

# Bayesian flexible modeling of trip durations

**Hugh Chipman, Edward George, Jason Lemp, and Robert McCulloch**

**Transportation Research Part B**

Volume 44, Issue 5 , Pages 686-698 , June 2010

2010/05/31(月)

論文ゼミ#2

M1 戸叶洋道

# BARTモデル

□ BART (Bayesian Additive Regression Trees) は、従属変数を、回帰木の和として表現したモデル

□ 回帰木は、ツリーの構造

$T$


ターミナルノードの値

$$M = \{\mu_1, \dots, \mu_B\}$$

分岐の条件

$$x = (x_1, \dots, x_p)$$

で構成  $g(x; T, M)$



# regression tree (回帰木)

□回帰木は、一番最初にルートノードがあり、そこから子供ノードが枝分かれし、一番下のターミナルノードへと細分化される構造をとる。各ターミナルノードに $\mu$ の値が格納されている。


□図は、ターミナルノードが3つの例。  $M = \{0.1, 0.8, 0.3\}$

□あるノードがターミナルノードでない確率は、 $\alpha(1+d)^{-\beta}$

$\alpha=0.95, \beta=2$ とすると( $d$ はノードの深さ)

それぞれのノードに子供がいる確率は...

□枝分かれの変数 $x$ とその値もランダムに決まる





# 回帰木の事前確率

$$\alpha = 0.95, \beta = 2$$

$x_1, x_2$  は, 0.0~2.0まで0.1刻みの値をとる

- $0.95 \times$  (root node is nonterminal)
- $0.5 \times$  (split is on  $X_2$ , one of two variables)
- $0.05 \times$  (split is on 1 of 20 possible locations)
- $0.2375 \times$  (left child is nonterminal)
- $0.5 \times$  (left child splits on  $X_1$ , one of two variables)
- $0.05 \times$  (split is on 1 of 20 possible locations)
- $(1 - 0.1056) \times (1 - 0.1056) \times$  (two children are terminal)
- $(1 - .2375)$ (right child of root node is terminal) =  $8.6 \times 10^{-5}$



□この木は,  $(x_1, x_2) = (1.0, 0.5)$  のとき,  $\mu_1 = 0.1$  を返す.

# A sum of trees model

$$Y = g(x; T_1, M_1) + g(x; T_2, M_2) + \cdots + g(x; T_m, M_m) + \varepsilon, \quad \varepsilon \sim N(0, \sigma^2)$$

$$f(x) = g(x; T_1, M_1) + g(x; T_2, M_2) + \cdots + g(x; T_m, M_m)$$

$\mu_{i,b}$  は,  $\mu \sim N(0, \sigma_\mu^2)$  に従うものとする.


$\sigma$  は,  $\sigma^2 \sim \nu\lambda / \chi_\nu^2$  に従うものとする.

$\hat{\sigma}$ : ( $\sigma$ のオーバーエスティメート)を定める. 実用的には, 標本標準偏差を用いる. 右の図では2.0

$\nu$ : 自由度 (degrees of freedom) を 3~10の範囲で定める.

$q$ : 分布がシグマハット以下である確率 (quantile)

デフォルト  $(\nu, q) = (3, 0.9)$



# A sum of trees model

---

$$Y = \sum_i g(x; T_i, M_i) + \varepsilon$$

decision rule

$\mu \sim N(0, \sigma_\mu^2)$

$\varepsilon \sim N(0, \sigma^2)$

$\sigma^2 \sim \nu\lambda / \chi_\nu^2$

# MCMC algorithm

---

- $y$ という観測値が与えられた時の、事後分布を導く

$$p((T_1, M_1), \dots, (T_m, M_m), \sigma | y)$$

- 基本的には、ギブスサンプラー

- まず $T$ と $M$ をひとつずつサンプリングし、

$$(T_1, M_1) | T_{(1)}, M_{(1)}, \sigma, y$$

$$(T_2, M_2) | T_{(2)}, M_{(2)}, \sigma, y$$

⋮

$$(T_m, M_m) | T_{(m)}, M_{(m)}, \sigma, y$$

- 次に $\sigma$ をサンプリングする

$$\sigma | T_1, \dots, T_m, M_1, \dots, M_m, y$$

- これを繰り返す


# MCMC algorithm

---

- M,  $\sigma$ は事前分布に標準正規分布を持つ
  - ⇒通常のベイズ更新を繰り返す
  
- Tは木の構造⇒どうやって更新？
  - GROW
    - ターミナルノードを増やす(0.25)
  - PRUNE
    - ターミナルノードを減らす(0.25)
  - CHANGE
    - 分岐条件を変更(0.4)
  - SWAP
    - 親子の分岐条件を交換(0.1)
- Tは事前分布を持たないので、ギブスサンプラーでは出来ない
  - ⇒メトロポリスヘイスティングス
  - Chipman(1998)によれば, 更新の選択確率は常に1

