

画像特徴量空間から類似性空間への写像を利用した 類似画像検索

中越 智哉

佐藤 健

北海道大学大学院工学研究科

北海道大学大学院工学研究科

事例ベース推論における事例検索のキーとして画像を用いることは、これまでにほとんど例のないものであるが、その実現を妨げる一つの原因として、画像の類似性を表現することが難しいということがあげられる。本論文では、画像の類似性は観点によって変化するものと考え、これを利用者ごとに学習することが必要であると考えた。さらに、画像を直接のキーとして検索するためには、学習した類似性を、画像特徴量だけを使って表現することが重要と考えた。本論文では、利用者からサンプル画像のグルーピングと、グループ間の類似度の形で画像の類似性に関する観点を獲得し、多次元尺度法と多変量線形回帰モデルを連動して用いることで、画像の類似性を画像特徴量から変換して表現することのできる手法を提案する。我々はこの手法を類似画像検索システムに適用し、従来手法として判別分析的手法を用いた類似画像検索手法との比較を行い、検索成功率においてより優れた結果を得た。

Similar image retrieval by mapping images into similarity space

Tomoya Nakagoshi

Ken Sato

Hokkaido University

Hokkaido University

As far as we know, there is no proposal of a case based reasoning system using multimedia data as an index of cases since it is difficult to express the similarity of multimedia data. We believe that a similarity of image depends on user's viewpoint, so it is important to reflect the viewpoint into an index of images. In this paper, a user expresses his viewpoint by grouping sample images and giving a similarity distance among these groups. Then, we use multidimensional scaling (MDS) to construct user's similarity space from the above information, and use multivariate linear regression model to derive a mapping from a graphical feature space to the similarity space. We compare our method with a previous method using discriminant analysis and show that our method is better than the method regarding retrieval success ratio.

1 研究の背景

我々は、実生活の中で、過去に経験したこと(事例)を参考にして、新たな問題に取り組んだり、なんらかの判断をしてそれを解決することがよくあ

る。このような方法を、事例ベース推論とよぶ。

本論文では、事例あるいは事例中の問題部分が画像で表されているような事例のことを画像事例とよぶ。また、画像事例を格納した事例ベースのことを、画像事例ベース、これを用いて行う事例

ベース推論を画像事例ベース推論とよぶことにする。画像を用いて事例ベース推論を行うという考え方は、過去にはほとんど例のないものである。

しかし、我々の実社会に適用することができそうな事例ベース推論には、画像を事例検索のキーとするものが多くあるだろう。例えば、人間が過去の経験をもとに、気象画像を見て天候を判断したり、患部の写真を見て病状を判断するといったことは、その一例であるといえる。

計算機の技術の発展に伴い、計算機で扱えるデータは、文字・数値情報にとどまらず、画像や音声といった、マルチメディア・データをも含むようになってきている。今後は、上の例のように、マルチメディア・データ、とりわけ、画像を直接的に扱うような事例ベース推論システムに対する要求は高まっていくであろう。

しかし、画像を直接のキーとして類似事例を検索できるようなシステムは、現状では存在していない。そのことについて我々は、画像事例間の類似性の表現、すなわち、解どうしの類似性と、問題(画像)どうしの類似性をうまく結びつけることが難しい、ということが一つの原因であると考えた。もしも、画像事例間の類似性をうまく表現することができれば、そのような事例ベース推論システムのために、大きな貢献となるだろう。

そこで、本論文では、画像事例ベース推論システム構築のための第一歩として、利用者の観点を学習し、画像をキーとして類似画像を検索する手法を提案し、その有効性を示すことを目的とする。

2 研究のアプローチ

以上のような経緯から、我々は、さまざまなマルチメディア・データの中で、特に画像に注目し、画像事例ベース推論システムの構築のためには、まず、画像事例における類似性をうまく表現する方法が必要であると考えた。

そのような方法を実現するためには、画像事例における事例の類似性とはどのようにして決まるのかということを考える必要がある。類似した画像事例の検索とは、すなわち画像部分が類似した事例の検索である。そのため、類似画像の検索技術を応用することで、類似画像事例の検索が可能

