

Budgeted stream-based active learning via adaptive submodular maximization

Kaito Fujii (UTokyo)

(joint work with Hisashi Kashima (KyotoU))

ERATO 感謝祭 Season IV

2017 年 8 月 3 日

目次

1 応用：プール型能動学習とストリーム型能動学習

2 既存研究：適応的劣モジュラ最大化

3 既存研究：劣モジュラ秘書問題

4 提案フレームワーク

5 実験


教師あり分類

入力

ラベルつきサンプルの集合 $\{(x_i, y_i) \in \mathcal{X} \times \mathcal{Y}\}_{i=1, \dots, n}$

出力

ラベルを予測する関数 $\hat{f}: \mathcal{X} \rightarrow \mathcal{Y}$



例) $\mathcal{X} = \mathbb{R}^2,$
 $\mathcal{Y} = \{\text{red}, \text{blue}\}$


教師あり分類

入力

ラベルつきサンプルの集合 $\{(x_i, y_i) \in \mathcal{X} \times \mathcal{Y}\}_{i=1, \dots, n}$

出力

ラベルを予測する関数 $\hat{f}: \mathcal{X} \rightarrow \mathcal{Y}$



例) $\mathcal{X} = \mathbb{R}^2$,
 $\mathcal{Y} = \{\text{red}, \text{blue}\}$

能動学習の動機

現実には

- ラベルなしサンプルはたくさん手に入るが、
- ラベル付与にはお金や時間がかかる

という状況が多い




能動学習

ラベルを付与するサンプルを**能動的に**選ぶことで、
少ないラベルつきサンプルで高い予測精度

プール型能動学習

ラベルなしサンプルは最初にすべて与えられる



ラベルなしサンプルの集合

$$V = \{x_i\}_{i=1, \dots, n} \subset \mathcal{X}$$




ラベル付与オラクル

$$\phi: V \rightarrow \mathcal{Y}$$


プール型能動学習

ラベルなしサンプルは最初にすべて与えられる



ラベルなしサンプルの集合

$$V = \{x_i\}_{i=1, \dots, n} \subset \mathcal{X}$$




ラベル付与オラクル

$$\phi: V \rightarrow \mathcal{Y}$$


プール型能動学習

ラベルなしサンプルは最初にすべて与えられる



ラベルなしサンプルの集合

$$V = \{x_i\}_{i=1, \dots, n} \subset \mathcal{X}$$




ラベル付与オラクル

$$\phi: V \rightarrow \mathcal{Y}$$


プール型能動学習

ラベルなしサンプルは最初にすべて与えられる



ラベルなしサンプルの集合

$$V = \{x_i\}_{i=1, \dots, n} \subset \mathcal{X}$$




ラベル付与オラクル

$$\phi: V \rightarrow \mathcal{Y}$$

プール型能動学習

ラベルなしサンプルは最初にすべて与えられる



ラベルなしサンプルの集合


$$V = \{x_i\}_{i=1, \dots, n} \subset \mathcal{X}$$

ラベル付与オラクル

$$\phi: V \rightarrow \mathcal{Y}$$

プール型能動学習

ラベルなしサンプルは最初にすべて与えられる



ラベルなしサンプルの集合

$$V = \{x_i\}_{i=1, \dots, n} \subset \mathcal{X}$$



ラベル付与オラクル

$$\phi: V \rightarrow \mathcal{Y}$$

ストリーム型能動学習

ラベルなしサンプルは一つずつ現れる

n 個のうち k 個にラベル付与する設定を考える (n, k 既知)



ラベルなしサンプルの集合

$$V = \{x_i\}_{i=1, \dots, n} \subset \mathcal{X}$$

ラベル付与オラクル

$$\phi: V \rightarrow \mathcal{Y}$$

ストリーム型能動学習

ラベルなしサンプルは一つずつ現れる

n 個のうち k 個にラベル付与する設定を考える (n, k 既知)



ラベルなしサンプルの集合

$$V = \{x_i\}_{i=1, \dots, n} \subset \mathcal{X}$$




ラベル付与オラクル

$$\phi: V \rightarrow \mathcal{Y}$$

ストリーム型能動学習

ラベルなしサンプルは一つずつ現れる

n 個のうち k 個にラベル付与する設定を考える (n, k 既知)



