画像局所特徴による対応点マッチングとその応用に関する研究

西村　孝　　指導教授：藤吉 弘亘

1.はじめに

特定物体認識では，画像変化に頑健であるだけでなく，リアルタイム処理が重要とされている．Lepetit 等によって提案された Randomized Trees を用いたキーポイントマッチング [1] は高精度かつリアルタイムを実現している．しかし，画像の見えの変化が強くなると対応点が取れないという問題点がある．そこで，本研究では，Randomized Trees を 2 段階に構築し入力画像の画像変化を分類することで，アフィン変換に頑健であり高速な対応点マッチング手法を提案する．

2.Randomized Trees によるキーポイント分類

Randomized Trees を用いたキーポイント分類手法の詳細を以下に述べる．

2.1 決定木の構築

始めに，テンプレートからキーポイントを検出し，アフィン変換に頑健なキーポイントを取捨選択する．複数のアフィンパラメータでアフィン変換を行い，すべてのアフィン変換画像でキーポイントを検出する．複数のアフィン変換画像で多く検出したキーポイントのみを選択する．次に，キーポイントを検出した全てのアフィン変換画像からキーポイントを中心とした 32 × 32 のパッチを作成してサブセットに分ける．決定木は 1 つのサブセットから構築する．

・決定木

決定木 $T = (T_1, \cdots, T_L)$ は分岐点（ノード）とノードの末端（リーフノード）から構成される．ノードには子ノードに分岐するための条件（特徴量）が記述されている．ノードとその分岐条件は事前に作成され，ノードの階層の数は事前に決められている．

・ノード

ノードの特徴量は，キーポイントを中心としたパッチ内の 2 点のピクセル $\mathbf{m}_1$ と $\mathbf{m}_2$ の輝度差を特徴量とする．

$$C_2(\mathbf{m}_1, \mathbf{m}_2) = \begin{cases} \texttt{left} & \texttt{If } I_\sigma(\mathbf{P}, \mathbf{m}_1) \leq I_\sigma(\mathbf{P}, \mathbf{m}_2) \\ \texttt{right} & \texttt{otherwise} \end{cases}$$

$I_\sigma(\mathbf{P}, \mathbf{m})$ は，注目画素 $\mathbf{m}$ のパッチ $\mathbf{P}$ の輝度値である．この特徴は 2 点の輝度レベルの差を見ているので，影等の影響は受けるが，照明変化に頑健な傾向にある．以上に示す特徴量により子ノードへの分岐が決定する．

・リーフノード

リーフノードには，テンプレートの各キーポイントがどれくらいたどり着いたのかを示す確率分布 $p_{\eta(T_l,\mathbf{P})}(Y(\mathbf{P}) = c)$ が格納されている．$\eta(T_l, \mathbf{P})$ は，入力パッチ $\mathbf{P}$ のたどり着いた木 T_l のリーフノードであり，c はテンプレートのキーポイントの種類を示す．次に，決定木を用いてキーポイントの分類を行う．

2.2 キーポイント分類

全てのサブセットから構築した決定木群 $T = (T_1, \cdots, T_L)$ によるキーポイントの分類の流れを図 1 に示す．L は決定木の数を示す．　入力画像からキーポイントを検出し，

図 1：キーポイントの分類

各キーポイントから 32 × 32 のパッチを作成する．キーポイントのパッチを決定木に入れることでリーフノードの確率分布 $p_{\eta(T_l,\mathbf{P})}(Y(\mathbf{P}) = c)$ に基づいてテンプレートのキーポイントに分類する．分類は，入力パッチ $\mathbf{P}$ がたどり着いた木 $T = (T_1, \cdots, T_L)$ のリーフノードの確率分布 $p_{\eta(T_l,\mathbf{P})}(Y(\mathbf{P}) = c)$ の平均を次式より求め，確率の高いキーポイント c に分類する．

$$\hat{Y}(\mathbf{P}) = \arg\max_c \frac{1}{L} \sum_{l=1}^{L} p_{\eta(T_l,\mathbf{P})}(Y(\mathbf{P}) = c)$$

3.提案手法：2 段階の Randomized Trees を用いたキーポイント分類

従来手法である Randomized Trees は，すべてのアフィン変換を含んだ学習画像で決定木を構築する．そのため，同一のキーポイントであっても見えの変化すべてを決定木 1 つで表現するのは困難である．そこで，提案手法では 2 段階に決定木を構築する．1 段階目に入力画像のアフィンパラメータの分類を行い，2 段階目では，1 段階目で推定したアフィンパラメータに近い画像変化で学習した決定木によりキーポイントの分類を行う．以下に決定木の構築方法を述べる．処理の流れを図 2 に示す．

図 2：2 段階の決定木によるキーポイントの分類

3.1 アフィンパラメータのクラスタリング

1 段階目の決定木群 $T1$ でアフィンパラメータの推定を行うため，画像変換後の見えの近いアフィンパラメータをクラスタリングする必要がある．パラメータでクラスタリングすると，回転における周期性が表現できないため，画像変換したパッチ画像を特徴量として k-means によりクラスタリングする．クラスタリングの流れを図 3 に示す．特徴量は，テンプレートのキーポイントを中心とする 32

図 3：アフィンパラメータのクラスタリング

× 32 のパッチ全てをアフィンパラメータごとに結合した輝度値を用いる．こうすることで，見た目で近い画像変化をクラスタリングできる．次に，クラスタリング結果を学習画像のパッチにラベルとして与えて，アフィンクラスの頻度を決定木で学習する方法を下記に示す．

