

# テクスチャ特徴量を用いた瓦礫構成物の種別に関する検討

## Material Identification by Using Image Texture Features Suitable for Objects in Rubble

○松本廣一郎 田代 治之 正 山崎 公俊 (信州大)

Koichiro MATSUMOTO, Haruyuki TASHIRO, Kimitoshi YAMAZAKI, kyamazaki@shinshu-u.ac.jp

This paper describes material identification suitable for objects in rubble. We focus on the difference of surface appearance for the material identification. We applied texture-based features: filter banks, LBP, and edge histograms. In proof experiments, we used 10 kinds of objects selected in reference to building materials, interior decoration, and objects in the indoor. The results for 7 of 10 kinds of objects showed high success rate.

**Key Words:** Material identification, image texture, disaster environment.

### 1 はじめに

倒壊家屋などの被災環境で探索活動をおこなう場合、まず、その環境を理解する必要がある。それには高度な認識能力が必要となるため、探索活動の多くは人間に頼っているのが現状である。しかしながら、探索者が被災環境へ直接入っていくことは危険な場合がある。そのため、そのような環境へ移動体を投入し、それを遠隔から操作することで情報収集をおこなうための研究開発が進められている。

本研究の目的は、倒壊した建物の内部に移動体を投入することを想定し、その移動体によって撮影される画像から、環境の構成物とそれらの状態を把握することである。例えば、目前に散らばる瓦礫に対して、木、コンクリート、布などの発見と種別をおこないたい。それらの情報は、遠隔操作者が周囲環境の構造を効率的に把握したり、探索対象のような異質な部分をいち早く検出するための基礎処理になると期待できる。さらに、瓦礫の材質や汚れの度合いなどを定量化することができれば、それらの上へ移動体が移動した際の滑りや崩れの起きやすさを推定するといった展開も期待できる。

瓦礫の種別に対しては、画像のセグメンテーションと分類が研究課題となる。本研究と近い環境を対象とした従来研究では、屋外画像に対する手法が多く提案されている。Zhang ら [1] による KNN-MRF マッチングを用いた画像への意味づけ手法や、Cheng ら [2] によるスーパーピクセルベースの領域分割手法、Shotton ら [3] によるテクストマップを用いた分類手法などがある。これらの研究では、比較的広い空間で撮影した画像対象としており、倒壊家屋へもぐりこんだような状況の撮影画像は想定していない。一方で、我々の研究グループでも、森林環境や瓦礫環境でのカテゴリ識別に取り組んでいる [4][5]。このうち文献 [4] は本研究の目的に近いが、そこではブレやボケが含まれる画像列を対象としており、滑りやすさや崩れやすさの推定へつながるような精細なテクスチャ情報処理はおこなわれていない。

本稿では、木板やレンガ、布などの検出と種別の試みについて報告する。比較的明瞭な画像が撮影できることを前提として、画像テクスチャの違いを種別の手掛かりとしたときに、有効に機能する画像処理手法と特徴量記述について検討をおこなう。

### 2 検討課題と検証方法

#### 2.1 撮影対象と撮影方法

対象環境が倒壊家屋等であることから、建材や内装に使用されるものや室内に配置される物体などを参考にし、10種類の対象物を選定した。対象物の内訳は、コンクリートブロック (concrete block)、レンガ (brick)、MDF 材 (MDF)、木板 (wood)、透明アクリル板 (acrylic)、アルミ板 (aluminum)、ダンボール (cardboard)、雑巾 (dustcloth)、タオル (チェック柄) (check pattern towel)、半透明のビニール袋 (plastic bag) である。これらの物体を図 1 に示す。




Fig.1 Target Objects




Fig.2 Shooting Environment

対象物の撮影のため、図 2 に示す箱型の撮影場を作成した。これは、倒壊した建物に見られる狭い領域を模したものである。撮影では、奥壁から 130[mm] の位置に対象物の撮影面がくるように物体を配置した。そして、撮影面からカメラまでの距離を様々に変更し撮影を行い、距離に応じた表面性状の見えの違いを考慮

した検討をおこなえるようにした。撮影に用いたカメラは、最大解像度 2048 × 1536 ピクセル（有効画素数 320 万画素）であるが、実験には、VGA（640 × 480 pixel）サイズに縮小したカラー画像を利用した。