であろうと考えられる。

「類似画像」というものを定めるためには、画像の類似性とはどのようなものであるかを考えることは避けて通れない問題である。我々は、画像の類似性とはその画像をどうとらえるか、どう扱うかというような観点によって変化するものであると考えた。さらに、そういった観点は、利用者によって、またその利用目的によっても異なりうるものであると考えられるため、利用者、利用目的ごとに観点を学習する必要があるだろう。

利用者が類似性を表現する簡単な方法として、これを類似度として表現する方法がある。人間は多くの場合、類似性に関して絶対的の尺度を持っておらず、相対的比較によってそれを表現することが多いと考えられるため、我々は順序尺度による非類似度での表現を考えた。さらに、これを距離として表現できる空間をつくることができれば、容易に類似検索が可能となるだろう。

一方で、利用者が実際に類似画像検索を行う場合、これまでは、キーワードを画像に付加しておき、そのキーワードを使って検索を行う、というものが多く見られたが、これは利用者が問い合わせの際にキーワードを考える必要があるだけでなく、画像データベース内の全ての画像についてキーワードを付加しておく必要があるため、規模が大きくなった場合、その労力は無視できないものとなる。また、画像を自然言語での確に表現することの妥当性には疑問があるといえるだろう。

利用者にとっては、「この画像と類似している画像を取り出したい」という要求を満たすための、もっとも簡単な問い合わせの与え方は、その例示画を示して問い合わせとすることであろう。また、画像のみを使って検索が実行できれば、画像データベースに人手により検索のための情報を付加する必要もなく、コストの問題も解決できると考えられる。

利用者ごとに類似性の観点を学習し、その結果を、問い合わせとして与えられた画像そのものだけを使って表すためには、画像と学習した類似性の双方を、変換可能な形で表す手法が必要である。

そのような手法を使えば、検索の際には、画像

から自動で画像特徴量¹を取り出し、変換写像によって類似性空間上に変換して検索を行うことで、利用者の観点が反映された類似画像検索ができるものと考えられる。本論文ではこのような手法を実現するものとしてM+R法を提案する。

3 M+R法の動作

M+R法は、利用者の類似性に関する観点を学習する類似性学習部と、実際の検索を行うための類似画像検索部の2つの部分からなる。

以下では、まずM+R法で用いる多次元尺度法と多変量線形回帰モデルについて概説した後、M+R法の手順について解説する。

3.1 多次元尺度法

多次元尺度法(Multidimensional Scaling;MDS) [1]は、複数の対象間の類似性を、入力データとし、対象のそれぞれを空間上の点として表現した空間付値を出力する手法である。空間付値の次元数は、利用者があらかじめ指定することができる。

出力される空間 X 上の対象 i と対象 j の距離(通常は、ユークリッド距離)を d_{ij} 、非類似度を s_{ij} とすると、これらの間には単調関係と呼ばれる以下の関係が近似的に満たされている。

$$\begin{cases} s_{ij} = s_{kl} \Rightarrow d_{ij} = d_{kl} \\ s_{ij} > s_{kl} \Rightarrow d_{ij} \geq d_{kl} \end{cases} \quad (1)$$

多次元尺度法の一つであるKruskalの方法では、出力される空間 X が、式(1)の単調関係をどのくらいよく満たしているかを評価する基準であるストレスを測定して、これを最小化するような手順をとる。ストレス S は

$$S = \sqrt{\frac{\sum_{i < j} (d_{ij} - \bar{d}_{ij})^2}{\sum_{i < j} (d_{ij} - \bar{d})^2}} \quad (2)$$

と書ける。このとき、 \bar{d} は d_{ij} の平均を示す。また、 \bar{d}_{ij} は入力データと出力する空間との比較に用いる媒介変数であり、入力データ s_{ij} の順序関係に矛盾しない理想的な距離を示していると考え

¹ 本論文においては、計算機上で表現される画像(画素の集合)の持つ特徴を、なんらかの方法によって数値(または、数値の集合)として表現したもの

てよい。つまり、出力される空間 X 上での対象間の距離関係が、入力データの順序関係に一致すれば、 $S=0$ となり、もっとも理想的な空間であると言える。このような空間を逐次近似的解法(最急勾配法)により求めて出力とする。

