



三星 諒太郎 九州大学/理研 AIP  
ryotaro.mitsuboshi@inf.kyushu-u.ac.jp

畑埜 晃平 九州大学/理研 AIP  
hatano@inf.kyushu-u.ac.jp

瀧本 英二 九州大学  
eiji@inf.kyushu-u.ac.jp



## エッジ最小化とソフトマージン最適化

入力: サンプル  $S = ((x_i, y_i))_{i=1}^m \in (\mathcal{X} \times \{\pm 1\})^m$ , パラメータ  $\nu \in [1, m]$ , 仮説集合  $\mathcal{H} \subset [-1, +1]^{\mathcal{X}}$ .

## エッジ最小化問題

$$\min_d \left[ f(d) + \max_{h \in \mathcal{H}} (d^\top A)_h \right], \quad f(d) = \begin{cases} 0 & d \in \Delta_{m,\nu} \\ +\infty & \text{otherwise} \end{cases} \quad (1)$$

ただし,  $\Delta_{m,\nu} = \{d \in [0, 1/\nu]^m \mid \|d\|_1 = 1\}$  で,  $A = (y_i h(x_i))$ .  
( $d^\top A)_h = \sum_i d_i y_i h(x_i)$  は仮説  $h \in \mathcal{H}$  の, 分布  $d$  に関するエッジ (正答率).

⇕ Fenchel 双対問題 (双対ギャップ 0)

## ソフトマージン最適化問題

$$\max_{w \in \Delta_{\mathcal{H},1}} \left[ -f^*(-Aw) := \min_{d \in \Delta_{m,\nu}} d^\top Aw \right] \quad (2)$$

ここで,  $f^*(\theta) = \sup_d [\theta^\top d - f(d)]$  は  $f$  の Fenchel 共役関数.  
マージンが大きい  $\Rightarrow$  汎化誤差の保証が良い.

出力:  $\sum_{h \in \mathcal{H}} \bar{w}_h h$ , ただし  $\bar{w}$  は (2) の最適解.

$\mathcal{H}$  が非常に大きいとき, LP ソルバを使っても (2) を解くのは困難.

## ブースティング

各ラウンド  $t = 0, 1, 2, \dots, T$  において,

- 1 サンプル上の分布  $d_t \in \Delta_{m,\nu}$  を決める.
- 2 弱学習器から  $(d_t^\top A)_{h_{t+1}} \geq g$  を満たす仮説  $h_{t+1} \in \mathcal{H}$  を得る.  
( $g$  は未知)

(2) の  $\epsilon$ -近似解  $H_T = \sum_{t=1}^T w_{T,t} h_t$  を出力.

## ■ LPBoost

$$d_t^L \leftarrow \arg \min_d \max_{h \in \{h_1, h_2, \dots, h_t\}} (d^\top A)_h + f(d)$$

## ■ ERLPBoost

$\eta = \frac{2}{\epsilon} \ln \frac{m}{\nu}$  として,

$$d_t^E \leftarrow \arg \min_d \max_{h \in \{h_1, h_2, \dots, h_t\}} (d^\top A)_h + f(d) + \underbrace{\frac{1}{\eta} \sum_{i=1}^m d_i \ln(m d_i)}_{=: f(d)}$$

## ■ C-ERLPBoost

$w_t^C = w_{t-1}^C + \lambda_{t-1}(e_{h_t} - w_{t-1}^C) \in CH(\{e_{h_1}, e_{h_2}, \dots, e_{h_t}\})$  として,

$$d_t^C \leftarrow \arg \min_d d^\top A w_t^C + \tilde{f}(d)$$

LPBoost ERLPBoost C-ERLPBoost 提案スキーム

	LPBoost	ERLPBoost	C-ERLPBoost	提案スキーム
$T$	$\Omega(m)$	$O(\frac{1}{\epsilon^2} \ln \frac{m}{\nu})$	$O(\frac{1}{\epsilon^2} \ln \frac{m}{\nu})$	$O(\frac{1}{\epsilon^2} \ln \frac{m}{\nu})$
反復一回	LP	CP	Sorting	$\geq$ Sorting

## 目標.

理論保証があり, かつ実用的なブースティングアルゴリズムが欲しい.

