領域モデルを統合し(図3の※B)、統合したモデルを用いて階層的に判別分析を行うことで、ユーザが対象画像を分類し認識する過程、すなわち心理的レベルの感性をシミュレートする(図3の※C)。

#### 4.3 注目画像領域の抽出

##### 4.3.1 本研究における注目画像領域抽出の目的

画像の領域分割は、一枚の画像から複数のオブジェクトを抽出する事を目的として、画像平面を局所特徴が類似したいくつかの領域に分割する手法である。領域分割手法としては、微細に分割された画像領域をクラスタリング手法を用いていくつかの領域に集約する手法が広く用いられている。

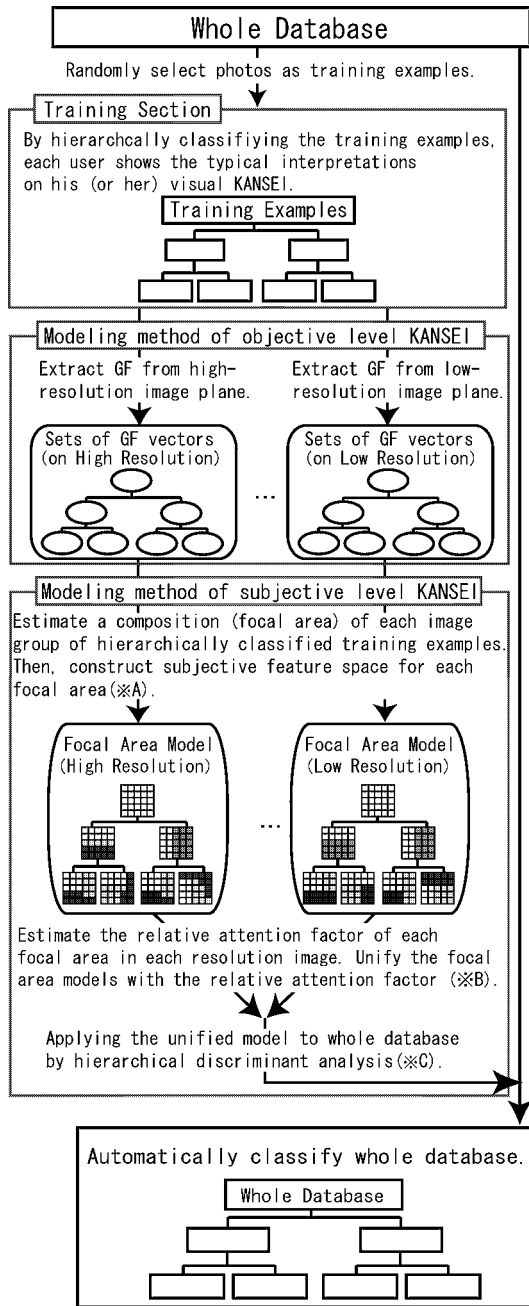


図3 感性の数理的モデル化の過程  
Fig.3 Modeling Method of Visual KANSEI

それに対し、本研究における注目画像領域抽出は、ユーザの主観によって類似していると判断された複数の画像に共通する類似画像領域（注目画像領域）を抽出し、ユーザが類似度判定の際に注目した構図を推定

することを目的とする。そのため、本研究では画像平面  $P$  を微細に区切らず、 $M \times M$  の粗いメッシュ状の画像領域  $P_k$  ( $k=1, \dots, M^2$ ) に区切り、初期クラスタとする。これらの初期クラスタに対し、各画像領域から抽出した画像特徴量ベクトル集合をクラスタ間の類似度判定の指標としてクラスタリング手法を適用し、各画像領域を順次統合してゆく。これにより、教示された画像群に属する各画像に共通する類似画像領域（注目画像領域）を抽出する。

#### 4.3.2 クラスタリング手法

本研究では分析対象データをそれぞれ別のクラスタと見なし、距離の近いクラスタを逐次統合することで最終的な分割結果を得る階層的クラスタリングを採用する。しかし、階層的クラスタリングではクラスタの統合をどの時点で終了するかは分析者の判断に委ねられるため、そのままの形で本研究に適用することは難しい。そこで本研究では、階層的クラスタリングのクラスタ統合基準として情報量基準の一種である MDL 基準を導入し、領域数を自動的に決定できるようにした。

#### 4.3.3 画像領域統合モデルの MDL

MDL 基準は Rissanen により、符号化における記述長最小化 (Minimal Description Length) 原理として導出されたものであり、モデルのパラメータの記述長とモデルを用いてデータを記述したときの記述長の和が最小になるモデルを最良とみなす [8]。

画像群  $C = \{c_1, \dots, c_N\}$  に属する画像  $c_i$  ( $i = 1, \dots, N$ ) の中のある領域  $P_k \subset P$  から抽出した画像特徴量ベクトルを  $\mathbf{x}_{i,k}$  ( $i = 1, \dots, N$ ) とし、 $\mathbf{x}_{i,k}$  の集合を  $X_k = \{\mathbf{x}_{i,k} \mid i = 1, \dots, N\}$  とする。ここで  $N$  は  $C$  に属する画像枚数である。いま、画像領域  $P_k$  及び  $P_l$  を統合し、画像特徴量ベクトルの集合  $X_{kl} = \{\mathbf{x}_{i,kl} \mid \mathbf{x}_{i,kl} \in X_k \cup X_l\}$  を生成することを考える。 $\mathbf{x}_{i,kl}$  にパラメータ  $\theta_{kl} = (\mu_{kl}, \Sigma_{kl})$  の  $n$  変量正規分布  $p(\mathbf{x}; \theta_{kl})$  を仮定すると、領域統合モデルの MDL は、

$$\begin{aligned} \text{MDL}_{(uni)} = & -\log L(\hat{\theta}_{kl}) + \frac{J_{(uni)}}{2} \log \frac{2N}{2\pi} \\ & + \log \int \sqrt{|I(\theta_{kl})|} d\theta_{kl}, \end{aligned} \quad (7)$$

