

自然画像を対象とする ランキング学習に基づく質感認識の一手法

阿部 徹^{†1} 岡谷 貴之^{†1} 出口 光一郎^{†1}

本研究の目的は、物体表面の光沢感や透明感といった質感に関するいくつかの属性の尺度を画像から推定する方法を実現することである。自然画像を扱えるようにするため、特定の質感に関する属性について、2枚の画像間で人がその強弱を判断した情報を学習データとし、これを使ったランキング学習を行うことで、その属性の強弱を表現する関数を求める手法を提案する。Flickr Material Databaseに含まれる画像を用いて、このような質感に関する属性の比較情報を含むデータセットを生成し、これに提案手法を適用した。属性の強弱を表現した関数を、光沢感、透明感、なめらかさの3つの質感属性について学習し、得られた関数の性能を実験によって評価したところ、良好な結果を得た。さらにこの関数を、金属、ガラス、石といった材質を分類する問題に利用する簡単な実験を行い、その有効性を確認した。

A Method for Recognizing Surface Qualities from Natural Images based on Learning to Rank

TAKASHI ABE,^{†1} TAKAYUKI OKATANI^{†1}
and KOICHIRO DEGUCHI^{†1}

The goal of this research is to develop a method for recognizing the quantitative values of several attributes associated with surface qualities of an object, such as glossiness and transparency, from its image. To make it possible to deal with natural images, we propose to use for learning data a set of relative information representing which of a pair of images has a larger value in terms of a particular attribute, which is created by humans, and then to obtain a function representing the relative strengths of the attribute based on learning to rank. We create a data set containing such relative information for several attributes using the images from Flickr Material Database, and then applied our method to the created data set. For three attributes of glossiness, transparency, and smoothness, we learn the functions representing the relative strengths of these attributes. We present a few experimental results in which the learned functions show good performances in predicting relative relations between a given

pair of images. We also perform a preliminary experiment in which the learned functions are applied to the classification of materials, such as metals, glasses, and stones. The experimental results show the effectiveness of this approach.

1. はじめに

本稿では、画像から物体の質感を認識する問題を考える。質感とは、物体の—特に表面の—状態について人が感じ取る様々な感覚を、包括的に表す概念である。金属やガラス、プラスチックといった材質の違いと深い関係があるが、それだけでなく、表面の柔らかさや温度などの物理特性や、手触りなどの抽象的な感覚とも大いに関係する。人がこのような質感を感じ取れる能力は、日常生活で大きな役割を果たしていると考えられる。

人は視覚・触覚を中心とする五感で物の質感を捉えていると考えられるが、その仕組み、特に脳内での情報処理のあり方は今のところあまり分かっていない。また工学的にも、どうすれば実物らしく見える映像をコンピュータグラフィックスで合成できるかや、身の回りの工業製品の見栄えや使い心地を向上させるにはどうすべきかといった視点から、質感を考えることには高い価値がある。こうした動機から、近年、脳科学や心理学、工学などの異分野が協力して、質感の理解を目指す様々なアプローチが試みられている*1

本研究では、ある物体の画像1枚が与えられたとき、その物体の質感（にかかわる物体表面の状態）を認識する問題を考える。上述のように質感はきわめて抽象的な概念であるが、ここでは、質感の形成に寄与していると考えられる属性、例えば光沢感、透明感、なめらかさ、でこぼこ具合など、物体表面（場合によってはその内部）の状態を表す属性をいくつかピックアップし、これを認識の対象とする。本稿では、これらの属性を質感属性と呼ぶ。これら質感属性は一般に連続量を取り、同一条件下では、同じ物体は各質感属性について同じ強さを持つと考えられる。本稿では、これらいくつかの質感属性の強さ（尺度）を画像から推定する問題を考える。

このような質感属性の強さを、画像から認識する研究はこれまでにもある。Drorらは、学習画像を用いて画像特徴と質感属性の強さの関係を機械学習する方法を示し、一定の認識