ラベルなしサンプルの集合

$$V = \{x_i\}_{i=1, \dots, n} \subset \mathcal{X}$$


ラベル付与オラクル

$$\phi: V \rightarrow \mathcal{Y}$$

ストリーム型能動学習

ラベルなしサンプルは一つずつ現れる

n 個のうち k 個にラベル付与する設定を考える (n, k 既知)



ラベルなしサンプルの集合

$$V = \{x_i\}_{i=1, \dots, n} \subset \mathcal{X}$$


ラベル付与オラクル

$$\phi: V \rightarrow \mathcal{Y}$$

ストリーム型能動学習


ラベルなしサンプルは一つずつ現れる

n 個のうち k 個にラベル付与する設定を考える (n, k 既知)



ラベルなしサンプルの集合

$$V = \{x_i\}_{i=1, \dots, n} \subset \mathcal{X}$$




ラベル付与オラクル

$$\phi: V \rightarrow \mathcal{Y}$$

ストリーム型能動学習

ラベルなしサンプルは一つずつ現れる

n 個のうち k 個にラベル付与する設定を考える (n, k 既知)



ラベルなしサンプルの集合

$$V = \{x_i\}_{i=1, \dots, n} \subset \mathcal{X}$$


ラベル付与オラクル

$$\phi: V \rightarrow \mathcal{Y}$$

ストリーム型能動学習

ラベルなしサンプルは一つずつ現れる

n 個のうち k 個にラベル付与する設定を考える (n, k 既知)



ラベルなしサンプルの集合

$$V = \{x_i\}_{i=1, \dots, n} \subset \mathcal{X}$$

ラベル付与オラクル


$$\phi: V \rightarrow \mathcal{Y}$$

本研究の概要

ストリーム型能動学習のための組合せ最適化フレームワーク


プール型能動学習

ラベルなしサンプルはすべて既知



ストリーム型能動学習

サンプルはひとつずつ現れる



適応的劣モジュラ最大化
[Golovin-Krause'11]

新たなフレームワーク
(本研究)

劣モジュラ秘書問題
[Bateni-Hajiaghayi-Zadimoghaddam'13]

目次

1 応用：プール型能動学習とストリーム型能動学習

2 既存研究：適応的劣モジュラ最大化

3 既存研究：劣モジュラ秘書問題

4 提案フレームワーク

5 実験

劣モジュラ最大化

与えられた集合 V の “よい” 部分集合を探す問題

Maximize $f(S)$

subject to $|S| \leq k$


$f: 2^V \rightarrow \mathbb{R}$

単調劣モジュラ関数

例) データセット V を要約する部分集合を探す問題

$$f \left(\begin{array}{c} \circ \quad \circ \quad \circ \quad \circ \\ \circ \quad \circ \quad \circ \quad \circ \\ \circ \quad \circ \quad \circ \quad \circ \end{array} \right) > f \left(\begin{array}{c} \circ \quad \circ \quad \circ \quad \circ \\ \circ \quad \circ \quad \circ \quad \circ \\ \circ \quad \circ \quad \circ \quad \circ \end{array} \right)$$

適応的な設定



観測したラベルによって次に選ぶサンプルを変えられる
→ 同じアルゴリズムでも、目的関数値が変化

適応的劣モジュラ最大化 [Golovin-Krause'11]

オラクルに関する事前分布を考え、目的関数の期待値を最大化

劣モジュラ性と単調性

$$f(v|S) \triangleq f(S \cup \{v\}) - f(S)$$


$S \subseteq V$ に対して $v \in V$ を追加したときの増分

劣モジュラ性と単調性

$$f(v|S) \triangleq f(S \cup \{v\}) - f(S)$$

$S \subseteq V$ に対して $v \in V$ を追加したときの増分

劣モジュラ性 $f(v|A) \geq f(v|B) \quad (\forall A \subseteq B, \forall v \in V \setminus B)$




劣モジュラ性と単調性

$$f(v|S) \triangleq f(S \cup \{v\}) - f(S)$$

$S \subseteq V$ に対して $v \in V$ を追加したときの増分

劣モジュラ性 $f(v|A) \geq f(v|B) \quad (\forall A \subseteq B, \forall v \in V \setminus B)$



単調性 $f(v|A) \geq 0 \quad (\forall A \subseteq V, \forall v \in V)$

$$f(\text{yellow circle} \bullet) - f(\text{yellow circle}) \geq 0$$

$\Delta(v|\psi)$

オラクルから $\psi = \{(v_i, y_i)\}_{i=1, \dots, \ell}$ を観測しているとき、
新たに $v \in V$ を追加した場合の**増分の期待値**

