

「学習問題の統合的帰着」

研究期間: 2020年11月～2023年3月

研究者: 末廣 大貴

加速フェーズ期間: 2023年4月～2024年3月

1. 研究のねらい

学習問題は、しばしば分類問題、回帰問題、ランキング問題といったタスクの種類や、「弱教師あり」「教師なし」といったデータの条件などに基づいて体系化されている。それに伴い、多くの研究ではタスクのドメインごとに学習問題の定式化や解法アルゴリズムの解析が行われている。しかし、実験的な解析のみが行われ、理論解析が充分になされていないことも多い。昨今の人工知能ブームに伴い、学習問題が増加の一途を辿る中、定式化は煩雑化しており、一般的な数理解析が行いづらいというのが最大の要因である。

理論解析を大幅に加速するためには、これまでのタスク・ドメイン依存の個別解析から脱却し、なんらかの方法で統合的に解析を行っていく必要がある。ここで、ある複数の問題が「統合的に理論解析可能」というのは、それらがある1つの学習問題に帰着できるということを意味する。「学習問題の帰着」とは、ある学習問題を、別の学習問題に変換することで解法を導き出すことである。例えば、学習問題 A が学習問題 B に帰着可能であれば、学習問題 B の解法アルゴリズムや、理論性能(計算量や汎化誤差など)を転用することができる。つまり、たとえ異なるタスク・データ条件であっても、ある別の学習問題に帰着することができれば、統合的に理論解析が行える。

本研究では、**学習問題の統合的理論解析を目指した帰着手法の開発**する。端的に言えば、学習問題の統合化に特化した帰着手法の開発である。学習問題を統合的に帰着できれば、これまでの個別解析からの脱却が可能となり、「どのようなアルゴリズムを用いて、どれくらいの計算量で解くことができ、どのような理論性能が保証できるか」をまとめて解析することが可能である。

加速フェーズ期間における目的は、学習問題の統合的帰着による**学習問題の体系化および実用性の立証**である。具体的には、経験誤差最小化(Empirical Risk Minimization, ERM)に基づく帰着スキーム[1](以下, ERM-reduction scheme)によって導かれる、①**学習問題のクラスを明らかにすること**、および、②**ERM-reduction scheme に基づく、理論性能保証を見据えた学習問題の創出**である。①、②ともに、これまでに基礎的な成果が得られているマルチインスタンス学習問題を題材とし、マルチインスタンス学習に帰着可能な学習問題のクラスに関する理論解析、および、マルチインスタンス学習問題の周辺の新問題創出を実施した。

2. 研究成果

(1)概要

機械学習問題における、経験誤差最小化問題の一般化帰着スキームを開発した。具体的には、ある機械学習問題 A と学習問題 B があり、A と B の損失が一致するようなインスタンスのペア(入力, 出力)変換関数, ならびに仮説変換関数が存在するとき, A が B に帰着可能であるという、経験誤差最小化帰着スキームを開発した。これにより, B の理論解析結果を用い, 汎化性能の導出および学習アルゴリズムが即時に適用できる。マルチインスタンス学習(MIL)問題について, 本帰着スキームの適用を考え, 帰着可能な問題に適用可能な汎化性能と, 学習アルゴリズムを示した。古典的な機械学習問題から, 近年提案された機械学習問題まで, 様々な学習問題が帰着可能であることを示した。具体的には, マルチクラス学習問題, マルチラベル学習問題, 補ラベル学習問題, マルチタスク学習問題が MIL 問題に帰着可能であることを証明した。また, MIL への帰着スキームをもとに, 新たな学習問題(最上位アイテム学習問題, negative feedback 付き最上位アイテム学習問題, perfectionistic loss に基づくマルチラベル学習)を提案し, いずれも MIL 問題に帰着可能であることを示した。補ラベル学習問題に, 本帰着に基づく学習アルゴリズムを実装し, 実用的にも有用であることを示した。最後に, 本研究は人工知能理論トップ会議である UAI2022 で発表を行った[1]。また, 本研究における直接的な成果ではないものの, 本研究の活動の一部であった「様々な分野の研究者との交流を通して様々な学習問題に関する定式化と理論の広く深く理解する」活動により, 署名照合問題における上位特化学習問題に関する定式化に着手し, 新たな署名照合学習アルゴリズムを開発した。また, 実験結果において, 署名照合分野において既存手法を上回る性能を示した。共著者らとともに国際会議 DAS2022 で発表を行い, Best Student Paper Award を受賞した[2]。