で算出することができる。ここで、 $\hat{\theta}_{kl}$ ,  $J_{(uni)}$ ,  $I(\theta_{kl})$ ,  $|\cdot|$  はそれぞれ、 $\theta_{kl}$  の最尤推定量、領域統合モデルの自由度、Fisher 情報行列、行列式である。また、 $L(\cdot)$  はゆ度関数であり、 $L(\cdot) = \prod p(\cdot)$  である。

#### 4.3.4 画像領域分割モデルの MDL

一方、画像領域を統合しない場合、 $\mathbf{x}_{i,k} \in X_k$ ,  $\mathbf{x}_{i,l} \in X_l$  にパラメータ  $\theta = (\theta_k, \theta_l)$  を持つ確率分布

$$p(\mathbf{x}; \theta) = \frac{p(\mathbf{x}; \theta_k)^{\delta_k} p(\mathbf{x}; \theta_l)^{\delta_l}}{\int p(\mathbf{x}; \theta_k)^{\delta_k} p(\mathbf{x}; \theta_l)^{\delta_l} d\mathbf{x}}, \quad (8)$$

$$\delta_i = \begin{cases} 1 & \text{if } \mathbf{x} \in X_i \\ 0 & \text{otherwise} \end{cases}, \quad (9)$$

を仮定する。ここで、 $p(\mathbf{x}; \theta_k)$ ,  $p(\mathbf{x}; \theta_l)$  はそれぞれパラメータ  $\theta_k$ ,  $\theta_l$  を持つ  $n$  変量正規分布の確率密度関数である。

このとき、領域分割モデルの MDL は、

$$\text{MDL}_{(div)} = -\log L(\hat{\theta}) + \frac{J_{(div)}}{2} \log \frac{2N}{2\pi} + \log \int \sqrt{|I(\theta)|} d\theta, \quad (10)$$

で算出することができる。ここで、 $\hat{\theta} = (\hat{\theta}_k, \hat{\theta}_l)$  は  $\theta = (\theta_k, \theta_l)$  の最ゆう推定量、領域分割モデルのパラメータの自由度  $J_{(div)} = 2J_{(uni)}$  である。

#### 4.3.5 注目画像領域抽出アルゴリズム

画像群  $C$  から注目画像領域を抽出する手順は以下のとおりである。

(1) 画像群  $C = \{c_1, \dots, c_N\}$  の画像平面  $P$  を  $M \times M$  のメッシュに分割し、各々を領域  $P_k \subset P$  ( $k = 1, \dots, M^2$ ) とする。

(2)  $P_k \subset P$  ( $k = 1, \dots, M^2$ ) から画像特徴量ベクトル集合  $X_k = \{\mathbf{x}_{i,k} \mid i = 1, \dots, N\}$  を抽出する。

(3) 次元圧縮のため、 $X = \bigcup_{k=1}^{M^2} X_k$  に主成分分析を適用し、 $Y = \bigcup_{k=1}^{M^2} Y_k$ ,  $Y_k = \{\mathbf{y}_{i,k} \mid i = 1, \dots, N\}$  を得る。

(4) 特徴空間  $Y$  における各画像領域の重心間のマハラノビス汎距離

$$D_{k,l}^2 = (\bar{\mathbf{y}}_k - \bar{\mathbf{y}}_l)^T \Sigma^{-1} (\bar{\mathbf{y}}_k - \bar{\mathbf{y}}_l), \quad (11)$$

を測定し、この距離が最小となる領域  $P_{i_1}, P_{i_2}$  を統合対象とする。ここで、 $\bar{\mathbf{y}}_k, \bar{\mathbf{y}}_l, \Sigma^{-1}$  はそれぞれ、 $Y_k, Y_l$  の重心ベクトル、共分散行列の逆行列である。

(5) 領域統合モデルと領域分割モデルの MDL をそれぞれ算出し、 $\text{MDL}_{(uni)} \leq \text{MDL}_{(div)}$  ならば、領域  $P_{i_1}, P_{i_2}$  を統合する。そうでなければ、処理を終了する。

(6) (4)-(5) の処理を繰り返す。

こうして得られた注目画像領域は、ユーザが画像群

$C$  内の画像を知覚する際に着目した構図に相当すると考えられる。

本論文では、注目画像領域を高解像度、低解像度それぞれの画像平面から独立に抽出し、画像中の細かな特徴に重きを置いた場合の構図、大まかな特徴に重きを置いた場合の構図をそれぞれ推定する。こうして推定した構図領域ごとに、ユーザが注目した特徴を独立に推定し、主観特徴空間を生成する。