## 2.2 指定画像領域に対する種別

基礎課題として、隣接画素の違いに着目した特徴量を用いて、対象物の種別を行う。カメラと物体の距離を 200[mm] とし、撮影面の角度を 0[deg] に固定して撮影をおこなったものを基準画像とする。基準画像に対し、各対象物ごとに人手で 5 種類の注目領域を指定し、その部分に関する特徴量を求める。一方で、検証用に撮影した画像でも同様の手順をおこない、基準画像との間で特徴量を比較することにより類似度を評価する。

検証のための画像撮影では、カメラと対象物の距離を 200[mm] に固定し、撮影面の角度を ± 60[deg] の範囲で 10[deg] 刻みで変更した。各対象物で各角度ごとに 10 枚ずつ撮影を行い、総数 130 枚の画像を取得する。一方で、災害現場では物体が水や泥で汚れている状況も存在すると考えられるため、同じ材質の物体を複数用意し、水や泥で汚した後、同様の比較を行う。そして、それらの物体の比較結果から以降のような手段で材料識別を行うべきかを考察する。

## 2.3 グリッドベースでの種別

発展的課題として、より複雑な環境への対応可能性を調べるため、画像の局所領域ごとに算出した特徴量を用いて種別性能の調査をおこなう。この方式によれば、画像をグリッドに区切り、各グリッドごとに識別を行うことで、対象物の面の大きさや形状なども推定可能になる。

画像撮影においては、10 種類の対象物のそれぞれについて、距離や角度を様々に変えて撮影をおこなった。カメラと物体の距離は、300[mm]、400[mm]、500[mm] の 3 種類で撮影し、撮影面に対する物体の角度は ± 20[deg] の範囲で無作為に変更した。撮影した画像は物体及び距離ごとに 50 枚ずつ撮影し、総数 1500 枚の画像を取得した。

これらの画像のうち一部を抽出し、学習用画像とした。学習用画像に対して多数の矩形領域を設定し、それらから求めた特徴量に対して教師あり機械学習を適用し、多クラス識別器を構成した。

検証実験では、学習に用いたいくつかの画像を入力として、それをグリッドに分けたのち、各グリッドごとに種別をおこなった。その結果から特徴量の性能を評価した。

## 3 手法の選定

表面性状の異なるいくつかの物体をカメラで撮影すると、それらの違いは画像テクスチャの違いとして現れると期待される。同様の着眼により、テクスチャのふるまいに着目した様々な画像特徴量が従来から提案されている。本研究では、Local Binary Pattern(LBP)[6] やフィルタバンクの利用を検討する。なお、単一の特徴量記述では様々な物体に対応することが難しい場合があるため、単一の特徴量だけでなく、複数の特徴量の組み合わせも検討する。

LBP では、注目画素とその周囲の画素の画素値の関係性から、出力画像の画素値を決定する。従来から様々な方式が提案されており、本研究では以下の三種類の方法を用いた。

- OLBP: 注目画素の画素値と周囲の画素の画素値を比べる事で、出力画像の画素値を決定する。
- ELBP: ある局所領域の中央を中心とし、半径 1px ほどの円を考える。円と円に接する周囲の画素の中央との距離に応じて周囲の画素の画素値に重みづけを行い、それらを全ての合計値を求める。この合計値と注目画素の画素値を比較し、出力画像の画素値を決定する。
- VLBP: ELBP と同様に重みづけ後の合計値を算出しておく。一方で、撮影画像と同じサイズで画素値が 0 の 3 枚の空のマスクを用意する。1 枚目のマスクに重みづけ合計値を代入した後、1 枚目と 2 枚目のマスクでお互いの画素値を考慮した加算を行い、3 枚目では重みづけ合計値、2 枚目のマスクの画素値を考慮した加算を行う。これを周囲の画素の数だけ繰り返し、最後に 3 枚目のマスクの画素値と周囲の画素数を考慮して出力画像の画素値を決定する。

このほかに、画像の局所領域での輝度変化を利用する方法を二種類えらんだ。一つ目は、様々な大きさを持つフィルタカーネルを用いて入力画像に畳み込み積分をおこない、最も大きな濃度勾配値が得られた時のフィルタの分散値から、出力画像の画素値を決める方法である。以後、この方式を magnitude と称する。二つ目は、検出したい勾配の向きを様々に変えたフィルタカーネルを用いて入力画像に畳み込み積分をおこない、最も大きな値を示したときの勾配方向によって、出力画像の画素値を決める方法である。以後、この方式を orientation と称する。

また、フィルタバンクについては、別テーマにおける事前検討 [5] より、比較的高い効果が見込まれる Leung-Malik(LML)[7] と YI[8] を選定した。これらの他に、素材表面の色情報を  $L^*a^*b^*$  表色系に変換したもの (LAB) も一つの特徴量として扱う。