3.2 1 段階目の決定木の構築

パッチのクラスタリング結果よりラベル付けしたアフィンクラスとパッチの輝度値を用いて決定木群 $T1 = (T1_1, \cdots, T1_{L_1})$ を構築する．L_1 は決定木の数を示す．キーポイントのパッチの輝度値で決定木のリーフノードを決定し，パッチのアフィンクラスの頻度を記憶する．こうすることで，入力画像のパッチから画像のアフィンクラスを分類することが可能となる．次に，2 段階目の決定木の構築方法を下記に示す．

3.3 2 段階目の決定木の構築

各アフィンクラスに所属するデータを用いてクラスごとの決定木群の集まり $T2 = (T2_1, \cdots, T2_K)$ を構築する．K はアフィンクラスの個数を示す．クラスごとの決定木群 $T2_K = (T2_{K,1}, \cdots, T2_{K,L_2})$ を構築することにより，見えの変化が近い学習画像で決定木群を構築できる．L_2 は決定木の数を示す．サブセットの学習画像はアフィンクラスに所属するデータから作成する．各クラスにおける決定木の構築方法やノードの特徴量は，Randomized Trees と同様である．下記に，構築した 2 段階の決定木を用いたキーポイント分類手法を述べる．

3.4 キーポイントの分類

1 段階目の決定木群 $T1$ でパッチのアフィンクラス Ac をパッチの輝度値を用いて分類する．次に，分類したアフィンクラス毎に Ac の 2 段階目である決定木群 $T2_{Ac}$ によりキーポイントを分類する．アフィンクラス Ac の分類は，次式に示すように，入力パッチ $\mathbf{P}$ がたどり着いた木 $T1 = (T1_1, \cdots, T1_{L_1})$ のリーフノードの確率分布 $p_{\eta(T1_l,\mathbf{A})}(Y(\mathbf{A}) = Ac)$ の平均を求め，しき値 th を超えるアフィンクラス Ac を抽出する．

$$G(Ac) = \begin{cases} 1 \ \texttt{If} \ \frac{1}{L_1}\sum_{l=1}^{L_1} p_{\eta(T1_l,\mathbf{A})}(Y(\mathbf{A}) = Ac) > th \\ 0 \ \texttt{otherwise} \end{cases}$$

2 段階目では，アフィンクラスごとに作成した決定木群の集まり $T2 = (T2_1, \cdots, T2_K)$ の中から 1 段階目の決定木で分類したアフィンクラス Ac の決定木群 $T2_{Ac}$ によりキーポイントの分類を行う．入力パッチ $\mathbf{P}$ が $G(Ac) = 1$ となるアフィンクラスのみの決定木から，リーフノードの確率分布 $p_{\eta(T2_{kl},\mathbf{P})}(Y(\mathbf{P}) = c)$ の平均を次式より求め，確率の高いクラス c に分類する．

$$\hat{Y}(\mathbf{P}) = \arg\max_c \frac{1}{L_2}\sum_{l=1}^{L_2}\sum_{k=1}^{K} G(k) p_{\eta(T2_{kl},\mathbf{P})}(Y(\mathbf{P}) = c)$$

4. 実験

対応点マッチングの精度比較と処理時間の比較実験を行う．実験に用いるデータベースは Mikolajczyk database と Morel database である．データベースのテンプレートを図 4 に示す．

(a) (b) (c)

図 4：テンプレート

比較対象は，SIFT[2]，Randomized Trees[1] である．図 5 に各テンプレートにおけるマッチング率を示す．横軸は画像の回転角度である．マッチング率は次式より求める．

$$\text{マッチング率} = \frac{\text{マッチング成功数}}{\text{マッチング数}}$$

図 6 にテンプレート a の 70 度回転した入力画像とのマッチング結果画像を示す．図 5 より，もっとも精度の良いのは提案手法であり，次に Randomized Trees，最後に SIFT の順である．従来手法である Randomized Trees と提案手法を比べると，提案手法の方が画像変化に対して頑健であることがわかる．これは，2 段階に決定木を構築することで，画像変化に近い決定木によるキーポイント分類でマッチング精度を高めたといえる．次に，各手法の処理時間を表 1 に示す．実験に用いた PC スペックは XeonX5355@2.66Ghz(1 コア) である．処理時間は，SIFT：1221ms，Randomized Trees：45ms，提案手法：78ms となり，SIFT がもっとも処理時間が長い，提案手法と従来手法である Randomized Trees を比べると，提案手法は，2 段階の決定木でマッチングを行うため，約 1.7 倍時間が増加しているが，12fps でリアルタイム処理が可能である．

図 5：マッチング精度結果

図 6：テンプレート a(70 度) の対応点マッチング結果

表 1：処理時間の計測結果

	処理時間 [ms]
SIFT	1221
Randomized Trees	45
提案手法	78

5. おわりに

本稿では，2 段階の決定木によるキーポイント分類手法を述べた．提案手法は，従来手法である Randomized Trees より高精度なマッチングが可能であることを示した．今後の課題として，オンラインで決定木を構築する手法を検討する予定である．

参考文献

[1] V. Lepetit and P. Fua, “Keypoint Recognition using Randomized Trees”, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol.28, No.9, pp.1465-1479, 2006.

[2] David G.Lowe, “Distinctive image features from scale-invariant keypoints”, International Journal of Computer Vision,Vol.60, No.2, pp.91-110, 2004.

研究業績

西村孝，都築勇司，王毅捷，Willy To，藤吉弘亘，松本学，“道路状況把握のための空撮画像を用いた物体移動方向の可視化”，精密工学会誌 Vol.75 No.2 pp.300-306, 2009.
(他 学会口頭発表 3 件)