# Geometric Context 特徴を用いた Randomized Trees による IM2GPS

EP06104 山内 一祥　　指導教授：藤吉弘亘

## 1. はじめに

ジオタグ (位置情報タグ) 付き画像データベースを用いて画像の撮影位置をアピアランスに基づいて推定する IM2GPS[1] が提案されている．IM2GPS では，$k$-NN 法による類似画像探索を行っており，処理に膨大な時間を費やすという問題がある．そこで，本研究では Geometric Context[2] によって得られるジオメトリ情報を Randomized Trees[3] により学習することで，高精度かつ高速な IM2GPS の手法を提案する．

## 2. 提案手法

提案手法の流れを図 1 に示す．ジオタグ付き画像データベースを用いて，Randomized Trees により学習する．これにより，高速な類似画像の探索が可能となる．

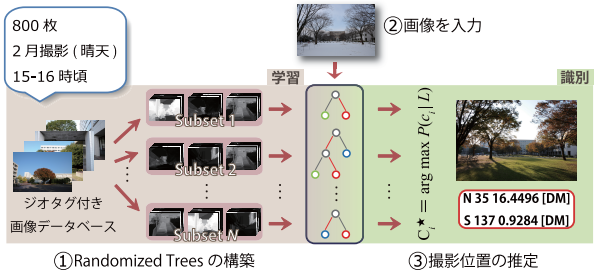


図 1：提案手法の流れ

### 2.1 Geometric Context

Geometric Context は，画像中の 3 次元の面構造を推定しラベリングする手法で，“ 地面 ”,“ 空 ”,“ 垂直物 (45 °,90 °,135 °) ”,“ 剛体 ”,“ 植物 ”の確信度を得られる．各ラベル画像は，30×20 ピクセルにダウンサンプリングする．

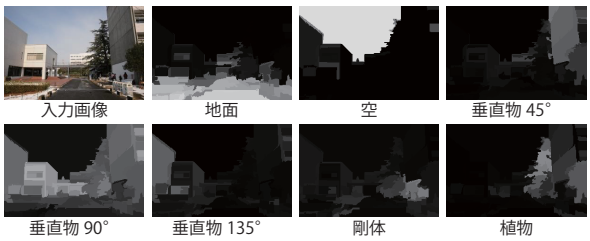


図 2：Geometric Context の可視化画像

### 2.2 Randomized Trees

提案手法では，Randomized Trees を用いて識別器を構築する．同位置で撮影した画像群を 1 つのクラスとし，クラス内の共通のジオメトリ情報を学習させる．

**学習**　Randomized Trees は複数の決定木を構築する識別器であり，決定木は分岐ノードを作成することで学習する．各分岐ノードに対し，入力データが $I_n$, 左右に分岐するデータがそれぞれ $I_l$,$I_r$，特徴ベクトルを v，分岐関数を $f$，$t$ をしきい値とすると，分岐は以下のように行われる．

$$I_l = \{i \in I_n | f(\mathrm{v}_i) < t\}, \quad (1)$$

$$I_r = I_n \setminus I_l \quad (2)$$

分岐関数 $f$ に入力する特徴には，Geometric Context の各分類画像に対して，以下の 4 つからランダムに選択する．(i) $p_{x,y,g}$，(ii) $p_{x_1,y_1,g_1} + p_{x_2,y_2,g_2}$，(iii) $p_{x_1,y_1,g_1} - p_{x_2,y_2,g_2}$，(iv) $|p_{x_1,y_1,g_1} - p_{x_2,y_2,g_2}|$，(i) は，あるピクセル $(x, y)$ における Geometric Context のラベル $g$ の確信度を表し，(ii)〜(iv) は，あるピクセル $(x_1, y_1)$，$(x_2, y_2)$ における Geometric Context のラベル $g_1$，$g_2$ の確信度の組み合わせを表す．同様に，しきい値 $t$ もランダムに選択する．

**識別**　学習により構築された複数の決定木の末端ノード $l$ のクラス分布 $P(c|l)$ を用いる．複数の決定木をトラバーサルすることにより得られる各木の分布から，平均分布 $P(c|L)$ を求める．たどり着いた複数の決定木の末端ノードの分布の平均分布 $P(c|L)$ は，決定木の数を $T$，$L = (l_1, ..., l_T)$ とすると式 (3) で求めることができる．

$$P(c|L) = \frac{1}{T}\sum_{t=1}^{T} P_t(c|l_t) \quad (3)$$

そして，式 (4) によりクラスを推定する．

$$C_i^\star = \arg\max_{c_i} P(c_i|L) \quad (4)$$

## 3. 評価実験

提案手法と従来手法の精度の比較を行う．評価項目は，探索時間と正解率の 2 つである．類似画像の撮影位置と入力画像の撮影位置の距離が，15m 以内かつ撮影方向が ±30 °以内の画像を正解画像とする．

### 3.1 データセット

Randomized Trees の構築には，2010 年 2 月中 (晴天) に中部大学内の 32 箇所で撮影された 800 枚の画像を用いる．テストセットには，2009 年 11 月中 (晴天) に撮影された 32 枚の画像を用いる．また，すべての画像には経度，緯度，撮影方向 (0-359 °) が記録されている．

### 3.2 実験結果

従来手法である IM2GPS と比較したテストセットの正解率を図 3 に，探索時間を表 1 に示す．図 3 より，提案手法は従来手法に比べ，正解率上位 5 位以内において約 16% 向上させることができた．従来法に比べ，提案手法では探索時間を大幅に短縮することができた．これは，決定木をトラバーサルすることで，特徴量空間を効率良く探索できるためである．

表 1：従来手法との比較

| | 探索時間 [ms] | 正解率 [%](上位 5 位以内) |
|---|---|---|
| 従来手法 | 634.8 | 81 |
| 提案手法 | 0.6 | 94 |

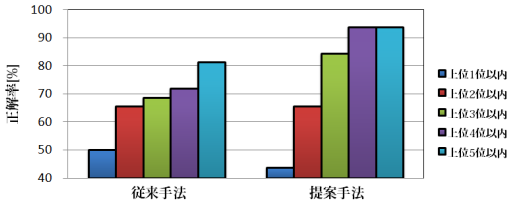


図 3：上位 5 位以内の正解率

図 4 に，類似画像を Google Maps 上に表示した例を示す．これにより，提案手法は季節の変化による植物の見えの変化に対して頑健に類似画像を探索できることがわかる．

図 4：提案手法による Google Maps 上の表示例

## 4. おわりに

本研究では，ジオメトリ情報を Randomized Trees により学習することで，高精度かつ高速な手法を提案し，評価実験によりその有効性を確認した．今後は，[1] により公開されているデータセットを用いた評価実験を行う．

## 参考文献

[1] J. Hays and A. A. Efros: “IM2GPS:estimating geographic information from a single image”, CVPR, pp. 1-8 (2008).

[2] D. Hoiem, A. A. Efros and M. Hebert: “Geometric context from a single image”, ICCV, **1**, pp. 654-661 (2005).

[3] L. Breiman: “Random forests”, Machine Learning, **45**, 1, pp. 5-32 (2001).