#### 4.4 主観特徴空間の生成

##### 4.4.1 画像分類用の主観特徴空間

本研究では、判別分析を用いて階層的に分類された画像群をたどることで、ユーザが画像各部位の特徴に注目して画像をカテゴリ分類する過程をモデル化する。

4.2 節で論じたように、ユーザが重視する画像特徴やその細かさは画像平面の領域によって異なると考えられる。そこで、高解像度及び低解像度の画像から各々抽出した注目画像領域ごとに独立に変数選択を行うことで、ユーザが画像分類の際に当該領域で着目した特徴を推定し、各領域に対応した画像分類用の主観特徴空間を生成する。

いま、教示用画像群  $C = \{c_1, \dots, c_N\}$  の解像度  $\rho$  の画像平面  $P_\rho$  は、4.3.5 節の注目画像領域抽出アルゴリズムによって  $K_\rho$  個の注目画像領域  $P_{k,\rho}$  ( $k = 1, \dots, K_\rho$ ) に分割されているとする。また  $C$  は、あらかじめユーザの主観的判断基準に基づいて任意の  $\alpha$  個の群  $C^{(j)} = \{c_1, \dots, c_{N_j}\}$ ,  $\bigcup_{j=1}^{\alpha} C^{(j)} = C$  に分類されているとする。

本研究では、注目画像領域  $P_{k,\rho}$  において  $\alpha$  個の群を判別するのに有効な変数を  $F$  統計量を用いて選択し [9]、領域  $P_{k,\rho}$  における画像分類用の主観特徴空間  $\Theta_{k,\rho}$  とする。

##### 4.4.2 画像認識用の主観特徴空間

前節で生成した画像分類用の主観特徴空間を用いて判別分析を階層的に適用した結果、様々な画像は最終的に、階層分類された各画像群のうち最下層に位置する画像群のいずれかに分類される。これら最下層に位置する画像群は、ユーザが自らの判断基準を階層的に教示した結果、互いにかなり類似した画像で構成されていると考えられる。

本研究では、ユーザが最下層に位置する画像群内の各画像にどのような類似性を見出したのかを推定するため、解像度  $\rho$  の画像平面  $P_{k,\rho}$  から抽出した画像特徴量ベクトル集合  $X_{k,\rho} = \{\mathbf{x}_{i,k,\rho} \mid i = 1, \dots, N\}$  に主成分分析を適用し、画像認識用の主観特徴空間  $\Omega_{k,\rho}$

とする。

本論文で考える心理的レベルの感性のモデルでは、判別分析を用いてユーザが画像をカテゴリ分類する過程をモデル化するには画像分類用の主観特徴空間を用いる。また、画像が分類された後、特定の画像群内でより詳細にユーザの心理的レベルの感性をモデル化するには画像認識用の主観特徴空間を用いる。

#### 4.5 画像領域の注目度

画像の類似度を主観的に判断する際、ユーザは画像中の各特徴を同列に評価せず、画像中の一部の（興味を引かれた）オブジェクトや背景を重点的に評価している。そこで本研究では、各解像度の画像平面から抽出された注目画像領域ごとに、ユーザがどの程度その領域に注目しているのかを推定する注目度を算出し、注目度に応じた重み付けを行う。

我々は領域内における画像特徴量の分布の分散を利用すれば、ユーザが当該領域にどの程度一貫した判断基準を与えているかを測定できると考えた。領域内での画像特徴量の分布の分散が大きければ、その領域内ではユーザの判断基準が一貫していない、すなわちユーザはさほどその領域に注目していないと考えられる。逆に領域内での画像特徴量の分布の分散が小さければ、その領域内ではユーザの判断基準が一貫している、すなわちユーザはその領域に注目していると考えられる。

本論文ではこの考えに基づき、解像度  $\rho$  の領域  $P_{k,\rho}$  ( $k=1, \dots, K_\rho$ ) における注目度  $z_{k,\rho}$  を次式で定義した。

$$\zeta_{k,\rho} = \frac{\sum_{\rho} \sum_k \log(|\Sigma_{k,\rho}|)}{\log(|\Sigma_{k,\rho}|)}, \quad (12)$$

$$z_{k,\rho} = \frac{\zeta_{k,\rho}}{\sum_{\rho} \sum_k \zeta_{k,\rho}}. \quad (13)$$

ここで、 $\Sigma_{k,\rho}$  は領域  $P_{k,\rho}$  の主観特徴空間における画像特徴量ベクトル集合の共分散行列、 $|\cdot|$  は行列式を表す。また、 $\sum_{\rho} \sum_k z_{k,\rho} = 1$  である。 $z_{k,\rho}$  の値が大きいほど、当該領域内におけるユーザの判断基準は一貫している、すなわちユーザはその領域に着目していると考えられる。

この注目度を用い、各解像度の画像特徴量ベクトル集合から独立に構築した注目領域モデルを統合することで、画像を認識する際、ユーザが画像中のどの部位の、どの大きさ（解像度）のオブジェクトや背景に着目しているのかを推定できる。本論文では、注目度を

用いて統合されたこれらの注目領域モデルを心理的レベルの感性のモデルと考える。

#### 4.6 判別分析

いま、教示用画像群  $C = \{c_1, \dots, c_N\}$  はあらかじめユーザの主観的判断基準に基づいて任意の  $\alpha$  個の群  $C^{(j)}$ ,  $\bigcup_{j=1}^{\alpha} C^{(j)} = C$  に分類され、 $C$  の解像度  $\rho$  の画像平面  $P_\rho$  は  $K$  個の注目画像領域  $P_{k,\rho}$  ( $k=1, \dots, K_\rho$ ) に分割されているとする。また、 $C^{(j)}$  の画像領域  $P_{k,\rho}$  から抽出した画像特徴量ベクトル集合を  $X_{k,\rho}^{(j)} = \{\mathbf{x}_{i,k,\rho}^{(j)}\}$ ,  $X_{k,\rho}^{(j)}$  の  $\Theta_{k,\rho}$  における表現を  $V_{k,\rho}^{(j)} = \{\mathbf{v}_{i,k,\rho}^{(j)}\}$  とする。ここで、 $\Theta_{k,\rho}$  は領域  $P_{k,\rho}$  の画像分類用の主観特徴空間である。