## 4 検証結果

### 4.1 指定画像領域に対する種別

撮影画像から、対象物が映り込んだ領域を手で指定し、その領域に対して物体種別を行った。識別に用いた学習データとして、領域内の画像を 5 種類の画像処理によって表面性状の特徴量を明確に示した画像を作成し、対象の画素値と対応する画素数を計算し領域内の全画素数で割ることで、領域内の面積に影響されない正規化したヒストグラムデータを作成する。物体の材質判定の際、撮影画像も同じようにヒストグラムデータを作成し、学習データと比較する。

ヒストグラムの類似度を算出する手法として以下の手法を適用する。

- Bhattacharyya 距離 :  
ある 2 つのヒストグラム  $H_1 \cdot H_2$  を確率分布で計算し、その類似性を測る距離である。Bhattacharyya 距離は以下の (1) 式で計算を行い、比較結果を  $d(H_1, H_2)$  で表す。

$$d(H_1, H_2) = \sqrt{1 - \frac{\sum_{i=0}^{255} \sqrt{H_1(i)H_2(i)}}{\sqrt{\sum_i H_1(i) \sum_i H_2(i)}}} \quad (1)$$

$d(H_1, H_2)$  は 0.00~1.00 までの値を取り、ヒストグラム  $H_1, H_2$  が完全一致している場合 0.00 の値を示す。

- 明度値の正規化 :  
ある 2 つのヒストグラムデータ  $H_1 \cdot H_2$  を大きさを計算し、その類似性を測る手法である。正規化は以下の (2) 式で計算を行い、比較結果を  $d(H_1, H_2)$  で表す。

$$d(H_1, H_2) = \sqrt{\sum_{i=0}^{255} (H_1(i) - H_2(i))^2} \quad (2)$$

ヒストグラム  $H_1, H_2$  が完全に一致している場合  $d(H_1, H_2)$  の値は 0.00 となる。

上記の手法を用いて撮影画像から得たヒストグラムデータを、特徴量ごとに材料 10 種類の学習データと比較し、学習データから最も撮影画像に類似していると思われるデータを持つ材料を選定する。本実験では、物体を撮影した際に、撮影した物体の材質が学習データから選定された材料と一致した割合を Bhattacharyya 距離・明度値の正規化で各々計算を行い、計算結果の平均を取った値をある物体・角度における材質識別率として記録する。以上の条件で材質識別実験を行った結果のうち、角度 0[deg] の結果のみをまとめたデータを図 3 に示す。

実験の結果、brick·dustcloth·check pattern towel は ± 20[deg] の範囲で識別率が高く、特に concreteblock·wood·acrylic·cardboard はどの角度でも認識率が高かった。ただし、magnitude は acrylic, orientation は wood で高い認識率を示したが、他の物体ではほぼ識別不可能であった。逆に、plasticbag·aluminum は特定の角度以外では、認識率が低い結果となった。また、cardboard と似た色合い・表面性状を持つ MDF も認識率が低かった。これらの傾向は、角度を 0[deg] に固定した図 3 でも確認できる。

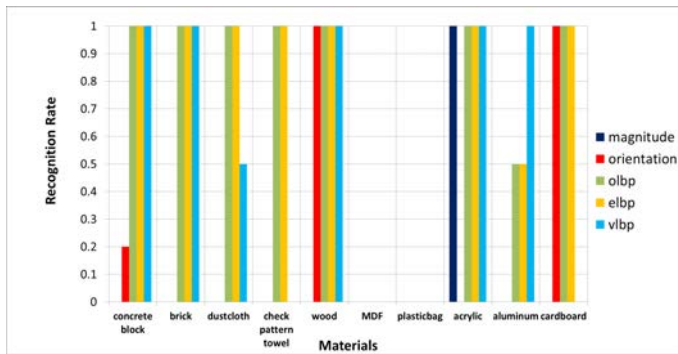


Fig.3 The comparison result(0[deg] only)

以上の結果から物体の材質認識において、光の反射による明暗の違いが顕著に出ると識別結果に大きく悪影響を及ぼすことが考えられる。また、似た配色と表面性状を持つ物体は、分類が困難である事も考えられる。

一方で、本実験ではもう一つ、同じ材質で水や泥を表面に付着させた材料を別に用意し、明度値の正規化による比較実験を行った。今回は最初の実験で認識率の高かった物体の中から concreteblock・brick・dustcloth・checkpatterntowel のみを用いて、図4に示す通り、水で濡らした物体・泥を付着させた物体を用意した。