^{†1} 東北大学
Tohoku University

*1 我が国では、文部科学省科研費新領域研究「質感脳情報学」が進行している。海外でも類似の研究プロジェクトが最近見られる。

精度を達成できることを示している¹⁾。

ただし、この研究では、認識の対象となる画像は、コンピュータグラフィクス (CG) によって合成したものをを用いていた。CG を使うことで、質感属性は表面反射モデルの物理パラメータなどに置き換え可能であり、定量的な定義が可能となる上、選んだ質感属性の強さを自由に変えた画像を作り出すことができ、極めて好都合であった。

一方、このように CG で合成した画像を用いることに伴う欠点はいくつかある。

一つは、単純な見えを持つ画像しか扱えないことである。既存研究では、個々の質感属性は、特定の (多くの場合、原始的な) 表面反射モデルの 1 パラメータと結び付けられることになる (例えば光沢度を 2 色性反射モデルの鏡面反射の強さに対応させるなど)。今や CG は非常に写実的な画像を生成できるようになっているが、それを可能にしているのは、光の反射に代表される光学的な物理現象を忠実にシミュレートすることであり、そうやって作られる物理モデルは年々複雑化している。個々の質感属性が、そのような複雑なモデルのどのパラメータと対応するかははっきりしないし、異なるモデル間でのそれらの対応は一層不透明となる。

これに関連したもう一つの欠点が、材質をまたいだ質感属性の関係を表現しにくいことである。先述の通り質感は材質と深い関係にある一方、材質を超越した概念であると考えられるのが自然である。例えば、光沢感や柔らかさ、手触りなどは、特定の材質について定義されるわけではなく、普遍的な概念である。CG で物理モデルのパラメータを制御して画像を合成する場合に、このような普遍性を扱えるかは疑問である。

さらにもう一つの欠点は、そうやって生み出された認識アルゴリズムが認識するものが、人が実際に感じているものと対応しない可能性のあることである。上述のように、質感はあくまで人が感じる感覚である。(少なくとも既存研究のやり方では) 認識アルゴリズムが認識しているのは CG の 1 パラメータに過ぎないと言える。むしろそのパラメータは人が選択したものであって質感属性と無関係ではないが、原理的には人の知覚と直接的な関係はないと言える。

以上の問題意識に基づいて、本研究では、自然画像を対象とした質感属性の認識を考える。自然画像の場合、CG のように、質感属性の (と関係すると思われる) 物理パラメータを直接変化させて画像サンプルを生成することはできない。代わりに、各画像に対し人が質感属性を与え、画像と質感属性の値のペアを大量に用意することで学習サンプルの集合を作ることが考えられる。しかしながら、このように質感属性の絶対値を回答者に求めるのはきわめて難しい。ある物体の画像を人に見せて、その光沢度を 0 から 100 の間で答えるよう

に指示しても、答えるのは困難である。それをどうにか行なったとしても、回答された質感属性の尺度をどのように正規化するかという問題が生じる。複数の画像に対してこの作業を行ううちに、回答者の尺度の基準がドリフトすることが考えられるし、別な回答者との関係を定めることも難しい。

そこで本研究では、各質感属性について、2 枚の画像をペアで提示し、その強弱を回答者に答えさせることで学習サンプルを生成し、こうして作られるサンプルの集合を使って質感属性の学習を行うことを考えた。具体的には、学習サンプルは例えば「画像 A は画像 B より光沢感が強い」という 2 枚の画像間の質感属性に関する比較情報を与える。このような比較情報の集合に対し、ランキング学習の手法を用いて質感属性を表現する関数を学習する。なお、質感属性の中には例えば「人工物かそうでない (= 自然物) か」のように、2 値で表現すべきものもあるが、本研究では連続量をとる質感属性のみを対象に、その比較情報を学習データとして与える方法を考える。(将来的には比較情報とこのような 2 値の質感属性の両方を扱えるようにする予定である。)

さらにこうして学習された質感属性関数を、材質認識に応用することを考えた。これは、材質のカテゴリーと質感属性間の強い相関を考えると、少ない数の質感属性の組み合わせで、材質の認識がある程度可能なのではないかという予想に基づく。また、その結果から、質感属性が低レベルな画像特徴と材質のカテゴリーをどの程度仲介し得るかを評価することも目的である。