## フランク・ウルフ (FW) のアルゴリズム

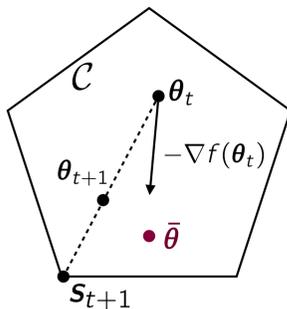
次の形の最適化問題を解く一次の繰り返し法.

$$\min_{\theta \in \mathcal{C}} f(\theta)$$

$\mathcal{C} \subset \mathbb{R}^m$  は閉凸集合,  
 $f: \mathcal{C} \rightarrow \mathbb{R}$  は  $\eta$ -平滑な凸関数.

各ラウンド  $t = 0, 1, 2, \dots, T$  において,

- 1  $s_{t+1} \leftarrow \arg \min_{s \in \mathcal{C}} s^\top \nabla f(\theta_{t+1})$  を計算.
- 2  $\theta_{t+1} = \theta_t + \lambda_t (s_{t+1} - \theta_t)$ ,  $\lambda_t \in [0, 1]$ .



$\lambda_t \in [0, 1]$  には様々な選択肢がある.

例:  $\lambda_t = \frac{2}{t+2}$  (Classic step),  $\lambda_t = \text{clip}_{[0,1]} \frac{\nabla f(\theta_t)^\top (\theta_t - s_{t+1})}{\eta \|\theta_t - s_{t+1}\|^2}$  (Short step), 等.

- $f(\theta_T) - f(\bar{\theta}) = O(\eta/T)$ .
- 一反復あたりの計算が非常に高速.  $\mathcal{C}$  が凸多面体  $\rightarrow$  LP.

**Fully-corrective FW:**  $\theta_{t+1} \in \arg \min_{\theta \in CH(\{s_1, s_2, \dots, s_{t+1}\})} f(\theta)$

- 過去に選んだ端点集合の凸包上で最適化問題を解く.
- 最も目的関数値を改善.

## フランク・ウルフ (FW) としてのブースティング

(1) で  $f$  の代わりに  $\tilde{f}$  を採用し, その Fenchel 双対問題を考える.

$$\max_{\theta \in -A\Delta_{\mathcal{H},1}} -\tilde{f}^*(\theta) := \max_{w \in \Delta_{\mathcal{H},1}} -\tilde{f}^*(-Aw) = \max_{w \in \Delta_{\mathcal{H},1}} - \left[ \max_d d^\top Aw - \tilde{f}(d) \right]$$

ここで,  $-A\Delta_{\mathcal{H},1} = \{-Aw \mid w \in \Delta_{\mathcal{H},1}\} \subset \mathbb{R}^m$  とおいた.

- 双対ギャップ 0.
- $\tilde{f}^*$  は  $L_\infty$ -ノルムに関して  $\eta$ -平滑 ( $\tilde{f}$  は  $L_1$ -ノルムに関して  $1/\eta$ -強凸).
- 分布  $d$  は, ある  $\theta = -Aw$  における  $f^*$ ,  $\tilde{f}^*$  の (劣) 勾配ベクトル.  
C-ERLPB.  $d_t^C = \nabla \tilde{f}^*(-Aw_t^C)$ .  
ERLPB.  $d_t^E = \nabla \tilde{f}^*(-Aw_t^E)$ , ただし  $w_t^E = \arg \min_{w \in CH(\{e_{h_1}, e_{h_2}, \dots, e_{h_t}\})} \tilde{f}^*(-Aw)$ .  
LPB.  $d_t^L \in \partial \tilde{f}^*(-Aw_t^L)$ , ただし  $w_t^L \in \arg \min_{w \in CH(\{e_{h_1}, e_{h_2}, \dots, e_{h_t}\})} \tilde{f}^*(-Aw)$ .
- FW の LP オラクルは最大エッジを返す弱学習器.

$$h_{t+1} \in \arg \max_{h \in \mathcal{H}} (d_t^\top A)_h \iff e_{h_{t+1}} \in \arg \max_{e \in \Delta_{\mathcal{H},1}} d_t^\top A e = \arg \min_{\theta \in -A\Delta_{\mathcal{H},1}} \theta^\top d_t$$

## 定理.

LPBoost, ERLPBoost, そして C-ERLPBoost は FW アルゴリズム.