3.2 多変量線形回帰モデル

分析の対象となるある現象Aについて、それを他の現象Bによって説明(推定)しようとする方法を、回帰分析 [2] という。具体的には分析の対象となる現象Aを変数 Y (従属変数) で表し、それを説明しようとする現象Bを変数 X_1, X_2, \dots, X_p (独立変数) で表したとき、未知パラメータ $\beta_0, \beta_1, \beta_2, \dots, \beta_p$ を使って

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p + \varepsilon \quad (3)$$

における ε (残差)を最小にする方法のことをいう。このような β_i は、最小2乗法によって求める。

観測値は一般には複数あるので、その数を N とし、従属変数を

$$\mathbf{Y} = (Y_1, Y_2, \dots, Y_N)' \quad (4)$$

で表し、独立変数、未知パラメータ、残差を同様にして、それぞれ

$$\mathbf{Y} = \mathbf{X}\beta + \varepsilon \quad (5)$$

と書いたものが線形回帰モデルである。

さらに、従属変数が

$$\mathbf{Y}' = (Y_1, Y_2, \dots, Y_m) \quad (6)$$

のようなベクトル変数である場合の線形回帰モデルのことを多変量線形回帰モデルという。 Y_1, Y_2, \dots, Y_m を

$$\begin{aligned} Y_1 &= \beta_{01} + \beta_{11} X_1 + \dots + \beta_{p1} X_p + \varepsilon_1 \\ Y_2 &= \beta_{02} + \beta_{12} X_1 + \dots + \beta_{p2} X_p + \varepsilon_2 \\ &\vdots \\ Y_m &= \beta_{0m} + \beta_{1m} X_1 + \dots + \beta_{pm} X_p + \varepsilon_m \end{aligned} \quad (7)$$

と表し、 $\mathbf{X}, \beta, \varepsilon$ をそれぞれ

$$\mathbf{X} = \begin{bmatrix} 1 & X_{11} & X_{21} & \dots & X_{p1} \\ 1 & X_{12} & X_{22} & \dots & X_{p2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & X_{1N} & X_{2N} & \dots & X_{pN} \end{bmatrix} \quad (8)$$

$$\beta = \begin{bmatrix} \beta_{01} & \beta_{02} & \dots & \beta_{0m} \\ \beta_{11} & \beta_{12} & \dots & \beta_{1m} \\ \vdots & \vdots & \ddots & \vdots \\ \beta_{p1} & \beta_{p2} & \dots & \beta_{pm} \end{bmatrix} \quad (9)$$

$$\varepsilon = \begin{bmatrix} \varepsilon_{11} & \varepsilon_{12} & \dots & \varepsilon_{1m} \\ \varepsilon_{21} & \varepsilon_{22} & \dots & \varepsilon_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ \varepsilon_{N1} & \varepsilon_{N2} & \dots & \varepsilon_{Nm} \end{bmatrix} \quad (10)$$

と表す。

3.3 類似性学習部

M+R法の類似性学習部は、利用者から画像の類似性に関する観点で

- サンプル画像をグルーピングしたもの
- そのグループに順序尺度で非類似度を設定したもの

の形で獲得し、それを画像特徴量を使って表現するための変換画像を得ることが目的である。

本来ならば一つの画像に対する、それ以外の全ての画像についての非類似度を設定することが望ましいが、画像の総数が増えるとそのような作業が容易ではなく、また、多次元尺度法の計算時間も膨大になりやすいため、このような入力データを用いることとした。

手順は以下ようになる。

1. サンプル画像をグルーピングする (サンプル画像数を n 、グルーピングされたグループ数を g とする)。
2. それらのグループどうしに類似度データ行列を設定する。
3. 類似度データ行列を多次元尺度法に入力することにより、グループ間の類似度の順序尺度

の関係を近似的に表現した空間を得ることができる。これを、類似性空間とする。このとき、類似性空間の次元数は、ストレス最小となる次元数 (m とする) にする。類似性空間上のベクトル表現 $y_i (1 \leq i \leq g)$ は、

$$y_i = (y_{i1}, y_{i2}, \dots, y_{im}) \quad (11)$$

と書ける。

4. 利用者のグルーピングにしたがい、サンプル画像一つ一つを、類似性空間上で各グループを示す点に対応させる。このとき、類似性空間を示す行列 \mathbf{Y} は、

$$\mathbf{Y} = \begin{bmatrix} y_{11} & y_{12} & \dots & y_{1m} \\ y_{21} & y_{22} & \dots & y_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ y_{n1} & y_{n2} & \dots & y_{nm} \end{bmatrix} \quad (12)$$