同じ材質の物体同士で比較を行うことで得られた結果を図5に示す。この結果から、VLBPに関して concreteblock と checkpatterntowel で泥付き物体と他の物体との比較において高い値を示したが、全体を通して水や泥に関係なくほぼ一定の比較結果となる傾向がみられた。この結果から、同じ材質の物体でも、通常の物体と水濡れの物体・泥付きの物は別の種類の物体である事は明確であるが、通常物体での識別結果に、一定の補正值を加える処理を施すことで、同じ物体として識別可能であると考えられる。

#### 4.2 グリッドベースでの種別実験

本実験では、2.3節で述べた課題に対し、グリッド毎に物体識別をする実験を行った。実験は、取得した50枚の画像からいくつかの画像を選択し識別を行った。画像は各物体に付き、距離ごとに5枚ずつ選択し、計150枚の画像を用いた。

各特徴量を用いた分類の識別率の定義イメージを図6に示す。識別率はグリッドに区切られたテスト画像において物体領域に存在する各グリッドが、対象物体のみで占められているグリッド領域を対象領域とし、対象領域中の正解グリッド数の割合で定義した。図中の赤色領域が対象物体、斜線部が対象グリッド領域、黄色グリッドが識別成功グリッド、水色及び黄緑色が識別失敗グリッドである。

物体毎の各特徴量の識別率を図8に示す。この結果から、特徴量を組み合わせる場合の方が単一の特徴量を用いた場合と比較して識別率が高い傾向にある事がわかる。特徴量を組み合わせる手法に関して、YI+LAB と YI+LML+LAB は識別結果として似た傾向を示している。一方で LML+LAB は brick 以外では、識




Fig.4 Situation of water,soil

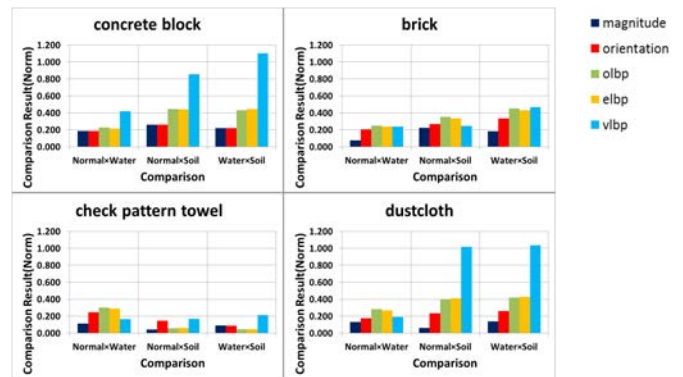


Fig.5 The comparison result of the water,soil




Fig.6 Recognition Rate Definition

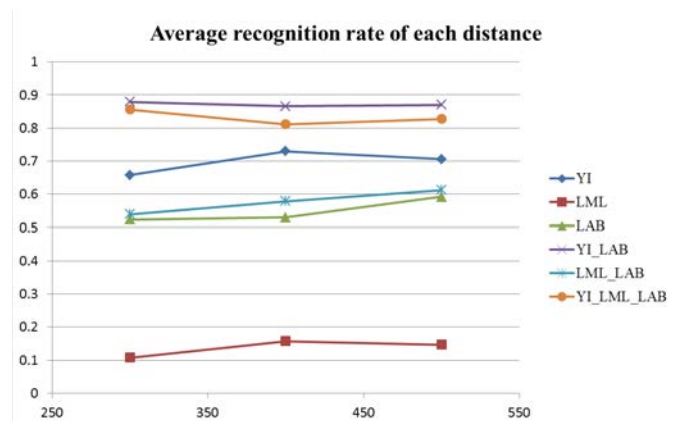


Fig.7 Average Recognition Rate of Each Distance

別率が低い。これは LML 単体の識別率の低さが影響していると考えられる。

特徴量を組み合わせる手法でも、cardboard と MDF は識別率が低かった。これらは MDF が cardboard に、cardboard が MDF に誤認されたグリッドが多かった。この誤認の理由としてダンボールと MDF 材の表面性状が似ていることが原因と考えられ、光の当たり方により見え方が変わってしまった事で MDF と cardboard の混同が発生したと考えられる。このことから、いずれの特徴量でも識別結果が光に大きく左右されてしまうため、学習において明暗を考慮したデータを用いるなどの対策を講ずる必要がある。