2. 関連研究

質感の認識とつながりの深い研究として、テクスチャの画像認識、材質 (マテリアル) の画像認識の研究がある。

テクスチャの認識とは、主に統計的な性質に基づく濃淡パタンの類似性に基づき、与えられた画像がどの見本と同じかを同定したり、あるいは 1 枚の画像に対し同じ類似度を持つ領域を切り出すことである。代表的なものに、LBP(Local Binary Pattern) を用いた手法²⁾、多数のガボールフィルタを用いる手法³⁾ などがある。

材質の認識とは、文字通り画像からそこに写る物体を構成する材質を同定することである。大きく分けて 2 つのアプローチがあり、ひとつは物体の材質によって決まる表面反射特性 (例えば BRDF) を画像から推定する方法⁴⁾ で、もう一つは物体認識同様に、画像特徴を抽出しこれに基づく分類を行う方法である。

物体の見えは複数の要因—照明条件、物体の幾何形状および表面反射特性—が絡み合っ

決まるので、単一の画像から表面反射特性を求める前者のアプローチは基本的に困難さを伴うが、いくつかの制限を与えることでBRDFのパラメータを推定する手法が提案されている。後者のアプローチは、近年研究が開始されている。Liuらはそれまではつきりと定義されていなかった材質認識をテクスチャ認識とは独立した問題と位置づけ、ベンチマークのためのデータセットを公開するとともに、ベイズ推定の枠組で適切な画像特徴を選択し分類を行う手法を提案した⁵⁾。また、HuらはKernel Descriptorを用いた手法を提案している⁶⁾。

質感に関する研究は神経科学の分野でも盛んに行われている。Motoyoshiらは、画像の明るさや光沢感に対する人の知覚が輝度ヒストグラムの歪度に基づいていることを示した⁷⁾。Motoyoshiらはさらに、画像のハイライトと陰影の関係が透明感の知覚のための手がかりとなっていることを示している⁸⁾。Hiramatsuらは、人の脳における材質認識の情報処理は、脳の視覚野の広い範囲を使っていることを示した⁹⁾。これら神経科学の分野における知見は、工学的な応用を考える上でも大変示唆に富む。

また一般物体認識やシーンの認識において、認識対象となるカテゴリに複数の属性を与え、これを学習の省力化などに利用する研究が近年盛んである¹⁰⁾⁻¹²⁾。これらは本研究で考える質感属性と深いつながりがある。中でも本研究で主題としている、属性の相対的な比較情報を学習データとする方法は、物体認識のためにParikhらによって提案されたものである¹³⁾。未知カテゴリの認識等へ利用するという手法を提案した

3. ランキング学習による質感属性の学習

本節では、ある自然画像の集合から選んだ2枚の画像に対し、特定の質感属性に関する大小関係を与えた学習データが多数あるとき、この学習データセットから質感属性の尺度を表す関数を学習する方法について述べる。

自然画像の集合に含まれる画像*i*に対し、後述する方法で抽出される画像特徴を \mathbf{x}_i と書く。ある特定の質感属性について、自然画像の集合からランダムに選んだ2枚の画像ペアに対し、その質感属性の大小関係を人が判断し、それによって多数の画像ペアの間の比較情報集合 $\mathcal{O} = \{(\mathbf{x}_i, \mathbf{x}_j), \dots\}$ を生成する。表記 $(\mathbf{x}_i, \mathbf{x}_j)$ は、今考えている質感属性の強さに関して、画像*i*のほうが画像*j*より大きいことを表すとする。

このような \mathcal{O} が与えられたとき、その要素について

$$f(\mathbf{x}_i) > f(\mathbf{x}_j) \quad (1)$$

となるようなランキング関数 $f(\mathbf{x})$ を学習することが目的である。ただし、全ての $(\mathbf{x}_i, \mathbf{x}_j) \in \mathcal{O}$ について(1)式を満たすことは普通はないので、できるだけこれを満たすように学習を行う

ということである。このランキング関数 $f(\mathbf{x})$ は、質感属性の強い画像に対してより大きな出力を返すよう学習されるので、これを質感属性の強さを表す関数と考えることができる。以下、学習によって得たこの関数を質感属性関数と呼ぶことにする。