と書ける。

5. サンプル画像自身からは画像特徴量を抽出しておく。画像特徴量の属性数を p とし、これらを行列として書けば、

$$\mathbf{X} = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1p} \\ x_{21} & x_{22} & \dots & x_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \dots & x_{np} \end{bmatrix} \quad (13)$$

となる。

6. 画像特徴量空間から類似性空間への変換画像 B を、多変量線形回帰モデル

$$\mathbf{Y} = \mathbf{XB} + \mathbf{E} \quad (14)$$

により構成し、これを出力とする。

3.4 類似画像検索部

類似画像検索部は、利用者が入力した画像そのものをキーとして、類似画像を検索して出力する。手順は以下ようになる。

1. まず、入力された画像自身から、画像特徴量を抽出し、これをベクトル表現する。

2. このベクトルを、類似性学習部で得られた変換写像を用いて、類似性空間上の点に変換する。
3. そして、類似性空間上で、入力された画像とのユークリッド距離の最も小さい画像を選び、出力とする。

3.5 多次元尺度法と多変量線形回帰モデルの連動

M+R法では、MDSと回帰分析を連動させて用いるが、これは、「画像の類似性」というユーザーの観点をMDSによって表現したものに対して、画像特徴量を基準とした従属関係を持たせていることになる。そして、多変量線形回帰モデルを適用した結果として得られた写像を使って、画像特徴量のみで画像の類似性を説明する、ということになる。MDSと多変量線形回帰を連動させて画像の類似性を学習し、類似検索を行う手法は、これまで提案されたことのないものである。

4 評価の方法

M+R法の評価のために、類似画像検索システムへの適用を考えた。

類似画像検索システムとは、大量に蓄積された画像の中から利用者が提示した画像と類似したものを効率良く検索して取り出すための仕組みのことである。M+R法を使うことで、画像を直接的に検索キーとする類似画像検索システムを構築することができ、利用者の考える画像どうしの類似性の観点にそった類似画像検索を行うことができると期待できる。

我々は、従来の類似画像検索の枠組みとして、栗田・下垣・加藤 [3]の方法との比較を行った。栗田らの方法の特徴を簡単に示すと以下ようになる。

- 利用者がサンプル画像のグルーピングを行うことによって、利用者の観点を与える
- 利用者の観点を反映するような空間 (主観特徴空間) が、アフィン写像

$$y = A'(x - \bar{x}_T)$$

によって構成できると仮定する。ここで、 y は主観特徴空間上のベクトルである。 x は画

像特徴量ベクトル、 \bar{x}_T は x の平均ベクトルである。

- この写像を、判別分析的な手法を用いて、利用者が与えたグルーピングにおいて異なるグループどうしの分散を最大に、同じグループ内の画像どうしの分散が最小になるように構成する。
- 利用者が検索のキーとして与えた画像から、画像特徴量ベクトルを抽出し、上で求めた写像によって、主観特徴空間上に変換し、類似画像を検索する

栗田らの方法と比べ、M+R法は、分けられたグループどうしに類似度を与えることができるので、類似性空間上で利用者が類似性が高いと判断したグループどうしは近く、類似性の低いと判断したグループどうしは遠くに配置できるため、利用者の観点をよりよく反映した空間を作ることができると考えられる。

5 実験

5.1 評価基準

システムの評価には、次の2つの指標を用いた。

検索成功率 テスト用の画像に対して、類似度の高い順に上位10個の画像を出力したとき、テスト用の画像と同じグループに含まれると判断される画像が1枚以上含まれている割合

分類正解率 テスト用の画像に対して類似度が最も高い画像が、テスト用の画像と同じグループに含まれると判断される割合

分類正解率の評価は、本来の類似画像検索システムの利用目的とは異なるが、M+R法の作る類似性空間のよさを測る基準の一つと考え、これを従来の分類手法の分類精度と比較した。