加速フェーズにおいては, 理論解析では大きな成果はまとめられていないが, 計算性複雑性理論を参考に様々な理論解析のアプローチを行い, 帰着可能な問題の定式化の見直しに成功している。今後さらに解析を進めていく。

実用化, 新問題の創出に関しては, マルチインスタンス学習問題に類似した問題設定として知られている Learning from Label Proportion (LLP)問題へ取り組み, また, 新問題として Learning from Majority Label(LML)問題を創出した。LLP に関しては, MIL への解析結果である「バグ数が多いほど汎化性能が改善する」という議論に基づき, バグ数を拡張する手法および新しい学習アルゴリズムを提案し, コンピュータビジョンのトップ会議である ICCV2023 で発表した[4]。LML に関しては, 問題の定式化および, 従来の MIL 手法とは一線を画した「クラスに属すると推定されるデータをカウントする」というアプローチを提案し, ICASSP2024[5]に採択済みである。実は LML は, インスタンスの分類を行うという設定により, 統合的帰着そのものを活かすことはできなかったが, MIL よりも「難しそうである」問題があること, すなわち MIL に帰着不可能でありそうな問題を発見したことは理論解析への大きな一歩となった。

また, 加速フェーズ期間中にも, 本研究の成功に大きく寄与する活動である「様々な分野の研究者との交流を通して様々な学習問題に関する定式化」を進め, 署名照合問題における高信頼度学習技術[Ji et al., Pattern Recognition(パターン認識トップジャーナル)], ノイズラ

ベルデータに対する効率的かつ高精度な学習手法[Song et al., Machine Learning (機械学習トップジャーナル)]を提案した。また、新しい学習問題の創出も行っており、マルチクラス分類において特定のクラスだけの精度が悪化してしまう問題を最悪クラス誤差最小化問題として定式化し、Boosting の枠組み解くアルゴリズムを開発した。arXiv にてプレプリントを発行済みである。

(2) 詳細

本研究の目的は、大きく4つのテーマ分けられ、以下 A~D を明らかにすることである: A. MIL 問題へ帰着するための統合的帰着手法, B. MIL 問題に帰着可能な問題の具体的な性質, C. MIL への帰着の実用性, D. 統合的帰着手法の一般形の指針。

加速フェーズにおける目的は、以下の E, F を明らかにすることである: E. MIL に帰着可能な学習問題の特徴づけ, F. MIL 周辺の新問題創出および、理論解析を見据えた定式化。

D. 統合的帰着手法の一般形の指針

機械学習問題における、経験誤差最小化問題 (Empirical Risk Minimization) の一般化帰着スキーム (以下, ERM-reduction scheme) を開発した。具体的には、ある機械学習問題 A と学習問題 B があり、A と B の損失が一致するようなインスタンスのペア (入力, 出力) 変換関数、ならびに仮説変換関数が存在するとき、A が B に経験後最小化問題について帰着可能であるという、ERM-reduction scheme を開発した。これにより、B の理論解析結果を用い、汎化性能の導出および学習アルゴリズムが即時に適用できる。概要を次図に示す。まず、上部にある定義により ERM-reducible scheme を提案し、経験誤差最小化に関する A と B の関係、ならびに汎化性能 (Rademacher complexity) に関する A と B の関係を導出した。