ランキング関数は線形関数でモデル化する。

$$f(\mathbf{x}) = \mathbf{w}^\top \mathbf{x}. \quad (2)$$

これにより、(1)式は

$$\mathbf{w}^\top \mathbf{x}_i - \mathbf{w}^\top \mathbf{x}_j = \mathbf{w}^\top (\mathbf{x}_i - \mathbf{x}_j) > 0$$

と書き換えられる。 \mathcal{O} の各要素についてこの不等式が成立するように \mathbf{w} を学習するというのは、 $\mathbf{x}' \equiv \mathbf{x}_i - \mathbf{x}_j$ と書き換えれば、線形識別器の学習と同じである。この学習のための方法として、L1正則化SVM(Support Vector Machine)を用いる。比較情報からランキング関数をSVMにより学習するという方法は、Ranking SVM¹⁴⁾と同じである。Ranking SVMは2サンプルの順序関係を学習データとして線形なランキング関数を学習する手法であり、2つの特徴の差を新たな特徴することでランキング学習を二値分類の学習におとしこみ、SVMにより学習するというものである。

ParikhらのRelative Attributes¹³⁾も同様に、SVMベースのランキング学習手法により画像の属性を学習している。彼らは $f(\mathbf{x}_i) > f(\mathbf{x}_j)$ という情報に加えて、「画像*i*と画像*j*のある属性は同じくらいである」という情報 $f(\mathbf{x}_i) = f(\mathbf{x}_j)$ も一緒に用いている。

一方我々は、大小関係で与えられた情報のみを使用し、このように等号で与えられる情報は使わない。これは、ある属性について、2画像の強弱を決めたい場合、その属性の強弱が同程度であるという場合もあるが、単に「どちらともいえない」という場合もあることによる。特に質感属性の場合、これに該当する場合が多い。このような場合、明らかに $f(\mathbf{x}_i) = f(\mathbf{x}_j)$ とするのは適切ではない。

4. 質感属性学習の評価

画像ペアとそれに与えた質感属性の強弱からなる学習サンプルの集合に対し、前節で説明した方法で学習される質感属性関数の精度を評価する実験を行った。

4.1 採用した質感属性と画像特徴

ここでは、「光沢感」「透明感」「なめらかさ」の3つの質感属性を考える。個々の質感属性に対し有効な画像特徴は、通常異なるため、事前の予備実験を経て質感属性ごとに使用する