5.2 画像特徴量

本研究で用いる画像特徴量は、色の構成比 (histX)、局所的な画像の濃度 (grayscaleX)、RGB

についての局所的な濃度 (rgbX)、grayscaleX の隣接するブロックのコントラスト (contX) である。詳細は文献 [5] を参照されたい。

5.3 実験の目的

以下のような目的で実験を行った。

- M+R 法がうまく作用する条件を分析する
オーバーフィッティング² が起こる条件
学習のよさとサンプル数の関連
非関連属性³ に対する強さの評価
類似性空間の次元数との関連
- 検索成功率における栗田らの手法、画像特徴量空間での検索との比較
- 判別分析 [2]、C4.5 [4] との比較による分類器としての評価

5.4 実験の条件

5.4.1 データ・被験者

実験に用いた画像データは、国旗の画像 194 枚である。実験の被験者は、著者を含め 9 人で、著者以外の被験者には、システムについての詳細を知らせていない。

5.4.2 クロスバリデーション

実験はクロスバリデーション (相互検証法、交差検定) によって行った。手順は次のようになる。

まず、用意した全ての画像を、学習用とみなして、入力データを獲得する。そして、各グループの画像数の割合が、サンプル画像全体の場合とできるだけ近くなるように、いくつか (数は任意) のグループに分割する。このとき、あるグループをテスト画像とすると、それ以外のグループを、学習用データとみなして学習し、評価する。

² ここでは、学習に用いるサンプルに偏ったあてはめが行われたために、変換写像の一般性が失われてしまうことをいう

³ 利用者の分類の観点と関連がないと考えられる属性 (画像特徴量) のこと

5.4.3 類似性空間の次元数

類似性空間の次元数は、多次元尺度法において矛盾が最小となる、ストレス最小の次元数を用いた。

5.4.4 栗田らの方法の次元数

栗田らの手法において、主観特徴空間を構成するための線形写像は、判別分析における線形判別関数に相当する。栗田らは、この線形判別関数を、寄与率に関して閾値を設けることで、次元数を減らして計算コストの削減を図っているが、ここでは、比較のため、寄与率に閾値を設けず、線形判別関数の次元数を減らさずにそのまま用いた。

5.5 実験結果

実験結果の一部を、表 1~5 に示す (各表中の、画像特徴量空間とは、画像特徴量空間上での検索を示している)。また、M+R 法での検索例を、図 1~3 に示す。表 1 から、サンプル数に対して属性数が多くなると検索成功率は下がる、すなわち類似性空間への写像にオーバーフィッティングが生じていることがわかる。また、表 2 からは、サンプル画像数を多くすることで、非関連属性の影響を小さくできていることがわかる。これらの結果をもとに、画像特徴量の属性数と学習用のサンプル画像数の条件を以下のように設定した。

- 画像特徴量 : 非関連属性なしの場合は、gs4,cont4(40 属性)。非関連属性ありの場合は、gs4,cont4(40 属性) と hist8(8 属性)。
- サンプル画像数: 117

これらの条件の下で、検索成功率、分類正解率の測定を行った結果が、表 3 と表 4 である。

表 3 から、非関連属性の有無にかかわらず、栗田らの方法と比べ高い検索成功率となっていることがわかる。加えて、表 5 から、M+R 法は栗田らの方法に比べ、被験者ごとの検索成功率のばらつきが少ないことがわかる。

また、図 2 と 3 は、M+R 法でメキシコ国旗 (図 1) をキーとして検索した場合の上位 10 枚の画像を、ある 2 人の被験者について示したものである。図 2 の被験者はメキシコ国旗を「マークのある画

像」という観点でグルーピングしており、検索結果も縞模様やマークの位置にはかかわらず上位にマークのある画像が検索されている。それに対し図3の被験者はこれを「縦縞で中央にマークのある画像」という観点でグルーピングしており、検索結果もやはりその観点到った画像が多く検索されているといえよう。

画像特徴量空間での検索と比べた場合、M+R法は同程度の検索成功率である。しかし、M+R法で検索に用いる類似性空間の次元数は最大でも利用者の行うグルーピングのグループ数-1である。国旗データの場合、被験者のグルーピングのグループ数は、最大18、最小4であったから、類似性空間の次元数は、全てグループ数-1であったとしても、最大で17、最小で3となる。画像特徴量の属性数は、国旗データでは40属性であるから、類似性空間の次元数はこれと比べ最小でもおよそ $\frac{1}{2}$ 、最大でおよそ $\frac{1}{13}$ であり、検索にかかる計算時間の短縮をはかることができるといえる。