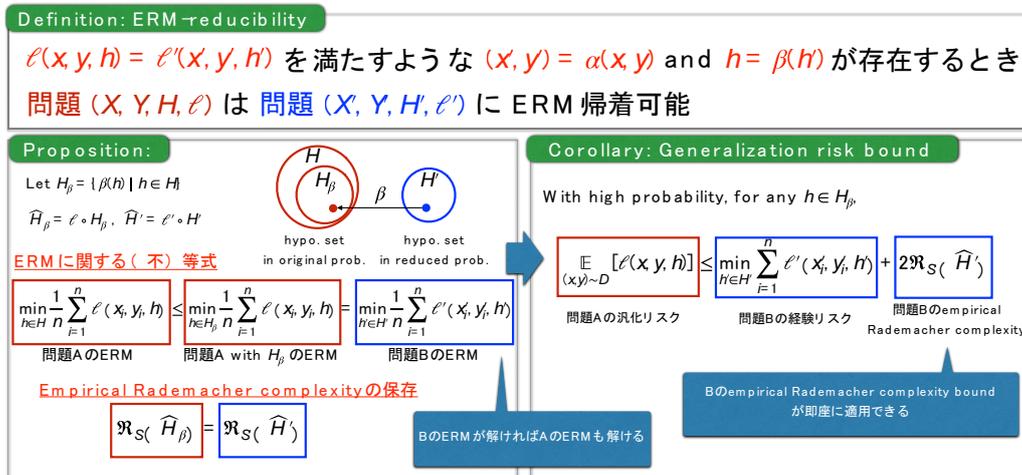


図 1: ERM-reduction scheme

A. MIL 問題へ帰着するための統合的帰着手法 および B. MIL 問題に帰着可能な問題の具体的な性質

マルチインスタンス学習 (MIL) 問題について、ERM-reduction scheme の適用を考え、帰着可能な問題が持つべき具体的な性質、および帰着可能な問題に適用可能な汎化性能と、学習アルゴリズムを示した。概要を次図に示す。

Definition: MIL-reducibility

問題 (X, Y, H, ℓ) が MIL 帰着可能 とは
 MIL Problem (X, Y, H, ℓ) が存在し (X, Y, H, ℓ) が (X, Y, H, ℓ) にERM 帰着可能であること.

MILの定義を踏まえると, MIL帰着可能であるための条件は:

$$\ell(x, y, h) = f_1(y \Psi_\rho(\{f_2(g(z)) \mid z \in X\})) \text{ を満たすような}$$

$$(X, y) = \alpha(x, y) \text{ and } h = \beta(h) \text{ が存在すること}$$

図 2: MIL 帰着可能な問題の具体的性質

図 2 は, 「なんらかの値の集合」を ρ -norm 関数で統合した式を目的関数にもつような学習問題は MIL に帰着可能であることを示唆し, 実際に様々な学習問題が帰着可能である(後述).

Theorem: Generalization risk bound for MIL-reducible problems

based on [Sabato and Tishby, 2012]

訓練サンプルを $S = ((x_1, y_1), \dots, (x_n, y_n))$ とし, 平均バグサイズを r_S とする.

$\widehat{G} = \{f_2 \circ g \mid g \in G\}$ とする. もし \widehat{G} の empirical Rademacher complexity が以下のような形でバウンドできるとき:

$$\mathfrak{R}_S(\widehat{G}) \leq \frac{C \ln^\rho(n)}{\sqrt{n}} \quad (C \text{ and } \rho \geq 0 \text{ are some values})$$

以下が成り立つ.

$$\mathfrak{R}_S(\widehat{H}) = O\left(\frac{\log(a^2 n^2 r_S) \left(\frac{aC}{\rho+1} \ln^{\rho+1}(a^2 n)\right)}{\sqrt{n}}\right)$$

図 3: MIL 帰着可能な問題に適用できる汎化性能のバウンド

$G = \{g: x \mapsto \langle w, x \rangle \mid w \in \mathbb{R}^q\}$ (線形関数) の場合を考える

Proposition: convex ERM

もし $y_i = -1 (i \in \{1, \dots, n\})$ で, f_1 非増加凸関数,
 f_2 が非減少凸関数のとき, 帰着したMILのERMは **凸計画問題** である.

one-class MIL に帰着

Proposition: DC (Difference of convex) ERM

f_1 が非増加凸関数かつ $f_1(c)$ が $c \in [-1, 1]$ において 次数 1 の斉次関数 (homogenous function)
 f_2 が非減少凸関数のとき, 帰着したMILのERMは **DC 計画問題** である.

$$f_1(ac) = af_1(c)$$

2クラス MIL に帰着

図 4: MIL 帰着可能な問題に対する最適化アルゴリズム

図 3 の結果より, 従来タスクごとに解析を行って導出していた汎化誤差の導出が, 帰着により容易に導出可能となる. また, 図 4 の結果より, 学習アルゴリズムが即座に設計でき, タスクごとにスクラッチから実装する必要がなくなる.

また, 古典的な機械学習問題から, 近年提案された機械学習問題まで, 様々な学習問題が帰着可能であることを示した. 具体的には, マルチクラス学習問題, マルチラベル学習問題, 補ラベル学習問題, マルチタスク学習問題が MIL 問題に帰着可能であることを証明し

た. また, MIL への帰着スキームをもとに, 新たな学習問題(最上位アイテム学習問題, negative feedback 付き最上位アイテム学習問題, perfectionistic loss に基づくマルチラベル学習)を提案し, いずれも MIL 問題に帰着可能であることを示した. これにより, これらの問題の汎化性能及びアルゴリズムを統合的かつ簡易的に導出可能となる. 結果の概要を次図に示す.