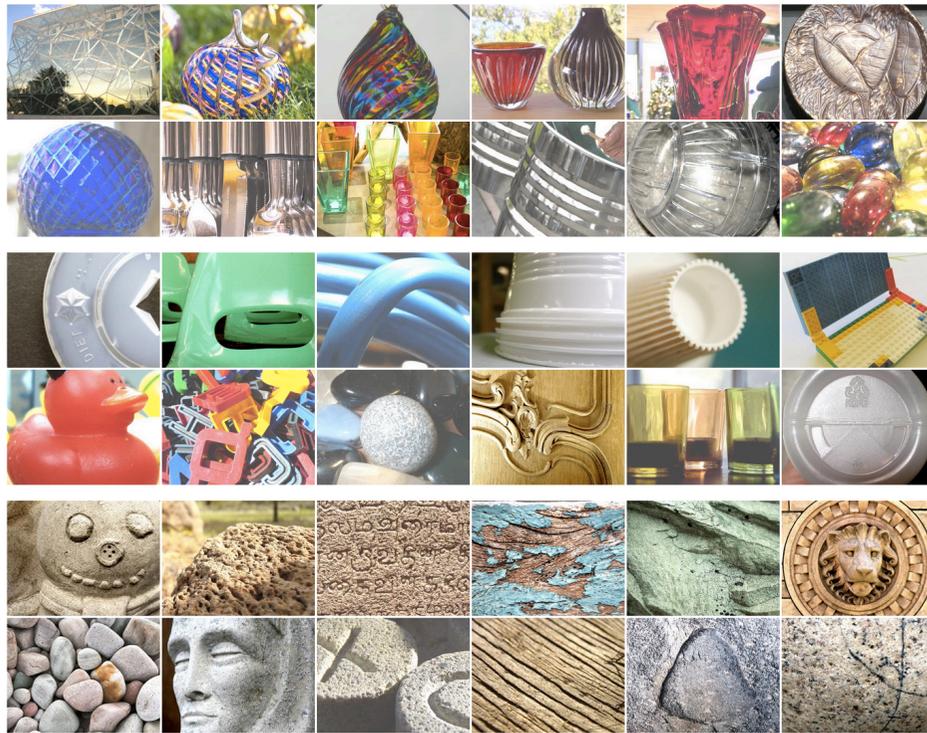


図 1 光沢感のランキング結果. (上段) 上位 12 枚 (中段) 中位 12 枚 (120 位~131 位) (下段) 下位 12 枚

る画像特徴を選んだ. 複数の画像特徴を利用する場合は, 特徴ベクトルを単純に結合する. 表 1 に, 各質感属性に対して使用する画像特徴を示す.

使用した画像特徴の詳細とその背景を以下簡単にまとめる.

SIFT-BOF

輝度画像から SIFT¹⁵⁾ を用いて特徴点とその特徴量を求めて, 通常の Bag-of-Features (BOF) の枠組で特徴ベクトルを生成する. SIFT と BOF の組み合わせは画像認識の様々な研究で用いられ, 良い成果を挙げってきた強力な特徴であり, 質感属性の認識においても有効である. これを踏まえて SIFT-BOF 特徴は, 3 つの質感属性全ての認識において使用する. 特に光沢感の強い物体のハイライトや, 物体の表面の荒さを捉えるのに向いている.

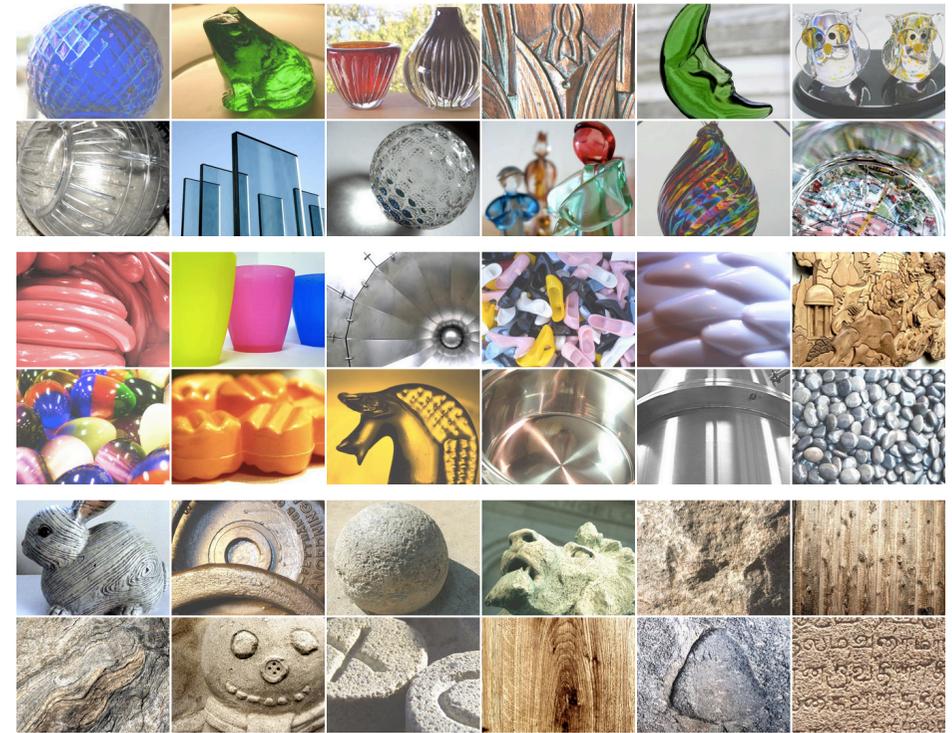


図 2 透明感のランキング結果. (上段) 上位 12 枚 (中段) 中位 12 枚 (120 位~131 位) (下段) 下位 12 枚

Color-BOF

RGB 画像から 3×3 の画像パッチをランダムにサンプリングし, 同様に BOF の枠組で画像特徴として用いる. 色の情報が質感の認識にどのように寄与するかに関してははっきりとした知見があるわけではない. しかし, 例えば透明感について考えると, 無色のガラスと色の付いたガラスはたとえ輝度が同じ場合でも, 無色のガラスのほうが透明感が強く感じられる傾向があると考えられる. このような予想に基づいて, 透明感の認識のみで Color-BOF 特徴を使用する.

