


# 全部分グラフ指示子上の分類森構築に向けて


## 北海道大学大学院 修士1年 横山侑政

### グラフの教師あり分類問題

入力 クラス( $y = +1$  or  $-1$ )の分かる複数のグラフ  $N$  個



出力 クラスを予測する分類森  $F$



$$F_t(x) = \sum_{i=1}^t f_i(x) = \sum_{i=1}^t \sum_{v \in \text{leaves of } f_i} w_v r_v$$

特徴ベクトル 部分グラフの有無

				...
	0	0	0	1
	1	0	0	0
	1	1	0	1
	1	1	1	1

全ての部分グラフに関して有無を調べるのは困難  
頻出する部分グラフのみ調べる方法もあるが、  
**可能なら全ての部分グラフを活用したい!**  
GBDT なら可能だが精度が悪い。XGBoost, RGF でもしたい。

### Gradient Boosting Decision Tree



決定木を勾配ブースティングする。正則化を明示的に考えない。  
決定木の大きさや縮小率を調整することで暗に正則化している。  
明示的な正則化のなければ、全部分グラフ指示子に基づいて学習できる。

$$\min Q = \sum_{i=1}^N \Phi(y_i, F_t(x_i)) = \sum_{i=1}^N \Phi(y_i, F_{t-1} + f_t) \approx \sum_{i=1}^N \Phi(\tilde{y}_i^{(t-1)}, f_t)$$

$$\tilde{y}_i^{(t-1)} = -\partial \Phi(y_i, F_{t-1}(x_i)) / \partial F_{t-1}(x_i)$$



全部分グラフ指示子に基づいた学習

○●を





ここまで分かっているとき、  
○●●の有無で分割することを考える

理想の分割(+1のみ含む)



理想の分割(-1のみ含む)



### XGBoost

パッケージ化されており、並列処理などによる高速化がされている。  
明示的な正則化があり、目的関数の近似にヘシアンも使う。

$$\begin{aligned} \min Q &= \sum_{i=1}^N \Phi(y_i, F_t(x_i)) + \Omega(F_t) = \sum_{i=1}^N \Phi(y_i, F_{t-1} + f_t) + \Omega(f_t) \\ &\approx \sum_{i=1}^N [\Phi(\tilde{y}_i^{(t-1)}, y_i) + g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i)] + \Omega(f_t) \\ &= \sum_{i=1}^N [g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i)] + \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2 \\ &= \sum_{v \in \text{leaves of } f_t} [(\sum_{i \in r_v} g_i) w_j + \frac{1}{2} (\sum_{i \in r_v} h_i + \lambda) w_j^2] + \gamma T \end{aligned}$$

$$\begin{aligned} \hat{y}_i^{(t-1)} &= F_{t-1}(x_i) \\ g_i &= \partial_{\hat{y}_i^{(t-1)}} \Phi(y_i, \hat{y}_i^{(t-1)}) \\ h_i &= \partial_{\hat{y}_i^{(t-1)}}^2 \Phi(y_i, \hat{y}_i^{(t-1)}) \\ \Omega(f_t) &= \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2 \\ T &\text{は } f_t \text{ の葉ノードの数} \end{aligned}$$

$f_t$  を固定すると、最適な  $w^*$  が計算できる。

$$w_j^* = -\frac{\sum_{i \in r_v} g_i}{\sum_{i \in r_v} h_i + \lambda}$$

このとき、目的関数は


$$\tilde{Q}(f_t) = -\frac{1}{2} \sum_{v \in \text{leaves of } f_t} \frac{(\sum_{i \in r_v} g_i)^2}{\sum_{i \in r_v} h_i + \lambda} + \gamma T$$

$f_t$  の  $r_0$  を  $r_1$  と  $r_2$  に分割するときの目的関数の差分は

$$\frac{1}{2} \left[ \frac{(\sum_{i \in r_1} g_i)^2}{\sum_{i \in r_1} h_i + \lambda} + \frac{(\sum_{i \in r_2} g_i)^2}{\sum_{i \in r_2} h_i + \lambda} - \frac{(\sum_{i \in r_0} g_i)^2}{\sum_{i \in r_0} h_i + \lambda} \right] - \dots$$

分割の目的は

$$\min \left[ \frac{(\sum_{i \in r_1} g_i)^2}{\sum_{i \in r_1} h_i + \lambda} + \frac{(\sum_{i \in r_2} g_i)^2}{\sum_{i \in r_2} h_i + \lambda} \right]$$



### Regularized Greedy Forest


定期的に、全ての葉の重みを計算しなおすことで  
収束を早め、簡潔なモデルを作成する。  
明示的な正則化があり、勾配ブースティングよりも調整しやすい。  
決定木単位ではなく、葉ノード単位でアンサンブルを行う。

$$F(x_i) = \sum_{v \in \text{leaves of } F} w_v r_v$$

$r_0$  を  $r_1$  と  $r_2$  に分割した分類森  $F'$  は

$$\begin{aligned} F' &= F - w_0 r_0 + w_1 r_1 + w_2 r_2 \\ &= F - w_0 r_0 + (w_0 + \delta_1) r_1 + (w_0 + \delta_2) r_2 \\ &= F + \delta_1 r_1 + \delta_2 r_2 \end{aligned}$$

$$\hat{\delta}_k = -\frac{Q'(F(\delta_1, \delta_2))}{Q''(F(\delta_1, \delta_2))} \Big|_{\delta_1=0, \delta_2=0}$$



出典[3]

目的関数  $Q$  は

$$\min Q = \sum_{i=1}^N \Phi(y_i, F(x_i)) + \Omega(F) = \sum_{i=1}^N \Phi(y_i, F(x_i)) + \lambda \sum_v w_v^2 / 2$$

分割の目的は

$$\begin{aligned} \min Q' - Q &= \Phi(y_i, w_1 r_1) + \Phi(y_i, w_2 r_2) - \Phi(y_i, w_0 r_0) + w_1^2 + w_2^2 - w_0^2 \\ &= \Phi(y_i, w_1 r_1) + \Phi(y_i, w_2 r_2) + w_1^2 + w_2^2 \end{aligned}$$

### 参考文献

- [1] Friedman, Jerome H. "Stochastic Gradient Boosting." mh (x; am) 1000 (1999): 0.
- [2] Chen, Tianqi, and Carlos Guestrin. "Xgboost: A scalable tree boosting system." arXiv preprint arXiv:1603.02754 (2016).
- [3] Johnson, Rie, and Tong Zhang. "Learning nonlinear functions using regularized greedy forest." IEEE transactions on pattern analysis and machine intelligence 36.5 (2014): 942-954.