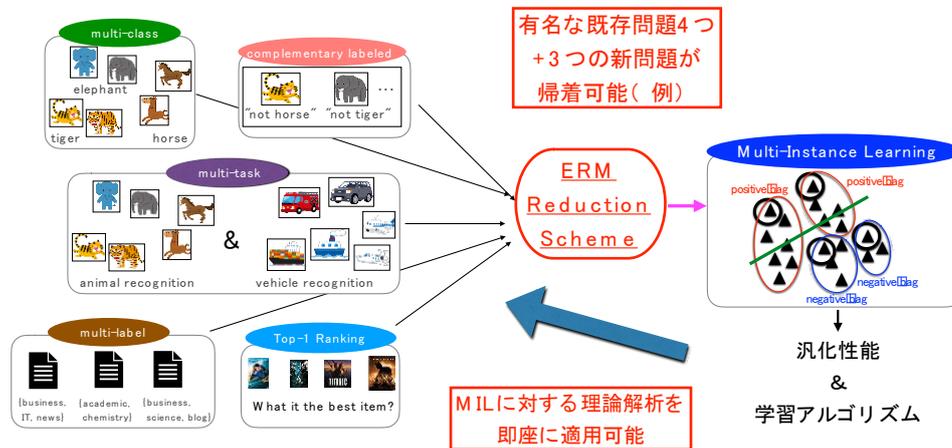


図 5: MIL 帰着可能な問題の例

C. MIL への帰着の実用性

最後に, 提案した一般化帰着スキームならびに MIL への帰着の実用的な有用性を示した. 具体的には, 補ラベル学習問題に対し, 本帰着スキームで導出した学習シナリオを適用した. 人工データおよび実データ

Dataset	Class	Dim.	Ours	Ishida+
artificial1	5	50	0.9999	0.9998
artificial2	10	50	0.808	0.646
artificial3	25	50	0.063	0.065
covertype	7	54	0.562	0.549
satimage	7	36	0.804	0.751
waveform	3	40	0.833	0.832
yeast	10	8	0.348	0.407

に対し, 既存のアルゴリズム (Ishida et al., 2017) と比較した結果を図 3 に示す. 多くのデータセットに対して高い精度を残しており, 提案した帰着スキームが実用的にも有用であることが確認できた. また, 導出した学習アルゴリズムが, 凸計画法または DC 計画法となることから, 経験誤差最小化に必要なハイパーパラメータが既存手法と比べて大きく低減できていることも示した.

本研究の目的は, 大きく4つのテーマ分けられ, 以下 A~D を明らかにすることである: A. MIL 問題へ帰着するための統合的帰着手法, B. MIL 問題に帰着可能な問題の具体的な性質, C. MIL への帰着の実用性, D. 統合的帰着手法の一般形の指針.

加速フェーズにおける目的は, 以下の E, F を明らかにすることである: E. MIL に帰着可能な学習問題の特徴づけ, F. MIL 周辺の新問題創出および, 理論解析を見据えた定式化.

D. 統合的帰着手法の一般形の指針

機械学習問題における, 経験誤差最小化問題 (Empirical Risk Minimization) の一般化帰着スキーム (以下, ERM-reduction scheme) を開発した. 具体的には, ある機械学習問題 A と学習問題 B があり, A と B の損失が一致するようなインスタンスのペア (入力, 出力) 変換関数, ならびに仮説変換関数が存在するとき, A が B に経験後最小化問題について帰着可能であるという, ERM-reduction scheme を開発した. これにより, B の理論解析結果を用い,

汎化性能の導出および学習アルゴリズムが即時に適用できる。概要を次図に示す。まず、上部にある定義によりERM-reducible schemeを提案し、経験誤差最小化に関するAとBの関係、ならびに汎化性能(Rademacher complexity)に関するAとBの関係を導出した。