4.2 実験の概要

ここでは, 自然画像のデータセットとして材質分類の問題で用いられている Flickr Material Database⁵⁾ (FMD) を使用した. FMD は Flickr から集められた, 10 カテゴリの材質

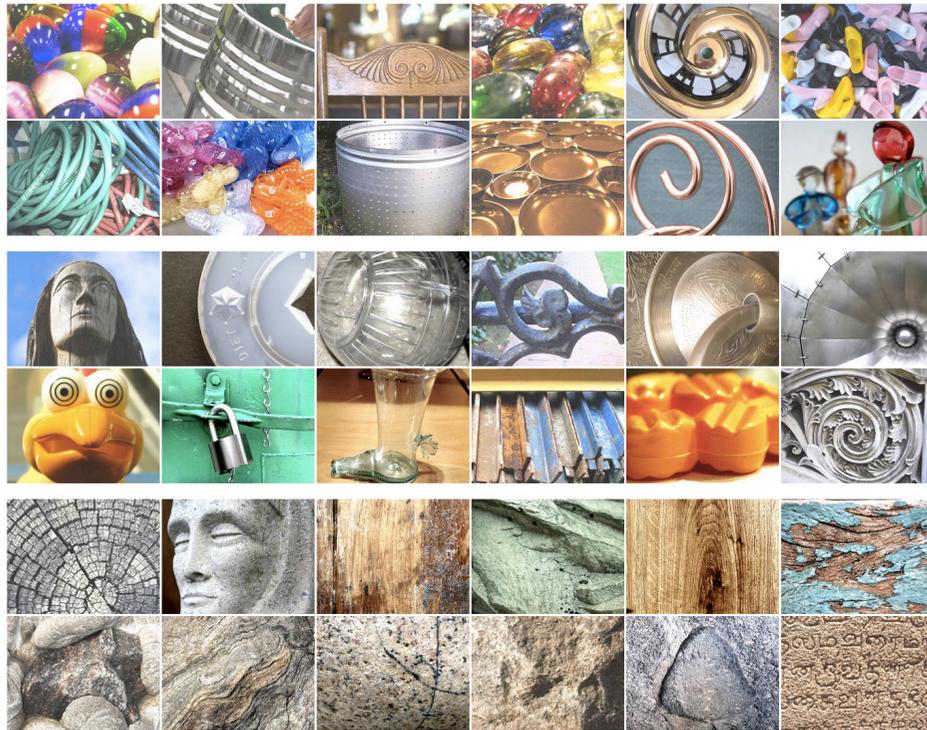


図 3 なめらかさのランキング結果. (上段) 上位 12 枚 (中段) 中位 12 枚 (120 位~131 位) (下段) 下位 12 枚

表 1 採用した質感属性とその認識に使用する画像特徴

質感属性	使用する画像特徴
光沢感	SIFT-BOF
透明感	SIFT-BOF, Color-BOF
なめらかさ	SIFT-BOF

の画像が各 100 枚ずつの合計 1000 枚の画像からなるデータセットである。本実験では、このうち金属、ガラス、プラスチック、石、木の 5 カテゴリーの画像、計 500 枚を用いた。FMD には画像上で対象物体と背景を分離するマスクが含まれており、これを使用して背景を除去する前処理を行っている。2 画像間の質感属性比較情報は図 4 に示す入力用のソフトウエ

アを使用して、(1) ランダムな 2 画像を回答者に提示し、(2) 指定した質感属性について左右どちらの画像が強いのか、あるいはどちらともいえないかを入力してもらうという手順で、各質感属性に対して約 1000 個のサンプルを得た (前節の ρ に相当)。500 枚の画像データセットを材質の各カテゴリごとに 50 枚ずつ二分し、250 枚ずつにわけ、一方を用いて質感属性学習を行い、もう一方の 250 枚の画像に対して、得られた質感属性関数によりランク付けを行いその精度を評価した。

