

# 知っておきたいキーワード

## ランダムフォレスト

山岡啓介<sup>†</sup>

<sup>†</sup> ソニー株式会社 共通要素技術部門 ユーザーエクスペリエンス開発部

"Random Forest" by Keisuke Yamaoka (User Experience Development Dept., Common Technology Division, Sony Corporation, Tokyo)

キーワード: ランダムフォレスト, 決定木, マルチクラス識別, 情報エントロピー, コンピュータビジョン, 人体姿勢推定

### ランダムフォレストとは

ランダムフォレスト (Random Forests) は、統計学習アルゴリズムであり、マルチクラス識別やクラスターリングに用いられる。決定木 (Decision Tree)<sup>1)</sup> を発展させる形で2001年にLeo Breiman<sup>2)</sup> によって提案され、その後多数の研究者によって

改良が加えられてきた。

近年では物体認識や文字認識といったComputer Visionの分野で多数用いられ、恐らく最も有名な例では、人体の姿勢推定を用いたゲームのコントローラ (MicrosoftのKinect) への応用が挙げられる。

同様の問題を解くのによく用いられるブースティング (Boosting) やサポ

ートベクタマシン (Support Vector Machine, SVM) といった他の統計学習手法と比較して、学習や識別が高速であり、ノイズに対して頑健であるというメリットを持つ。一方、ランダム性を確保しつつ学習を収束させるために、大量の学習データを必要とするという特徴も持つ。

### 決定木

まず、ランダムフォレストの基本構成要素である「決定木」について説明する。

決定木は、あるデータの集合をその属性によって分類したもので、枝はある特徴をもつ部分集合を表し、葉がその分類を表すような木構造のことをいう。データに隠されたルールを発見しモデル化、いわゆる「データマイニング」によく使われる手法である。

次に、決定木によるモデル化の例を以下に示す。表1は海水浴に関するサンプル調査結果で、各々のデータは海水浴に行くか行かないかを表す属性値 (結果属性) および気候に関するさま

表1 サンプル調査結果

気温	天気	風速	海水浴
30℃以上	晴れ	5m未満	行く
30℃未満	雨	5m以上	行かない
30℃以上	雨	5m未満	行かない
30℃以上	晴れ	5m未満	行く
30℃未満	晴れ	5m以上	行かない
30℃未満	晴れ	5m未満	行く
30℃以上	晴れ	5m以上	行かない
情報量 = 0.985			

ざまな属性 (説明属性、特徴量) を持っている。気温が高く晴れている場合には海水浴に行きたくなるといったことは予測できるが、この表から人の行動がどのようにルール付けされるかを説明することは意外と難しい。そこで、

決定木の登場となる。

決定木は属性によってデータ集合を部分集合に分けていき、最終的に属性値ごとの集合へと分割することを目指す。ここで、分け方の指標として平均情報量 (エントロピー) を用いる。Nクラスに分類されるようなデータをIとした場合の情報量Eは一般的に下記の式で計算される。

$$E(I) = -\sum_{i=1}^n P_i \log_2 P_i$$

$P_i$  はクラス*i*のデータ数の割合を表す。

この式から、平均情報量はデータの属性値に偏りがあり、より良く分類された集合である場合には小さくなるのがわかる。表1のデータの平均情報量は0.985である。

☞

決定木の学習は、分割した部分集合の平均情報量が元の集合の平均情報量と比較して、なるべく低くなるよう説明属性を選んでいくという処理を繰り返すことにより行う。この平均情報量の差を情報利得(情報ゲイン)といい、説明属性の識別力を示す指標となる。

それぞれの説明属性で分割した場合の属性値の度数と平均情報量、および情報利得を表2に示す。

表を見ると、今回の調査対象者は「風速」により判断が左右されている。つまり、決定木の1層目は「風速」属性によって分割するのが良いということがわかる。2層目以下も同様に、情報利得の大きい属性で分けていき、部分集合の属性が一つに揃うまで分割を続け、木構造を構成していく。以上が決定木の学習法で、途中段階の節をノードまたは分岐ノード、末端をリーフ