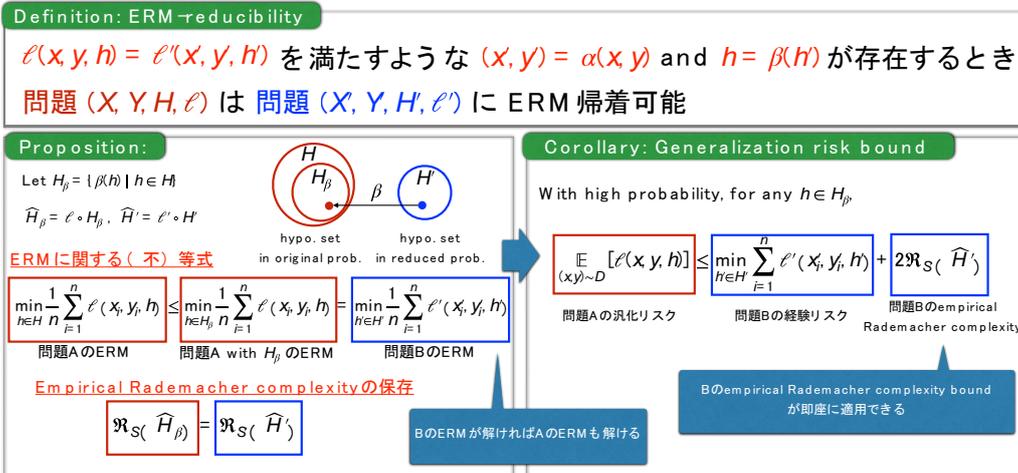
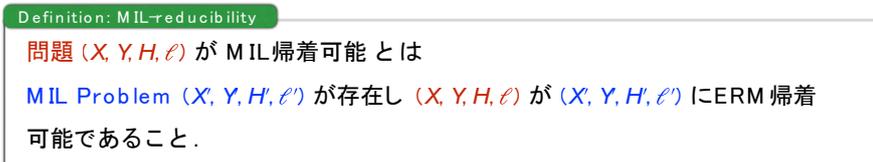


図 6: ERM-reduction scheme

A. MIL 問題へ帰着するための統合的帰着手法 および B. MIL 問題に帰着可能な問題の具体的な性質

マルチインスタンス学習(MIL)問題について、ERM-reduction schemeの適用を考え、帰着可能な問題が持つべき具体的な性質、および帰着可能な問題に適用可能な汎化性能と、学習アルゴリズムを示した。概要を次図に示す。



MILの定義を踏まえると、MIL帰着可能であるための条件は:

$$\ell(x, y, h) = f_1(y \Psi_\rho(\{f_2(g(z)) \mid z \in X\}))$$

を満たすような

$$(x, y) = \alpha(x, y) \text{ and } h = \beta(h') \text{ が存在すること}$$

図 7: MIL 帰着可能な問題の具体的な性質

図 2 は、「なんらかの値の集合」を p-norm 関数で統合した式を目的関数にもつような学習問題は MIL に帰着可能であることを示唆し、実際に様々な学習問題が帰着可能である(後述)。

Theorem: Generalization risk bound for MIL-reducible problems based on [Sabato and Tishby, 2012]

訓練サンプルを $S = ((x_1, y_1), \dots, (x_n, y_n))$ とし, 平均バグサイズを r_S とする.

$\widehat{G} = \{f_2 \circ g \mid g \in G\}$ とする. もし \widehat{G} の empirical Rademacher complexity が以下のような形でバウンドできるとき:

$$\mathfrak{R}_S(\widehat{G}) \leq \frac{C \ln^{\rho}(n)}{\sqrt{n}} \quad (\text{C and } \rho \geq 0 \text{ are some values})$$

以下が成り立つ.

$$\mathfrak{R}_S(\widehat{H}) = O\left(\frac{\log(a^2 n^2 r_S) \left(\frac{aC}{\rho+1} \ln^{\rho+1}(a^2 n)\right)}{\sqrt{n}}\right)$$

図 8: MIL 帰着可能な問題に適用できる汎化性能のバウンド

$G = \{g: x \mapsto \langle w, x \rangle \mid w \in \mathbb{R}^q\}$ (線形関数) の場合を考える

Proposition: convex ERM

もし $y_i = -1 (i \in \{1, \dots, n\})$ で, f_1 非増加凸関数,
 f_2 が非減少凸関数のとき, 帰着した MIL の ERM は **凸計画問題** である.

one-class MIL に帰着

Proposition: DC (Difference of convex) ERM

f_1 が非増加凸関数かつ $f_1(c)$ が $c \in [-1, 1]$ において 次数 1 の斉次関数 (homogeneous function)
 f_2 が非減少凸関数のとき, 帰着した MIL の ERM は **DC 計画問題** である.

$$f_1(ac) = af_1(c)$$

2クラス MIL に帰着

図 9: MIL 帰着可能な問題に対する最適化アルゴリズム

図 3 の結果より, 従来タスクごとに解析を行って導出していた汎化誤差の導出が, 帰着により容易に導出可能となる. また, 図 4 の結果より, 学習アルゴリズムが即座に設計でき, タスクごとにスクラッチから実装する必要がなくなる.