この時、画像群  $C^{(j)}$  と対象画像  $c_T$  間の距離を次式で定義する。

$$D_{(j)}^2 = \sum_{\rho} \sum_{k=1}^{K_\rho} z_{k,\rho} \left\{ \frac{1}{\dim \Theta_{k,\rho}} \times (\mathbf{v}_{k,\rho} - \bar{\mathbf{v}}_{k,\rho}^{(j)})^T \Sigma_{(j,k,\rho)}^{-1} (\mathbf{v}_{k,\rho} - \bar{\mathbf{v}}_{k,\rho}^{(j)}) \right\}. \quad (14)$$

$\mathbf{v}_{k,\rho}$ ,  $\bar{\mathbf{v}}_{k,\rho}^{(j)}$ ,  $\Sigma_{(j,k,\rho)}^{-1}$ ,  $\dim \Theta_{k,\rho}$ ,  $z_{k,\rho}$  はそれぞれ、 $c_T$  の画像特徴量ベクトルの  $\Theta_{k,\rho}$  における表現、 $V_{k,\rho}^{(j)}$  の重心ベクトル、 $V_{k,\rho}^{(j)}$  の共分散行列の逆行列、 $\Theta_{k,\rho}$  の次元数、領域  $P_{k,\rho}$  の注目度である。本研究では、対象画像と各画像群までの距離  $D_{(j)}^2$  ( $j=1, \dots, \alpha$ ) を計算し、 $\min\{D_{(j)}^2 \mid j=1, \dots, \alpha\} = D_{(l)}^2$  となる画像群  $l$  に対象画像が属すると判定する。

#### 4.7 類似画像検索への応用

我々は提案した視覚感性のモデル化手法を類似画像検索システムに応用し、個人の視覚感性を反映した類似画像検索システムを開発した。

##### 4.7.1 粗検索

我々のシステムでは、例示画像  $c_T$  が与えられると、まず粗検索として  $c_T$  が階層的に分類されたデータベース内のどの群に最も類似しているのかを、注目度により統合された注目領域モデルに基づき段階的に判別する。この段階的判別はデータベースの最下層に到達するまで繰り返され、最下層において  $c_T \in C^{(l)}$  と判定された画像群  $C^{(l)}$  のみを検索対象とする。階層的分類の手順を事前に踏むことで、画像データベースはユーザにとってよく目に付く特徴が類似している画像群から細かな特徴が類似している画像へと階層的に分類されている。そのため粗検索を経て決定された検索対象グループ内の各画像と例示画像は、ユーザから見ると

かなり類似したものであると期待できる。

#### 4.7.2 詳細検索

次に詳細検索として、 $C^{(l)}$  の解像度  $\rho$  の注目画像領域  $P_{k,\rho}^{(l)}$  ( $k=1, \dots, K_\rho^{(l)}$ ) と対応する画像認識用の主観特徴空間  $\Omega_{k,\rho}^{(l)}$  を用いて、例示画像と  $C^{(l)}$  内の各画像との類似度

$$\text{Sim}_{(i)} = \sum_{\rho} \sum_{k=1}^{K_\rho^{(l)}} z_{k,\rho}^{(l)} \left\{ \frac{1}{\dim \Omega_{k,\rho}^{(l)}} \times (\mathbf{s}_{k,\rho} - \mathbf{s}_{i,k,\rho}^{(l)})^T \Sigma_{(k,\rho)}^{-1} (\mathbf{s}_{k,\rho} - \mathbf{s}_{i,k,\rho}^{(l)}) \right\}, \quad (15)$$

を測定し、 $\min\{\text{Sim}_{(i)} \mid i=1, \dots, N_l\} = \text{Sim}_{(t)}$  となる画像  $c_t$  が  $c_T$  に最も類似していると判定する。ここで  $z_{k,\rho}^{(l)}$ ,  $S_{k,\rho}^{(l)} = \{\mathbf{s}_{i,k,\rho}^{(l)} \mid i=1, \dots, N_l\}$ ,  $\Sigma_{(k,\rho)}^{-1}$ ,  $K_\rho^{(l)}$ ,  $N_l$  はそれぞれ、領域  $P_{k,\rho}^{(l)}$  の注目度、領域  $P_{k,\rho}^{(l)}$  から抽出した画像特徴量集合  $X_{k,\rho}^{(l)} = \{\mathbf{x}_{i,k,\rho}^{(l)} \mid i=1, \dots, N_l\}$  の  $\Omega_{k,\rho}^{(l)}$  における表現、 $S_{k,\rho}^{(l)}$  の共分散行列の逆行列、 $C^{(l)}$  の解像度  $\rho$  の画像平面での注目画像領域数、 $C^{(l)}$  に属する画像枚数である。また、 $\mathbf{s}_{k,\rho}$  は  $c_T$  の画像特徴量ベクトルの  $\Omega_{k,\rho}^{(l)}$  における表現である。