表2 説明属性による分割

気温			
30℃以上		30℃未満	
行く	行かない	行く	行かない
2	2	1	2
平均情報量 = 0.965		情報利得 = 0.020	

天気			
晴れ		雨	
行く	行かない	行く	行かない
3	2	0	2
平均情報量 = 0.694		情報利得 = 0.291	

風速			
5m以上		5m未満	
行く	行かない	行く	行かない
0	3	3	1
平均情報量 = 0.464		情報利得 = 0.521	

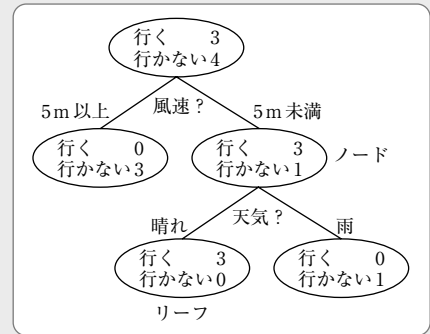


図1 決定木

見ると、調査対象者が何を基準に判断しているかがよくわかる。

今回の学習には平均情報量を用いたが、経済学におけるデータマイニングでは、しばしば「ジニ係数」を指標として学習したCARTと呼ばれる決定木が用いられる。

たは末端ノードと呼ぶ。

このようにして表1のデータをモデル化した決定木が図1である。これを

## ランダムフォレストのアルゴリズム

属性値や属性(特徴量)が多数ある大量のデータがあった場合、1本の決定木でモデル化することは著しく困難となる。そこで、複数の木で構成され

る森(フォレスト)としてモデル化することを考えたのがランダムフォレストと言える。

図2にその学習アルゴリズムを示す。このように、データIからランダムにサンプリングされたS個のサブセットに対して、これもランダムに選択された属性を用いてS本の決定木を作成するという、とてもシンプルなアルゴリズムとなっている。ここでのポイントは、データセット、および属性のランダム性により、決定木群が互いに相

関の低い状態になっていることが期待されるということである。通常は、これらの木を数百本というオーダーで作成し、精度と汎化能力を確保する。また、階層が深くなるほど過学習になる傾向があるので、深さをあらかじめ決めておくことが一般的である。

図3は、実際に学習されたランダムフォレストのイメージを示している。それぞれのリーフは属性値のヒストグラムを持つということになる。

次に、これを用いて実際に

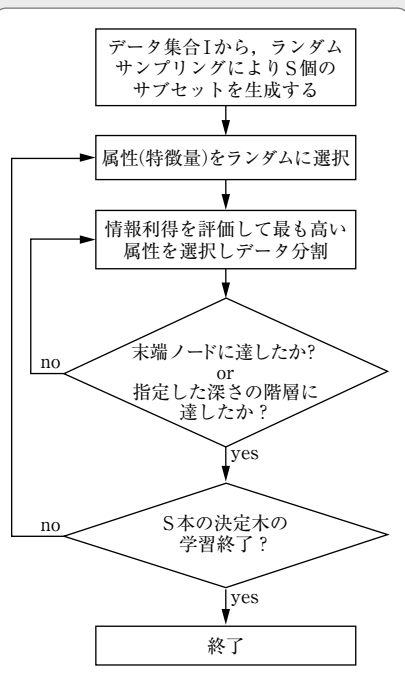


図2 ランダムフォレスト学習フロー

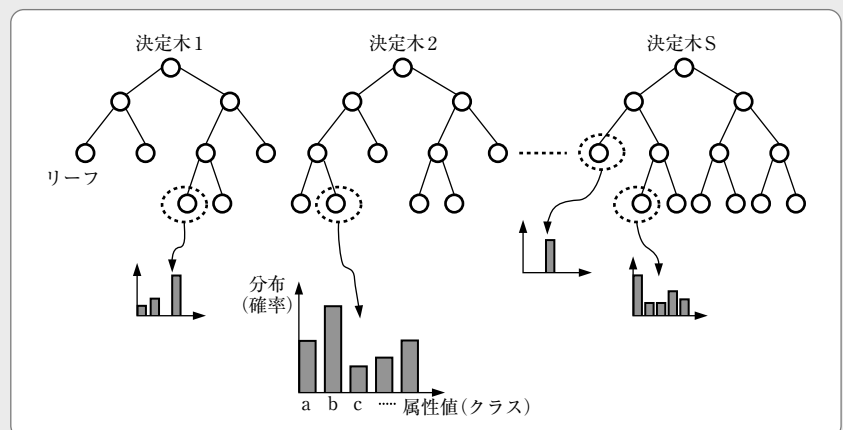


図3 ランダムフォレストの例

☞ 識別問題を解く方法を説明する。

図4に示すように、未知の属性値を持つデータ(クエリ)  $Q$  をそれぞれの決定木に入力し、ノードの説明属性にしたがって、リーフに到るまでトレースしていく(この作業をトラバースルという)。そして、各リーフの持つヒストグラムを集計して平均値を求め、最大値を示す属性値をそのクエリの結果として出力する。