		属性数		
		21	40	96
サンプル数	39	0.718	0.513	0.410
	78	0.795	0.718	0.410
	117	0.846	0.821	0.564

表 1: 属性数、サンプル数を変動した場合の検索成功率 (グループ数 18)

		非関連属性		差
		あり	なし	
学習用	39	0.670	0.758	0.088
サンプル	78	0.768	0.814	0.046
画像数	117	0.829	0.824	0.005

表 2: M+R法で、非関連属性を含めた場合と、そうでない場合の検索成功率の比較

6 結び

6.1 本研究の貢献

我々はM+R法が優れていると考える点を次のように考える。

	M+R法	栗田らの方法	画像特徴量空間
非関連属性なし	0.836	0.668	0.882
非関連属性あり	0.814	0.688	0.891

表 3: 検索成功率の平均値

	M+R法	判別分析	C4.5
非関連属性なし	0.520	0.505	0.485
非関連属性あり	0.513	0.488	0.482

表 4: 分類正解率の平均値

	M+R法	栗田らの方法
非関連属性なし	0.051	0.152
非関連属性あり	0.059	0.151

表 5: 検索成功率の標準偏差



図 1: 検索例のキー画像 (メキシコ国旗)




図 2: 検索例 1




図 3: 検索例 2

1. 利用者が検索を行う際には、画像をそのまま与えるだけでよい。
2. 画像事例ベース自体に、検索のために人手により情報を追加したりする必要がない。

これらは、従来からあるキーワードを主体とした画像検索システムと比較して優位な点であるといえる。また、予備的実験の結果をもとに条件を設定して、実験を行った結果、さらに以下の結論を得た。

観点の変化に対する柔軟な学習 複数の被験者からの学習に対し、栗田らの方法と比べ、被験者ごとの検索成功率のばらつきがおよそ $\frac{1}{3}$ と少ない(表5)。これは利用者ごとの観点の変化をより柔軟に学習できていることを示す。

検索成功率の向上 栗田らの方法と比較し、検索成功率が平均で60パーセント台から80パーセント台に向上した(表3)。

計算時間の短縮 画像特徴量空間をそのまま検索に用いるのに比べ、検索に用いる空間が小さくてすむ。利用者の設定するグループ数によって、検索に用いる空間の次元数は、同程度の検索成功率を保ちながら、 $\frac{1}{2}$ から、最大で約 $\frac{1}{13}$ にまで減らすことができた。

非関連属性の影響 学習に用いるサンプルを増やすことにより、非関連属性の影響を小さくすることができた(表2)。

分類器としての性能 従来ある分類手法と比較しても同程度か、それより優れた結果が見られた(表4)。これは類似性空間のよさに関する一定の評価になるといえる。

6.2 今後の課題と発展

M+R法についての課題には次のようなものがあげられる。

- 実験の結果、多次元尺度法においてストレス最小となる次元数の空間が必ずしも最良の結果とはならないことがあった。

- 利用者にとっては10個以内の対象に類似度をつけることもけっして容易ではなく、学習にかかるコストが大きい。
- 多次元尺度法、多変量線形回帰モデルと同様の要求を満たす仕組みがあれば、それらを適用してみることも興味深い。

今後の発展としては、これらの課題を克服しつつ、M+R法を用いた画像事例ベース推論システムの構築が行われることが期待される。

謝辞

本研究について議論していただいた原口 誠教授、大久保 好章助手に感謝致します。また、マルチメディアを含む事例ベース推論の重要性について指摘していただいた(株)ドーシスの仲谷 善雄氏に感謝致します。

参考文献

- [1] J.B.Kruskal, M.Wish 著, 高根 芳雄訳, 人間科学の統計学I/多次元尺度法, 朝倉書店, 1980.
- [2] 塩谷 實, 統計ライブラリー/多変量解析概論, 朝倉書店, 1995.
- [3] 栗田 多喜夫, 下垣 弘行, 加藤 俊一, 主観的類似度に適応した画像検索, 情報処理学会論文誌, Vol.31, No.2, pp227-237, 1990.2.
- [4] J.Ross.Quinlan 著, 古川康一監訳, AIによるデータ解析, トッパン, 1995.
- [5] 中越 智哉, 画像事例ベースのための画像をキーとする類似検索手法の開発, 北海道大学大学院工学研究科修士論文, 1999.