適応的劣モジュラ性

$$\Delta(v|\psi_1) \geq \Delta(v|\psi_2) \quad (\forall \psi_1 \subseteq \psi_2, \forall v \in V \setminus \text{dom}(\psi_2))$$

適応的単調性

$$\Delta(v|\psi) \geq 0 \quad (\forall \psi, \forall v \in V)$$

目次

1 応用：プール型能動学習とストリーム型能動学習

2 既存研究：適応的劣モジュラ最大化

3 既存研究：劣モジュラ秘書問題

4 提案フレームワーク

5 実験

問題

ランダムな順序で n 人の候補を面接する (n は既知)
面接したら直ちに採用するかどうか決める

アルゴリズム

最初の $\lfloor n/e \rfloor$ 人は採用しない
それ以降にその時点までで最良の候補が現れたら採用
→ $1/e$ 以上の確率で最良の候補を採用できる

問題

ランダムな順序で n 人の候補を面接する (n は既知)
面接したら直ちに採用するかどうか決める

アルゴリズム

最初の $\lfloor n/e \rfloor$ 人は採用しない
それ以降にその時点までで最良の候補が現れたら採用
→ $1/e$ 以上の確率で最良の候補を採用できる

$$n = 10$$



古典的秘書問題 [folklore'60s]

問題

ランダムな順序で n 人の候補を面接する (n は既知)
面接したら直ちに採用するかどうか決める

アルゴリズム

最初の $\lfloor n/e \rfloor$ 人は採用しない
それ以降にその時点までで最良の候補が現れたら採用
→ $1/e$ 以上の確率で最良の候補を採用できる

$$n = 10$$



3



4

古典的秘書問題 [folklore'60s]

問題

ランダムな順序で n 人の候補を面接する (n は既知)
面接したら直ちに採用するかどうか決める

アルゴリズム

最初の $\lfloor n/e \rfloor$ 人は採用しない
それ以降にその時点までで最良の候補が現れたら採用
→ $1/e$ 以上の確率で最良の候補を採用できる

$$n = 10$$



古典的秘書問題 [folklore'60s]


問題

ランダムな順序で n 人の候補を面接する (n は既知)
面接したら直ちに採用するかどうか決める

アルゴリズム

最初の $\lfloor n/e \rfloor$ 人は採用しない
それ以降にその時点までで最良の候補が現れたら採用
→ $1/e$ 以上の確率で最良の候補を採用できる

$$n = 10$$



古典的秘書問題 [folklore'60s]


問題

ランダムな順序で n 人の候補を面接する (n は既知)
面接したら直ちに採用するかどうか決める

アルゴリズム

最初の $\lfloor n/e \rfloor$ 人は採用しない
それ以降にその時点までで最良の候補が現れたら採用
→ $1/e$ 以上の確率で最良の候補を採用できる

$$n = 10$$




古典的秘書問題 [folklore'60s]

問題

ランダムな順序で n 人の候補を面接する (n は既知)
面接したら直ちに採用するかどうか決める

アルゴリズム

最初の $\lfloor n/e \rfloor$ 人は採用しない
それ以降にその時点までで最良の候補が現れたら採用
→ $1/e$ 以上の確率で最良の候補を採用できる



劣モジュラ秘書問題 [Bateni-Hajiaghayi-Zadimoghaddam'13]

ランダムな順序で現れる n 人の候補のなかから k 人を選ぶ
単調劣モジュラ関数 $f: 2^V \rightarrow \mathbb{R}$ を最大化

$n = 10, k = 3$



競合比

$\alpha \in [0, 1]$ がアルゴリズムの競合比



任意の問題例について，アルゴリズムの解 S が

$$\mathbb{E}[f(S)] \geq \alpha \max_{S^* \subseteq V} f(S^*)$$

を満たす

入力をすべて知っている場合の最適値

目次

1 応用：プール型能動学習とストリーム型能動学習

2 既存研究：適応的劣モジュラ最大化

3 既存研究：劣モジュラ秘書問題

4 提案フレームワーク

5 実験

提案フレームワークの仮定

仮定 1 ストリームの順序に**ランダム性**を仮定

仮定 2 全体のサンプル数 n は既知だと仮定

仮定 3 目的関数に**方策適応的劣モジュラ性**を仮定

- 適応的劣モジュラ性よりも強い性質
- 応用で使われる多くの関数で成り立っている

適応的劣モジュラ性との比較

劣モジュラ性

$$\begin{aligned} f(A \cup \{v\}) - f(A) &\geq \\ f(B \cup \{v\}) - f(B) \\ (\forall A \subseteq B, v \in V \setminus B) \end{aligned}$$