図中の  $C_q$  に関する式は、統計学的に言えば、最尤法による単純ベイズ識別器のパラメータ推定に相当する。

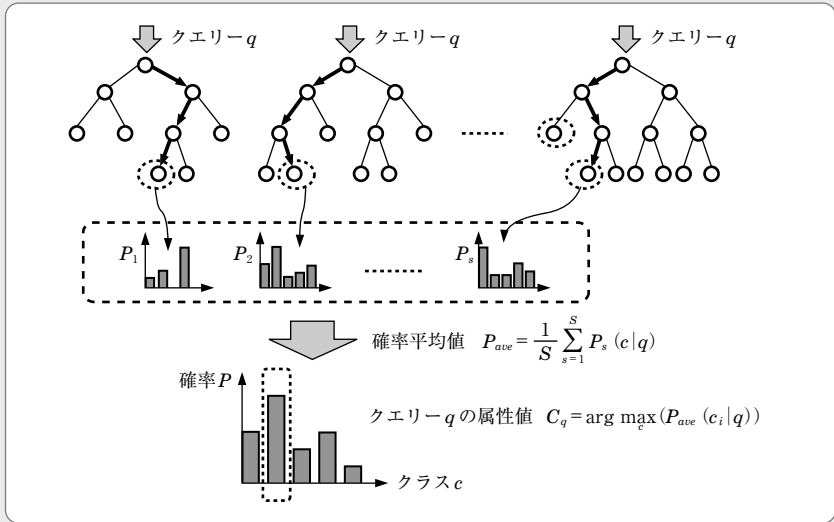


図4 識別の方法

### ランダムフォレストの応用例

冒頭にも述べたが、アクティブ型3Dセンサを用いた人体姿勢推定システムであるMicrosoft社のKinectにおいて、ランダムフォレストが応用されている。以下、その解説をする。

J.Shottonらによって開発された<sup>3)</sup>このシステムは、3Dセンサによって得られる距離画像(センサ・カメラからの距離を示すグレイスケールの画像)の各ピクセルが、どの人体パーツに属するかという問題を解いている。

ここで用いられている説明属性、つまり特徴量を図5に示す。

「Depth Image Features」と名付けられたこの特徴量は、注目ピクセルから一定量オフセットした2点における距離値の差分値という、非常に単純な

ものである。膨大に存在する組合せからランダムに選び出した2点と、ランダムに設定された閾値を説明属性とし、ノードを分岐することにより決定木を学習していく。

決定木は20階層のものを3本用いている。それぞれの特徴量は非常に弱い識別力しか持たないが、それが $2^{20} \times 3$ 、つまり300万を超える数集まることに

より高い推定性能を実現している。

距離により、抽出された人体マスク中のすべてのピクセルは、ランダムフォレストにより何れかの人体パーツに分類される。そして、パーツごとにMean Shift法によって最頻値推定が行われ、その3次元位置を推定している。

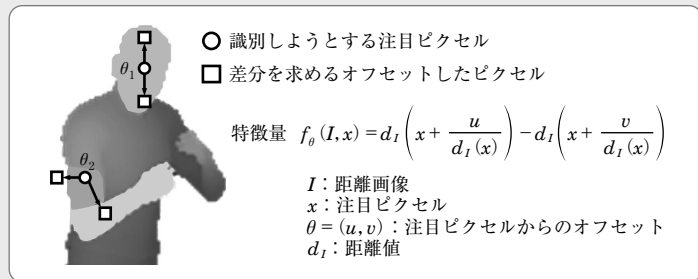


図5 ランダムフォレストの例

### むすび

以上のように、ランダムフォレストは、比較的単純なアルゴリズムながら

高い識別性能を示し、また、学習や識別が高速であるといった優れた性質を持つ。現在も盛んに研究され改善が試みられており、今後も画像認識の分野

等での幅広い活用が期待される。

(2012年3月25日受付)

### 参考文献

- 1) T.Menzies, Y. Hu: "Data Mining for Very Busy People", IEEE Computer, pp.18-25 (Oct. 2003)
- 2) L.Breiman: "Random Forests", Machine Learning, pp.5-32 (2001)
- 3) J.Shotton, A. Blake, et. al: "Real-Time Human Pose Recognition in Parts from Single Depth Images", CVPR (2011)



ヤマオカ ケイスケ  
**山岡 啓介** 1992年、東京大学工学部機械情報工学科卒業。同年、ソニー(株)入社。DAT, Super Audio CDなどのオーディオ機器の開発・商品化に従事。その後、画像処理・認識技術の研究開発に従事し、ヒューマノイドロボットQRIOの開発等に参画。現在はそれらを活用した新たなユーザーエクスペリエンスの開発を担当している。