## 提案スキーム

各ラウンド  $t = 0, 1, 2, \dots, T$  において,

- 1 分布  $d_t = \nabla \tilde{f}^*(-Aw_t) = \arg \min_{d \in \Delta_{m,\nu}} d^\top Aw_t + \frac{1}{\eta} \sum_{i=1}^m d_i \ln(m d_i)$  を計算.
- 2 仮説  $h_{t+1} \in \mathcal{H}$  を得る.
- 3  $\min_{q \leq t} (d_q^\top A)_{h_{q+1}} + \tilde{f}^*(-Aw_t) \leq \epsilon/2 \implies \text{break.}$
- 4  $w_{t+1}^F \in \Delta_{\mathcal{H},1}$  を FW 的に計算.
- 5  $w_{t+1}^B \in \Delta_{\mathcal{H},1}$  を任意に計算.
- 6  $w_{t+1} \in \arg \min_{w \in \{w_{t+1}^F, w_{t+1}^B\}} \tilde{f}^*(-Aw)$

## 定理.

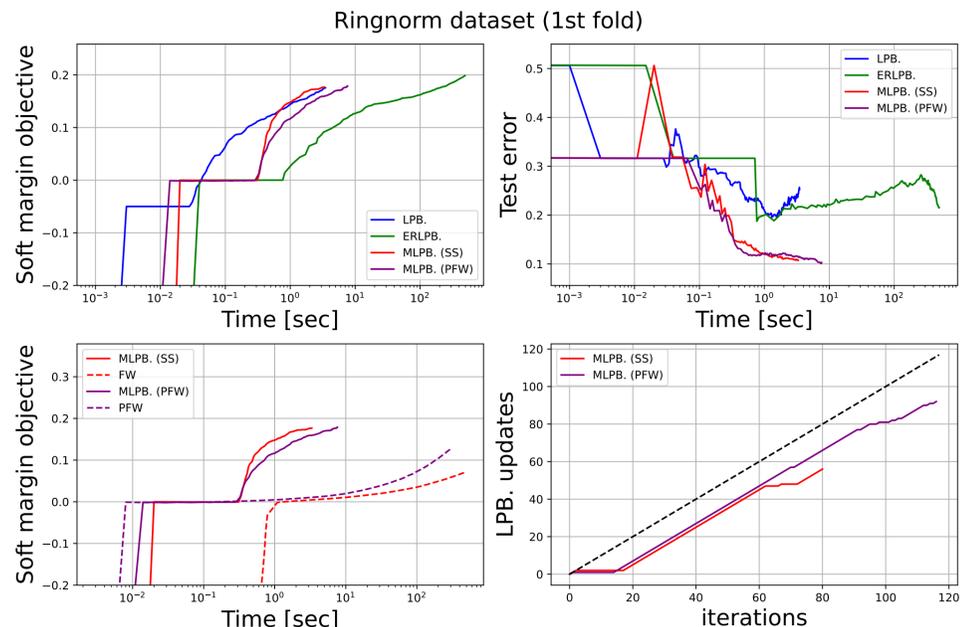
適切な  $w_{t+1}^F$  の更新の下, 提案スキームは高々  $T = O(\frac{1}{\epsilon^2} \ln \frac{m}{\nu})$  ラウンド後に  $-f^*(-Aw_T) \geq g - \epsilon$  を達成.

- $d_t = \nabla \tilde{f}^*(-Aw_t)$  は  $O(m \ln m)$  時間で計算可能.
- 各反復  $t$  において弱学習器が  $h_{t+1} \in \arg \max_{h \in \mathcal{H}} (d_t^\top A)_h$  を返す.  
 $\implies$  (2) の  $\epsilon$ -近似解を出力.
- $w_{t+1}^F$  の計算は各ラウンドで一定量の改善を保証する FW.  
 $\implies$  FW にも自由度がある.
- $w_{t+1}^B = \arg \min_{w \in CH(\{e_{h_1}, e_{h_2}, \dots, e_{h_{t+1}}\})} \tilde{f}^*(-Aw)$  で ERLPBoost になる.

## 実験

Gunnar Rätsch のベンチマークデータセット<sup>3</sup>で比較.

- パラメータ:  $\epsilon = 0.01$ ,  $\nu = 0.1m$ .
- 弱学習器: エッジが最大となる深さ 2 の決定木を返す.



## まとめと今後の課題

- ブースティングを FW として捉えた.
- FW に基づく新たなブースティングの枠組みを提案.  
■ LPBoost を組み込み, 理論保証付きで高速なブースティングを実現.
- 最悪ケースを除き, LPBoost は最速.  
 $\implies$  収束保証つきでより高速なブースティングはできるか?

<sup>3</sup>http://theoval.cmp.uea.ac.uk/~gcc/matlab/default.html#benchmarks.