類似画像を行う際の計算量の面でいえば、例示画像が階層的に分類されたデータベースのどの群に最も類似しているのかを特定するために  $\mathcal{O}(\log N)$ 、特定された群  $C^{(l)}$  内で詳細検索を行うために  $\mathcal{O}(N_l)$  の計算が必要となる。ここで  $N, N_l$  はそれぞれ、データベース全体の画像枚数、 $C^{(l)}$  の画像枚数であり、 $N \gg N_l$  である。

一方、階層分類を行わない場合、データベース全体を検索対象とするため、計算量は  $\mathcal{O}(N)$  となる。

### 5. 実験結果とその評価

#### 5.1 データベースの階層分類

従来の画像検索システムの多くは、同一のカメラおよび環境下で撮影するなど、検索対象の画質が揃っていることを前提としていた。しかし本稿では、市販の写真素材集、インターネットで公開されている著作権フリーの写真、著者らがデジタルカメラで撮影した写真など、画質（ノイズや撮影条件）や被写体が各々異なる画像 14,000 枚を用意し、提案した類似画像検索システムの有効性を検証した。

まず、我々は教示用画像群として 3,000 枚の画像をデータベースから無作為に抽出し、これらを階層的に分類することでユーザの主観的な判断基準を示した。

なお、本研究で用いた画像データベースはかなり多様なコンテンツを含んでいたため、本稿ではデータベースを丁寧に階層分類し、より精密に心理的レベルの感性をモデル化するために 3,000 枚の教示画像を用いた。ただし、粗い近似モデルでよい場合は、より少ない教示用画像群で心理的レベルの感性をモデル化することも可能である。図 4 にユーザが示した階層分類の一例を示す。図 4 に示した教示例はあくまでも一例であり、ユーザによって主観的な分類の結果は異なる。また、図 4 中の画像群に付与されているラベルは著者らが解析時に便宜的に付与したものであり、ユーザがこのラベルを指針として画像の分類を行ったわけではない。

次に、階層的に分類された各画像群に情報量基準を用いたクラスタリング手法を適用し、各群の注目画像領域を抽出した。本稿では、注目画像領域を高解像度 (1/1)、低解像度 (1/16)、2 種類の解像度の画像群から独立に抽出し、画像平面中の細かな特徴に重点を置いた場合の構図、大まかな特徴に重点を置いた場合の構図及び各領域の注目度を推定した (図 5)。こうして得られた画像領域ごとに独立に主観特徴空間を生成し、注目領域モデルを構築した。注目度を用いてこれらの注目領域モデルを統合することで、ユーザが画像の類似度を判断する際、画像のどの部位のどの特徴に着目したかを推定することができる。

我々は注目度により統合した注目領域モデルを階層的判別分析によりデータベース全体に適用し、データベース全体を自動的に階層分類した。本稿では、以上の手順を踏んで階層的に分類された画像データベースを用いて類似画像検索システムの評価を行った。


#### 5.2 検索精度の評価

我々は教示用画像と重ならないようにデータベースから 1,000 枚の画像を無作為に抽出し、評価用画像とした。これらを検索キーとして類似画像検索を行い、その検索精度を評価する。なお、本稿では比較のため、提案特徴量の主観特徴空間を生成しなかった場合、画像特徴量として次数を 2 までとした高次自己相関特徴およびカラーヒストグラム（色空間を構成する各軸を 15 区間に分割して算出）を用いた場合の検索精度についても評価を行った。

##### 5.2.1 判別分析の精度

本節では、粗検索において、ユーザが対象画像を主観的にカテゴリ分類する過程をどの程度までシミュレートできているのかを評価する。まず、あらかじめ目視により各評価用画像が階層分類されたデータベー

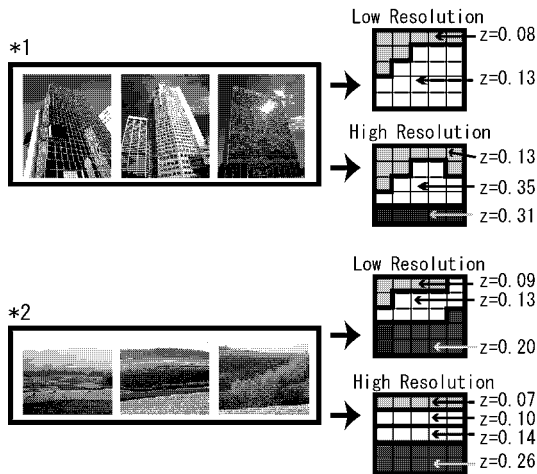




(\*) The names of the groups are given by the authors independently from the examinee for convenience.

図 4 階層分類による教示の一例

Fig. 4 An Example of Hierarchically Classified Database



(\*) Here, the groups, \*1 and \*2, appears in Fig. 4. A parameter  $z$  denotes expectation value of each focal area.