また, 古典的な機械学習問題から, 近年提案された機械学習問題まで, 様々な学習問題が帰着可能であることを示した. 具体的には, マルチクラス学習問題, マルチラベル学習問題, 補ラベル学習問題, マルチタスク学習問題が MIL 問題に帰着可能であることを証明した. また, MIL への帰着スキームをもとに, 新たな学習問題(最上位アイテム学習問題, negative feedback 付き最上位アイテム学習問題, perfectionistic loss に基づくマルチラベル学習)を提案し, いずれも MIL 問題に帰着可能であることを示した. これにより, これらの問題の汎化性能及びアルゴリズムを統一的かつ簡易的に導出可能となる. 結果の概要を次図に示す.

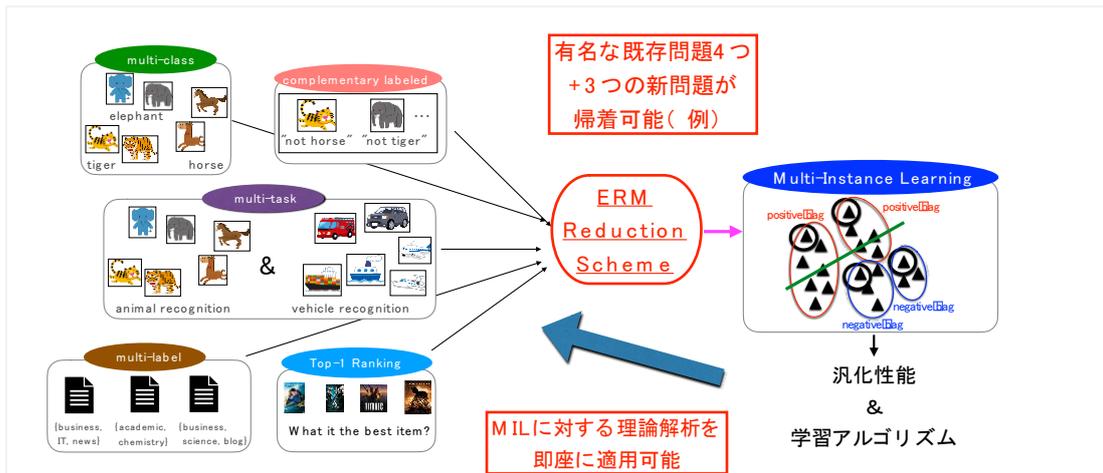


図 10: MIL 帰着可能な問題の例

C. MIL への帰着の実用性

最後に、提案した一般化帰着スキームならびに MIL への帰着の実用的な有用性を示した。具体的には、補ラベル学習問題に対し、本帰着スキームで導出した学習シナリオを適用した。人工データおよび実データ

Dataset	Class	Dim.	Ours	Ishida+
artificial1	5	50	0.9999	0.9998
artificial2	10	50	0.808	0.646
artificial3	25	50	0.063	0.065
covertype	7	54	0.562	0.549
satimage	7	36	0.804	0.751
waveform	3	40	0.833	0.832
yeast	10	8	0.348	0.407

に対し、既存のアルゴリズム (Ishida et al., 2017) と比較した結果を図 3 に示す。多くのデータセットに対して高い精度を残しており、提案した帰着スキームが実用的にも有用であることが確認できた。また、導出した学習アルゴリズムが、凸計画法または DC 計画法となることから、経験誤差最小化に必要なハイパーパラメータが既存手法と比べて大きく低減できていることも示した。

加速フェーズ:

E. MIL に帰着可能な学習問題の特徴づけ

これまでの成果から、MIL に帰着可能な問題のクラス、すなわち MIL 完全なクラスの存在が示唆される。一方で、ある問題があるクラスに属するか、を効率的に判定するためには、クラスの「良い特徴づけ」が必要となる。現状の帰着の枠組みでは、帰着のプロセス(図 1 の α , β) を問題ごとに設計する必要がある。すなわち、MIL に帰着可能な問題かを判定するためには、 α , β が存在するかどうかの判定を行う必要があり、これは多項式時間で行うことができない。