4.3 実験結果

得られたランキング結果と与えた比較情報との一致率を表 2 に示す。一致率とはランク付け対象画像間に入力された比較情報のうち、得られたランキング結果と矛盾していないものの割合である。この表から、3 つの質感属性全てに関して一致率はチャンスレートの 0.5 を大きく上回っており、質感属性関数の学習に成功していることが分かる。

光沢感、透明感、なめらかさのランキングの中から上位、中位、下位の一部を抜粋したものを、それぞれ図 1、図 2、図 3 に示す。人の目から見てもほとんど違和感の無い結果が得られているが、いくつか問題のある結果も含まれている。例えば、透明感のランキングの 4 番目に、明らかに透明感の感じられない模様の彫られた木の画像が位置している。その一方で中位の画像の中に明らかに透明度の高いガラス製の馬の画像がある。上位の画像は透明感に加え多少のハイライトと凹凸から生じるエッジを持つという傾向があることから、ハイライトとエッジを持った模様の彫られた木が上位になり、なめらかな形でエッジが少なく照明の影響によりハイライトも少ないガラス製の馬は中位になったと推測される。これを改善するためには、学習サンプルの数をより増やすか、あるいは透明感の認識により効果的な画像特徴を使用するのが有効ではないかと考えている。

表 2 比較情報の正解率

質感属性	一致率
光沢感	0.78
透明感	0.81
なめらかさ	0.84

5. 質感認識の材質分類への応用

金属、ガラス、石といった物体の材質は、質感と非常に強い結びつきがある。そこで、質



図 4 質感属性比較情報入力のためのソフトウェア

感属性の張る空間上で材質分類ができる可能性について検討を行った。

5.1 分類手法

前節のようにして n 個の質感属性関数 $\{f_1, f_2, \dots, f_n\}$ が学習されたとする。画像 x の質感属性の張る空間への写像

$$z = (f_1(x), f_2(x), \dots, f_n(x)).$$

を考える。質感属性空間上で各材質 c の画像は正規分布に従って分布すると仮定すると、

$$P(z|c) = N(\mu_c, \Sigma_c)$$

$$P(c|z) = P(z|c)P(c)/P(z)$$

と与えられる。各材質の正規分布のパラメータ μ, Σ は、学習データを元に定める。このように定めたパラメータを用いて、テスト入力 z に対する分類結果 \hat{c} を

$$\hat{c} = \arg \max_c P(c|z) = \arg \max_c N(\mu_c, \Sigma_c)P(c)$$

のように定める。ここでは $P(c) = \text{const.}$ とする。

5.2 実験の概要

前節と同様に FMD のうち金属、ガラス、プラスチック、石、木の 5 カテゴリーの画像、計 500 枚を用いた。500 枚の画像データセットを各カテゴリ 50 枚ずつ計 250 枚ずつに二分し、交差検定により分類精度を測定した。用いた質感属性は同様に光沢感、透明感、なめらかさの 3 つである。また、比較対象として SIFT-BOF 特徴と最近傍探索による分類も行った。

5.3 実験結果

質感属性を用いた分類精度を表 3, SIFT-BOF 特徴と最近傍探索による分類精度を表 4 にそれぞれ示す。質感属性を用いた場合の方が精度は低いものの、質感属性は恣意的に選んだものである上、SIFT-BOF 特徴の 70 次元に比べて質感属性空間は 3 次元しかないこと、

また質感属性空間のサンプルの分布を単純なガウス分布で近似していることなどを考えると、十分優れた結果であるとも言える。

質感属性の数を増やせば結果は単純に改善できると思われる。また、前節同様に各質感属性の認識に用いる画像特徴をより強力なものとするだけでも推定精度は向上させられるだろう。

表 3 質感属性を用いた材質分類精度、平均精度 0.46

	金属	ガラス	プラスチック	木	石
金属	0.16	0.26	0.47	0.02	0.09
ガラス	0.08	0.66	0.26	0	0
プラスチック	0.04	0.11	0.85	0	0
木	0.24	0.01	0.30	0.15	0.30
石	0.18	0.03	0.19	0.11	0.49