図 5 各画像群の注目画像領域の抽出例

Fig. 5 Examples of Focal Areas in Multiple Resolution Planes

ス内のどの画像群に属するべきかを判定する。次に各評価用画像が、階層的に分類されたデータベース中のどの画像群に最も類似しているのかを判別分析を用いて判定し、判別分析の結果と事前の目視判定の結果が一致した割合（群判別の成功率）で粗検索の精度を評価した（表 1）。また、心理的レベルの感性のモデル化手法における注目領域抽出および注目度の有効性を評価するため、注目領域抽出しなかった場合（表中の注目領域なし）、抽出した場合（表中の注目領域あり）、さらに注目度を組み合わせた場合それぞれについて判別成功率を算出した。

表 1 に示したように、提案特徴量を用いた場合、判別成功率の値は他の画像特徴量を用いた場合と比べ高い水準の値を示した。

提案特徴量の画像分類用の主観特徴空間を生成しなかった場合の判別成功率は、生成した場合と比べ低い

表 1 非教示データに対する判別成功率  
Table 1 Recognition Ratio for Unknown Data

	注目領域 +注目度	注目領域 あり	注目領域 なし
提案特徴量	94.3%	91.1%	83.8%
提案特徴量 (主観特徴空間非生成)	—	86.4%	75.2%
高次自己相関特徴	63.5%	61.7%	56.5%
カラーヒストグラム	66.1%	65.0%	57.7%

水準にとどまっている。これは、主観的に画像をカテゴリ分類する際にユーザが着目した特徴、着目しなかった特徴を選別せずに高い次元の特徴空間のまま評価を行った結果、いわゆる次元の呪い [10] に陥ってしまったことが原因であると考えられる。なお、高い次元の特徴空間のままでは共分散行列の行列式の値が計算できず、注目度を算出できない場合があったため、注目度導入時の精度は評価していない。

高次自己相関特徴は刺激強度の積に着目した特徴量であるため、画像撮影時の環境光の違いや画像にのったノイズなどの要因により、特徴量の値が影響されやすい。今回の実験で用いた画像データベースには撮影環境や画質が異なる画像が多数含まれていたが、上述の理由により、高次自己相関特徴ではこういった画像の類似性をうまく表現できなかったと考えられる。それに対し、提案特徴量は 3.1 節で論じたように、ノイズや環境光の変化に強い設計となっている。そのため、ノイズや環境光の違いといった諸条件の違いにあまり影響されることなく、各画像の特徴をうまく表現できたと考えられる。

また、我々の画像データベース内には画像全域の色彩分布は類似していても、オブジェクトの形状やテクスチャが大きく異なる画像が多数含まれていた。カラーヒストグラムは局所的な明暗や色彩の特徴を欠いているがゆえに、オブジェクト形状やテクスチャの違いをうまく表現できなかったと考えられる。それに対し、提案特徴量は局所的な明暗や色彩の対比情報を

ベースにして、画像中の直線的、曲線的な変化を表現できるように設計されている。そのため、今回の実験に用いたデータベースのように多種多様な画像を検索対象とする場合でも、各画像中のオブジェクト形状やテクスチャの違いをうまく表現できたと考えられる。

注目領域の抽出に関しては、抽出した場合のほうが抽出しなかった場合と比べて高い判別率を示した。また注目度に関しても、注目度を導入したほうが高い判別率を示した。したがって、注目領域抽出および注目度の算出は、ユーザの主観的な画像のカテゴリ分類過程をシミュレートする上で有効であると考えられる。

### 5.2.2 詳細検索の精度

つぎに、判別分析の結果もつとも評価用画像に類似していると判断された画像群内で詳細検索をおこない、類似度上位 30 枚検索時の精度を適合率 (表 2) と再現率 (表 3) で評価した。

表 2 非教示データに対する適合率  
Table 2 Precision Ratio for Unknown Data

	注目領域 +注目度	注目領域 あり	注目領域 なし
提案特徴量	74.1%	68.2%	57.0%
提案特徴量 (主観特徴空間非生成)	—	56.7%	43.4%
高次自己相関特徴	40.3%	36.6%	30.5%
カラーヒストグラム	34.2%	32.8%	22.7%

表 3 非教示データに対する再現率  
Table 3 Recall Ratio for Unknown Data

	注目領域 +注目度	注目領域 あり	注目領域 なし
提案特徴量	68.5%	63.7%	52.9%
提案特徴量 (主観特徴空間非生成)	—	51.7%	40.3%
高次自己相関特徴	37.3%	33.7%	28.0%
カラーヒストグラム	33.8%	31.5%	21.0%

表 2, 表 3 に示したように、本稿で提案した手法を用いた場合、適合率、再現率ともに高い水準の値を示した。

画像特徴量に高次自己相関特徴やカラーヒストグラムを用いた場合、適合率、再現率ともに提案手法に比べて低い水準にとどまっている。これは、粗検索である判別分析における成功率が提案特徴量と比べて低かったためだと考えられる。また、前節で論じたように高次自己相関特徴は環境光の変化に弱いため、カラーヒストグラムは局所的な明暗や色彩の特徴を欠いているために今回実験に用いた画像の特徴をうまく表

現できなかったということも影響したと考えられる。

この詳細検索では、注目度を導入した場合の精度が導入していない場合に比べ、適合率、再現率ともに高い水準の値を示している。このことから、ユーザが画像のどの部位のどの特徴に着目して画像を互いに類似していると主観的に判断したのかを、注目度によりうまく推定できていると考えられる。

### 5.2.3 心理的レベルの感性のモデルの有効性

次に、心理的レベルの感性のモデル化を行った場合 (階層分類使用) と行わなかった場合 (階層分類非使用) で同様の実験を行った (画像特徴量は提案特徴量を使用)。

表 4 心理的レベルの感性のモデルの有効性検証  
Table 4 Evaluation of Modeling Method of Subjective Leve KANSEI