様々なアプローチを検討した結果、帰着プロセスの見直しを検討している。今後さらに解析を進め、クラス MIL の特徴づけを明らかにする。

F. MIL 周辺の問題に対する、理論解析を見据えた定式化

本研究の実用研究、特に MIL 周辺の問題に対する実用研究を行った。Learning from Label Proportion (LLP) は、MIL 同様インスタンスの集合(バッグ)が入力で、ラベルとしてバッグ内インスタンスのクラス割合が付与されるような問題である。クラス割合が一致するような学習を行うことで、最終的には各インスタンスの分類を目的とする。従来、LLP の難しさはバッグ

に含まれるインスタンス数によって特徴づけられていたが、これまでの研究成果から、バッグの数が多くなるほど汎化誤差が小さくなることに着目し、予備実験によりこの事実を確認した。また、バッグを拡張、すなわちバッグ数を人工的に増加させる手法を提案し、従来手法を上回る性能を達成した。LLP の問題設定およびデータ拡張手法の概要を図 6 に示す。

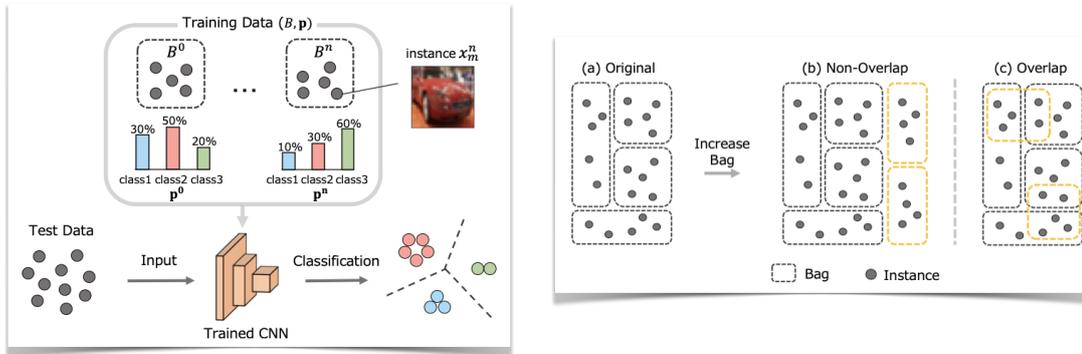


図 6: LLP の問題設定 (左) とバッグ拡張手法の概要

Learning from Majority Label (LML) という新しい学習問題を提案した。腫瘍画像など、医療画像データは画像の規模の大きさから画像をグリッドに区切り、MIL の問題設定として扱う (すなわち、一枚の医療画像がパッチ=インスタンスの集合) ことが慣習的である。また、医療データにおいては「多数派クラス」(癌の最終判定結果) のみが残されていることも多く、多数派クラスのみがラベルとして付与されるような設定は実用タスクでも十分に考えられる。最終目標は LLP 同様、インスタンスの分類 (医療画像であれば全てのパッチを分類することによるセグメンテーション) である。従来の MIL 手法とは一線を画した「クラスに属すると推定されるインスタンスをカウントする」というアプローチを提案した。概要を図 7 に示す。

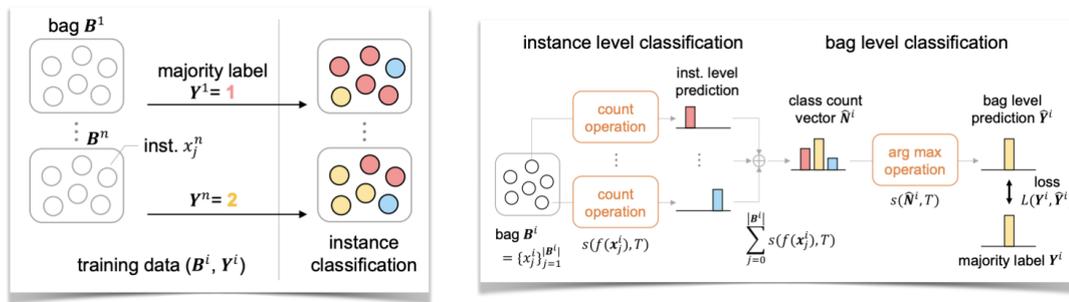


図 7: LML の問題設定 (左) とクラス所属インスタンスカウント手法

3. 今後の展開

学習問題の統合的帰着による**学習問題の体系化および実用性の立証**を行っていく。具体的には、①ERM-reduction scheme によって導かれる学習問題のクラスを明らかにすること、および、②ERM-reduction scheme に基づいた、理論性能保証を見据えた学習問題の創出である。①により、計算量理論分野のように、学習問題を「難しさ」によって整理することが可能となり、従来とは異なるタスク非依存の体系化が可能となる。また、②により、従来の学習問題創出プロセス「タスク→定式化→理論解析」ではなく、「タスク→理論解析付き定式化」と、定式化の新たな道筋を示すことで、統合的帰着スキームの実用性を示すことができる。