このことから、物体識別において用いる特徴量の組み合わせとして YI+LAB が適していると考えられる。

続いて、各距離ごとの平均識別率の結果を図7に示す。ここでは、距離ごとに全物体のそれぞれの特徴量の識別率を平均し




Fig.8 Object Identification Success Rate

た結果を比較した。YI, LML, LAB, 及び LM+LAB は距離が遠くなるほど識別率が向上する傾向が見られ、YI+LML+LAB, YI+LAB は距離が近い方が識別率が高い傾向が見られた。

## 5 まとめ

本研究では、倒壊した内部に投入される移動体に搭載する物体識別手法について検討した。本稿では、建材や内装及び室内に配置されると考えられる物体を参考に 10 種類の物体を選定し、これらの識別を行った。識別には、物体の表面性状に着目し、これらを画像テクスチャの違いとして捉え、特徴量を用いた手法について提案した。

提案手法は、LBP を用いる手法とフィルタバンクを用いる手法の 2 つがあり、それぞれに対して検証実験を行った。

LBP を用いる手法の実験では、10 種類の物体に対し画像単位で比較を行う事で識別できるか検証した。実験の結果、コンクリートブロック、レンガ、木板、雑巾、タオル（チェック柄）、ダンボール、アクリル板は、光の影響によらず高い識別率で識別可能である事が確認された。一方で、半透明のビニール袋、アルミ板、MDF 材は識別率が低かった。このことから、鏡面光沢部分や半透明部分を持つ物体や、表面性状と色情報が非常に似ている物体は光の当たり方に影響を受ける事で、識別が困難になるという結果を得た。また、物体表面を水や泥で汚染した実験では、汚染による表面性状の変化に応じて識別率が変化する事が確認され、汚染が激しくない物体ならば識別可能であるという結果が得られた。

フィルタバンクを用いる手法の実験では、選定した物体の画像をグリッド状に区切り、各グリッド毎に識別を行った。実験の結果、単一の特徴量を用いて識別を行うよりも、いくつかの特徴量を組み合わせて識別を行う方が識別率が高いという結果が得られた。また、特徴量の組み合わせにおいて、識別率が低い特徴量を組み合わせてしまうと識別率が低下する事が確認された。実験により、YI+LAB の組み合わせは識別率が高く、どの距離でも安定していることから、この特徴量の組み合わせが物体識別に用いる特徴量の組み合わせとして有効である事が確認された。

本稿における実験により、2 つの提案手法では光による識別率低下の影響が確認された。このことから、光の影響への対策が必要となる。また、提案手法の識別精度向上も今後の展望として挙げられる。

## 謝辞

本研究は内閣府 ImPACT の補助を受けたものである。

## 参考文献

[1] H. Zhang, J. Xiao and L. Quan: "Supervised label transfer for semantic segmentation of street scenes," in Proc. of the 11th European conference on Computer Vision, pp. 561 - 574, 2010.

[2] C. Cheng, C. Chen, D. Page and M. Abidi: "Outdoor Scene Image Segmentation Based on Background Recognition and Perceptual Organization," IEEE Trans. on Image Processing, pp. 1007 - 1019, 2012.

[3] J. Shotton, J. Winn, C. Rother, and A. Criminisi: "Textonboost for image understanding: Multi-class object recognition and segmentation by jointly modeling texture, layout, and context," Int. J. Computer Vision, vol. 81, no. 1, pp. 2 - 23, Jan. 2009.

[4] S. Arnold, K. Yamazaki: "Patch-wise Object Recognition for a Mobile Robot by means of a Convolutional Neural Network," 第 33 回日本ロボット学会学術講演会, 講演番号 2B1-04, 2015

[5] 山崎:「テクスチャと色情報を用いた森林画像の領域分割と種別」第 21 回ロボティクスシンポジウム, 2016.

[6] DC. He and L. Wang, "Texture Unit, Texture Spectrum, And Texture Analysis, Geoscience and Remote Sensing," IEEE Transactions on, vol. 28, pp. 509 - 512, 1990.

[7] T. Leung and J. Malik: "Representing and recognizing the visual appearance of materials using three-dimensional textons," International Journal of Computer Vision, Vol. 43, No. 1, pp. 29 - 44, 2001.

[8] 山崎, 稲葉:「布地, しわ, 布の折れ重なりに着目した画像特徴量による無造作に置かれた布製品の個体識別」, 計測自動制御学会論文集, Vol.49, No.7, pp. 661-669, 2013.