	適合率	再現率
提案手法	74.1%	68.5%
階層分類非使用	41.4%	37.8%

表 4 に示したように、提案手法 (階層分類使用) の方が適合率、再現率ともに高い水準にある。これは、対象画像群ごとに構図及びユーザが重視する画像特徴を推定した上で階層的に判別分析を行うことにより、階層分類によって示されたユーザの主観的な類似度判断基準をうまく再現できているからだと考えられる。

また、検索に要する計算コストの面では、階層分類を用いた場合 (提案手法)、検索に平均 1.9 秒を要したのに対し、階層分類を用いなかった場合には、平均 7.3 秒を要した (AMD Athlon 1.3GHz, メモリ 512MB のマシン上で計測)。

## 6. む す び

本論文で我々は、視覚感性のモデル化手法を提案し、類似画像検索に応用した。

生理的レベルの感性のモデル化としては、視覚の知覚過程における特徴抽出機構を模した画像特徴量を定義し、画像から抽出した。心理的レベルの感性のモデル化としては、人間の直感的な画像の分類過程を模したデータベースの階層的な分類によりユーザの主観的類似度判断基準を教示し、これを分析することでユーザが重視する特徴量の推定を試みた。

ユーザが重視する特徴は画像平面の領域によって異なると考えられるため、本研究ではまず情報量基準を用いたクラスタリング手法を適用して画像群に属する各画像に共通する構図を推定し、その上で各構図領域

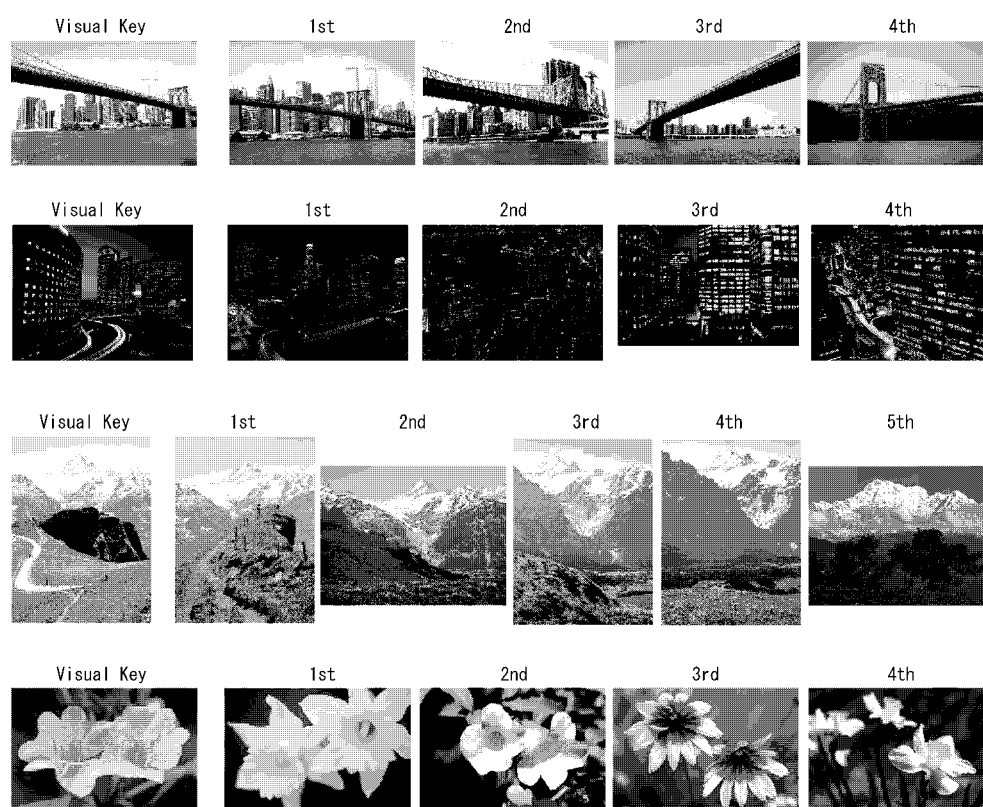


図 6 主観的なカテゴリの推定とその中での類似検索の結果  
Fig. 6 Examples of Similarity Retrieved Results

ごとにユーザが重視する特徴量を推定した（注目領域モデル）。ただし、ユーザが同一画像上で異なる大きさのオブジェクトや背景に着目していた場合、単一解像度から抽出した画像特徴量のみでは、ユーザの視覚感性を十分にモデル化しえない可能性が高い。そこで、本研究では複数の解像度の画像特徴量集合からそれぞれ注目領域モデルを独立に構築し、ユーザが画像の類似度を判定する際に画像のどの領域のどの大きさ（解像度）のオブジェクトや背景に注目したのか（注目度）を推定した。推定した注目度を用いて複数の解像度から構築した注目領域モデルを統合し、統合したモデルを用いて階層的に判別分析を行うことで、ユーザが対象画像を分類し認識する過程、すなわち心理的レベルの感性をシミュレートした。

類似画像検索においては、例示画像に階層的判別分析を適用することでユーザが主観的に対象画像を分類する過程をシミュレートし、データベース内で例示画像に最も類似した画像群を特定する。そして、特定さ