表 4 SIFT-BOF 特徴と最近傍探索による材質分類精度、平均精度 0.55

	金属	ガラス	プラスチック	木	石
金属	0.32	0.29	0.17	0.14	0.08
ガラス	0.20	0.65	0.08	0.05	0.02
プラスチック	0.20	0.14	0.55	0.05	0.06
木	0.06	0.13	0.09	0.60	0.12
石	0.09	0.09	0.04	0.13	0.65

6. まとめ

本稿では、物体の質感を認識する問題、具体的には光沢感や透明感といった物体表面の状態を表す質感属性の強さを画像から推定する問題について考えた。

そのための手法として、各質感属性について、2 枚の画像ペアを提示し、その強弱を回答者に答えさせるという手順で生成した「画像 A は画像 B より光沢感が強い」といった質感属性に関する比較情報から、ランキング学習の手法を用いて画像の質感属性の強さを表現する関数を求める手法を提案した。

様々な材質の物体の画像で構成される Flickr Material Database を用いた実験により、光沢感、透明感、なめらかさの 3 つの質感属性に関して提案手法による質感属性の強さの予測

精度を調べ、良好な性能を示すことを確認した。さらに、学習された質感属性関数を金属、ガラス、石といった材質を分類する問題に利用することを検討した。わずか3つの質感属性しか用いていないにも関わらず、ある程度高い認識率を示した。

本稿では3つの質感属性を認識対象にしたが、今後は人間の視覚情報処理の知見等も参考にし、適切な質感属性とそれに対応する画像特徴を探し、より多くの質感属性を扱えるようにする必要があると考えている。また、質感情報を材質分類に利用する方法に関してよりよい枠組を検討したり、zero-shot learning などの応用方法について研究する。

参 考 文 献

- 1) R.O. Dror, E.H. Adelson, and A.S. Willsky. Recognition of surface reflectance properties from a single image under unknown real-world illumination. In *Proc. the Workshop on Identifying Objects Across Variations in Lighting at CVPR*, 2001.
- 2) T.Ojala, M.Pietikainen, and T.Maenpaa. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(7):971–987, 2002.
- 3) A.K. Jain and F.Farrokhnia. Unsupervised texture segmentation using gabor filters. *Pattern recognition*, 24(12):1167–1186, 1991.
- 4) P.Debevec. Digitizing the parthenon: Estimating surface reflectance properties of a complex scene under captured natural illumination. In *VMV*, 2004.
- 5) C. Liu, L. Sharan, E. H. Adelson, and R. Rosenholtz. Exploring features in a Bayesian framework for material recognition. In *Proc. CVPR*, 2010.
- 6) D.Hu, L.Bo, and X.Ren. Toward robust material recognition for everyday objects. In *Proc. BMVC*, pages 48.1–48.11, 2011.
- 7) I.Motoyoshi, S.Nishida, L.Sharan, and E.H. Adelson. Image statistics and the perception of surface qualities. *Nature*, 447(7141):206–209, 2007.
- 8) I.Motoyoshi. Highlight–shading relationship as a cue for the perception of translucent and transparent materials. *Journal of Vision*, 10(9), 2010.
- 9) C.Hiramatsu, N.Goda, and H.Komatsu. Transformation from image-based to perceptual representation of materials along the human ventral visual pathway. *NeuroImage*, 57(2):482–494, 2011.
- 10) A.Farhadi, I.Endres, D.Hoiem, and D.Forsyth. Describing objects by their attributes. In *Proc. CVPR*, pages 1778–1785. IEEE, 2009.
- 11) C.H. Lampert, H.Nickisch, and S.Harmeling. Learning to detect unseen object classes by between-class attribute transfer. In *Proc. CVPR*, pages 951–958, 2009.
- 12) Y. Wang and G.Mori. A discriminative latent model of object classes and attributes. In *ECCV*, 2010.
- 13) D.Parikh and K.Grauman. Relative Attributes. In *Proc. ICCV*, 2011.
- 14) R.Herbrich, T.Graepel, and K.Obermayer. Large margin rank boundaries for ordinal regression. In *Advances in Large Margin Classifiers*, pages 115–132. MIT Press, 2000.
- 15) D.G. Lowe. Object recognition from local scale-invariant features. In *Proc. ICCV*, volume2, pages 1150–1157. Ieee, 1999.