適応的設定に拡張


適応的劣モジュラ性

$$\begin{aligned} \Delta(v|\psi_A) &\geq \Delta(v|\psi_B) \\ (\forall \psi_A \subseteq \psi_B, v \in V \setminus B) \end{aligned}$$

適応的劣モジュラ性との比較

劣モジュラ性

$$\begin{aligned} f(A \cup \{v\}) - f(A) &\geq \\ f(B \cup \{v\}) - f(B) & \\ (\forall A \subseteq B, v \in V \setminus B) & \end{aligned}$$



$$\begin{aligned} f(A \cup P) - f(A) &\geq \\ f(B \cup P) - f(B) & \\ (\forall A \subseteq B, P \subseteq V \setminus B) & \end{aligned}$$




適応的設定に拡張

適応的劣モジュラ性

$$\begin{aligned} \Delta(v|\psi_A) &\geq \Delta(v|\psi_B) \\ (\forall \psi_A \subseteq \psi_B, v \in V \setminus B) & \end{aligned}$$

適応的劣モジュラ性との比較



方策適応的劣モジュラ関数の性質

補題 [Feige-Mirrokni-Vondrák'07]

$f: 2^V \rightarrow \mathbb{R}$ 劣モジュラ関数.

$A(r): A \subseteq V$ の各要素を確率 r で含む集合.

$$\mathbb{E}[f(A(r))] \geq (1-r)f(\emptyset) + rf(A)$$

方策適応的劣モジユラ関数の性質

補題 [Feige-Mirroknj-Vondrák'07]

$f: 2^V \rightarrow \mathbb{R}$ 劣モジユラ関数.

$A(r)$: $A \subseteq V$ の各要素を確率 r で含む集合.

$$\mathbb{E}[f(A(r))] \geq (1-r)f(\emptyset) + rf(A)$$



適応的設定に拡張

補題 [Fujii-Kashima'16]

$(\{f_\phi\}_\phi, \rho)$ 方策適応的劣モジユラ関数.


$\pi(r)$: 方策 π から各要素を確率 $1-r$ で削除してできる方策.

$$\mathbb{E}[f_\phi(A(\pi(r), \phi))] \geq (1-r)\mathbb{E}[f_\phi(\emptyset)] + r\mathbb{E}[f_\phi(A(\pi, \phi))]$$

適応的ストリームアルゴリズム

ストリーム設定 限られたメモリの範囲でサンプルを保持

ストリーム全体を k 分割し、
各部分ストリームから増分の期待値最大のサンプルを選択




定理 [Fujii-Kashima'16]

このアルゴリズムの競合比は $(2 - \sqrt{3})(1 - 1/e) \approx 0.16$.

適応的秘書アルゴリズム

秘書設定 ラベルを付与するかどうかすぐに判断

各部分ストリームに古典的秘書アルゴリズムを適用して、増分の期待値最大のサンプルを確率 $1/e$ で選ぶ



定理 [Fujii-Kashima'16]

このアルゴリズムの競合比は $\frac{1-1/e}{2e\sqrt{1+2/e}} \approx 0.08$.

目次

1 応用：プール型能動学習とストリーム型能動学習

2 既存研究：適応的劣モジュラ最大化

3 既存研究：劣モジュラ秘書問題

4 提案フレームワーク

5 実験

データセット


- WDBC ($n = 596$, 32 次元)
- MNIST ($n = 14780$, PCA で 10 次元に削減)

比較手法


- 不確実性サンプリング
- ランダムサンプリング

提案手法は ALuMA [Gonen+13] に基づいて設計

実験結果




WDBC



MNIST

それぞれの設定で

提案手法は比較手法よりも誤差が小さい




本研究の概要

ストリーム型能動学習のための組合せ最適化フレームワーク


プール型能動学習

ラベルなしサンプルはすべて既知



ストリーム型能動学習

サンプルはひとつずつ現れる



適応的劣モジュラ最大化
[Golovin-Krause'11]

新たなフレームワーク
(本研究)

劣モジュラ秘書問題
[Bateni-Hajiaghayi-Zadimoghaddam'13]