れた画像群のみを検索対象として類似画像検索を行うことで、高い検索精度（上位 30 枚検索時で適合率 74.1%，再現率 68.5%）と計算時間の低減を実現した。

**謝辞** 本研究の初期にご助言を頂いた産業技術総合研究所の大津展之博士、栗田多喜夫博士に感謝します。また本論文の執筆にあたり、様々な助言を下された産業技術総合研究所の坂本隆博士に感謝します。

#### 文 献

- [1] 多田昌裕, 加藤俊一, “階層的分類を用いた視覚感性のモデル化と類似画像検索への応用,” 情処学論, vol.44, no.SIG 8, pp.37-45, 2003.
- [2] L. Spillmann and J.S. Werner, Visual Perception, Academic Press, San Diego, 1990.
- [3] Y. Gong, Intelligent Image Databases Towards Advanced Image Retrieval, Kluwer Academic Publishers, 1998.
- [4] N. Otsu, and T. Kurita, “A new scheme for practical, flexible and intelligent vision systems,” Proc. IAPR Workshop on Computer Vision, pp.431-435, 1988.
- [5] T. Kurita, N. Otsu, and T. Sato, “A Face Recognition Method Using Higher Order Local Autocor-

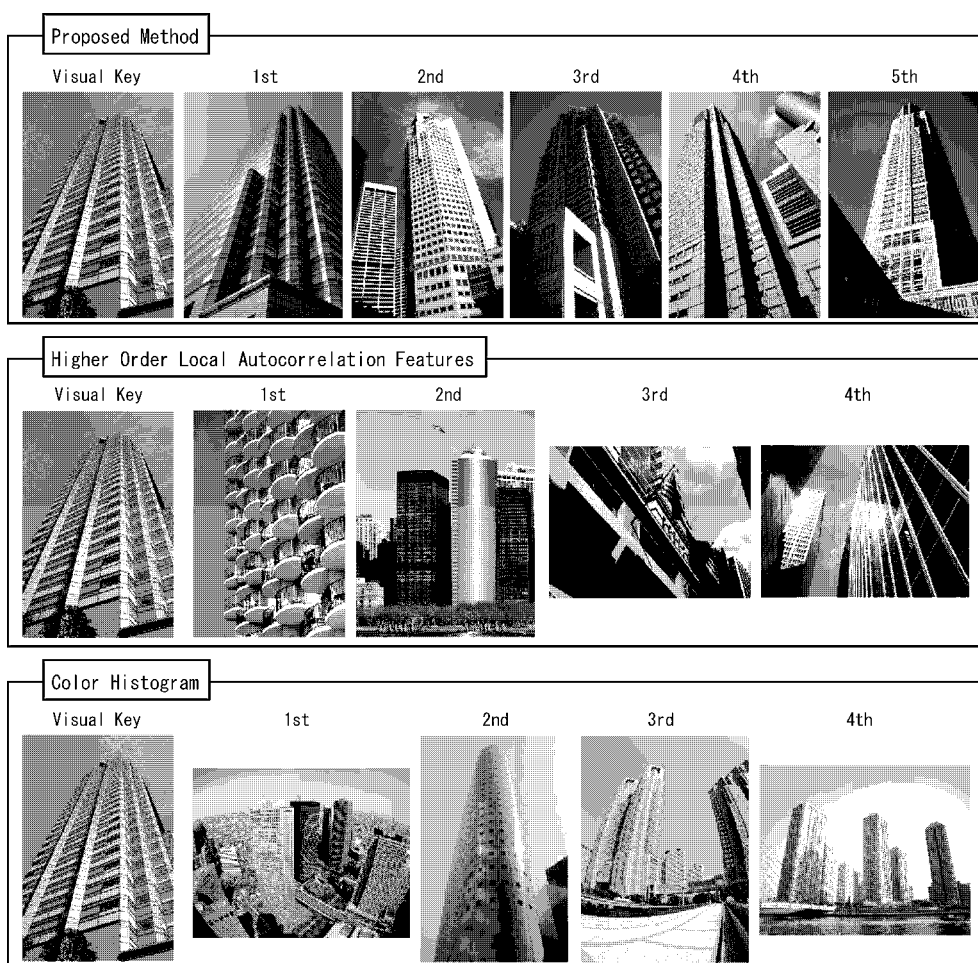


図 7 他手法の検索結果との比較  
Fig.7 Comparison of Retrieved Results

relation And Multivariate Analysis,” Proc. of 11th International Conf. on Pattern Recognition, vol. 2, pp.213-216, 1992.

[6] T. Kurita and N. Otsu, “Texture Classification by Higher Order Local Autocorrelation Features,” Proc. of Asian Conf. on Computer Vision, pp.175-178, 1993.

[7] 池田光男, 眼はなにを見ているか—視覚系の情報処理—平凡社・自然叢書 8, 平凡社, 東京, 1988.

[8] J. Rissanen, “Fisher Information and Stochastic Complexity,” IEEE Trans. Inf. Theory, vol.42, pp.40-47, 1996.

[9] 田中豊, 垂水共之, 脇本和昌 (編), パソコン統計解析ハンドブック II 多変量解析編, 共立出版, 東京, 1984.

[10] 石井健一郎, 上田修功, 前田英作, 村瀬洋, わかりやすいパターン認識, オーム社, 東京, 1998.

(平成 15 年 12 月 8 日受付, 5 月 6 日再受付)



多田 昌裕 (学生員)

2001 中央大・理工・経営システム工学卒.  
2003 同大大学院理工学研究科博士前期課程了. 現在, 同大大学院博士後期課程在学中. 感性工学の研究に従事.



加藤 俊一 (正員)

中央大学工学部経営システム工学科教授. 京都大学大学院工学研究科博士後期課程了, 工学博士. ヒューマンメディア工学の研究に従事. 情報処理学会, 日本感性工学会, IEEE の各会員.