# なぜ sum of ?

- ❑ Chipmanは、1998年に単回帰木のモデルを提案している
- ❑ 木が一つだと柔軟性に乏しく、すぐにある値に収束してしまうが、それが真の値かどうかはわからない。
- ❑ ある「good tree」を見つけて何度も再スタートを繰り返さなければならない



# Fitting trip duration data with BART

□ データは、テキサス州の車によるトリップ

□ 各トリップの変数(17個)

■ 世帯属性

- 世帯人数
- 収入
- 子供の数 etc...

■ トリップメーカーの変数


- 年齢
- 職業 etc...

■ トリップの変数

- 日時
- トリップタイプ
- 出発時間
- 自由流れトリップ距離
- 自由流れトリップ時間
- トリップ時間 etc...

従属変数  $y = \frac{dur}{ffd}$

トリップ時間は5分単位で丸められて報告されていることが多いので注意！




# BART results, all variables

## □ BARTモデル結果

- 図は,  $\sigma$ のMCMCの結果のプロット
- burn-inは300で, 総繰り返し数2300
- 計算時間226秒(2.93GHz,Core 2 Duo)
- $\sigma$ の平均値は0.5
- $y$ とBARTのR二乗値は48%
- $x$ に関する変換は必要ない  
(sum of tree が自動的に柔軟に形を変える)

## □ 通常の線形回帰モデル結果

- $\sigma$ の推定値は0.58(図の赤線)
- R二乗値は28%
- $x$ に関して変換が必要



# 結果の解釈

---

- 各繰り返しで得られる  $f^*(x)$  は, 真の  $f(x)$  の事後分布からのサンプルとして考えることができる.
- $f^*(x)$  の平均値は,  $f(x)$  の平均値と推定することができる.
- BARTを予測デバイスと考えるならば,  $f^*(x)$  の平均値に各  $x$  を代入してあげれば  $y$  を予測することができる.
- 実際にどのような関数になっているか(どの変数が被説明変数に対してどのように寄与しているか)はわからない.

# 結果の解釈

---

- Chipmanは、変数選択法を提案
- 分岐に利用されている回数が多い変数ほど、被説明変数に対する寄与が大きいと考える。
  - 今回の場合,
    - free flow distance(19%)
    - trip type(4%)
    - departure time(3.4%)
  - が分岐で多く利用された。


# 結果の解釈

□ 重要だと思われる変数をの組み合わせをいくつか抽出して、比較する。

■ ワークトリップはソーシャルトリップよりも長い

■ 20時よりも17時の方が基本的に長い時間となっている⇒出発時間がtrip durationに大きな影響を与えている

■ ソーシャルトリップは他のトリップよりも不確実性が高い



# Transforming independent variables

## □ 線形回帰モデルを，変数変換で改善

### ■ free flow distanceを対数変換

- R二乗値28⇒40%
- $\sigma$ の推定値0.58⇒0.53

### ■ departure timeの変換(popuri et al(2008)による)

$$g_1(T) = \exp\left(\sin\left(\frac{2\pi T}{24}\right)\right), g_2(T) = \exp\left(\cos\left(\frac{2\pi T}{24}\right)\right)$$
$$g_3(T) = \exp\left(\sin\left(\frac{4\pi T}{24}\right)\right), g_4(T) = \exp\left(\cos\left(\frac{4\pi T}{24}\right)\right)$$

$$g(T) = \sum_{i,j} \beta_{i,j} g_i(T)^j$$

- R二乗値40⇒41%
- $\sigma$ の推定値0.53⇒0.52

### ■ ちなみに，今回のBARTモデルは，R二乗値48%， $\sigma$ の平均0.5

# まとめ

- sum of trees + MCMC によって、柔軟に、そして自動的に説明変数の関数に変化していくモデル.
- 線形な回帰モデルと違い、変数の変換を自動的にやってくれるため、予測のモデルとしては非常に有用.
- しかし、Chipmanもその解釈に奮闘中であるように、 $y$ と $x$ の関係がブラックボックスの中にある感じは否めない.