(加速フェーズ実施後追記)

これまでの研究を足がかりとして、より一般的な枠組みおよび統合化技術の汎用化を目指す。特に、MIL に関する研究成果を足がかりとして、様々な学習問題に対する統合化が可能な枠組みの開発を目指していく。

4. 自己評価

当初計画にあげていた目的は達成することができた。当初スケジュールで予定していた「MIL への帰着スキーム→一般化帰着スキーム」という流れにはならず、ほぼ同時に達成することとなった。しかし、これは当初考えていたとおり、各テーマを行き来しながら考えていくことで目的に到達できるであろうという目論見通りとなった。

また、ACT-X 関係者、共同研究者等、様々な研究者との交流を積極的に行い、様々な学習問題に関する知見を得ることで、研究を大きくすすめることができた。具体的には、医療情報学分野の研究者や、文字情報学研究者らと共同研究を行い、細胞検出問題や、署名照合問題における上位特化学習問題に関する定式化に着手し、新たなアルゴリズムを開発した。これらは本研究の直接的な成果ではないものの、上位特化学習問題に関する知見は本研究における MIL への帰着事例創出に大きく貢献した。

本研究は、あらゆる学習問題に跨っている研究であることから、領域会議や国内外の学会を通し、ACT-X 内外の研究者らと議論を交わすことができた。今後も、本研究を軸として様々な研究者との交流を積極的に行い、学習問題の定式化および理論構築の知見で異分野に貢献しながら、得られた知見を自身の研究に還元して新たな成果を求めていく。

理論研究に関しては解決の糸口は掴んでいるものの、目標に現状達成できていない。理論研究に関しては大きく進展させることはできていないが、実活用研究に関してはコンピュータビジョンのトップ会議にも採択されるなど、大きな成果を挙げることができた。また、理論解析がうまく進まないときもコラボ研究などを積極的に行うことで、実社会貢献を行いながら理論研究のヒントを得る、という好循環を今年度も実行できたと考えている。

ACT-X メンバーとともに「数理情報研究交流会」という異分野交流に特化した研究会を発足するなど、加速フェーズ中も異分野交流を積極的に行った。戦術した通り、医療画像認識で重要な問題である LLP や LML は本研究の今後の展開にも大きく活用できると考えている。千葉大の計良氏とも LLP に関する共同研究を進めている。

今後も理論研究にとどまらず、異分野研究者との共同研究等を通して、実社会における問題の



解決を行いながら多様な知識を吸収，発展させ，理論と実活用の好循環サイクルにより研究を進めていきたいと考えている。

5. 主な研究成果リスト

(1) 代表的な論文(原著論文)発表

研究期間累積件数: 5件

研究期間累積件数: 10件(加速フェーズ実施後更新)

1. Daiki Suehiro , Eiji Takimoto, "Simplified and Unified Analysis of Various Learning Problems by Reduction to Multiple-Instance Learning", Proceedings of the 38th Conference on Uncertainty in Artificial Intelligence (UAI 2022), 2022.8, PMLR 180:1896–1906.
経験誤差最小化問題に基づく学習問題の帰着スキームを提案した。帰着スキームを用いることで、汎化誤差の導出およびアルゴリズムの設計が容易となる。また、帰着スキームをマルチインスタンス学習問題に適用し、様々な学習問題がマルチインスタンス学習問題に帰着できることを示した。
2. Xiaotong Ji, Yan Zheng, Daiki Suehiro and Seiichi Uchida, "Revealing Reliable Signatures by Learning Top-Rank Pairs", Proceedings of the 15th IAPR International Workshop on Document Analysis Systems, pp.323–337, 2022.5.
署名照合問題に対し、上位特化学習を適用するための定式化を考案した。単純な精度だけでなく、従来本問題で軽視されていた予測の「信頼性」すなわち「本物の署名であることに対する信頼度」を大きくするための学習を可能とした。従来手法よりも高い性能で署名照合が行えることを示した。
3. Kazuma Fujii, Daiki Suehiro , Kazuya Nishimura, and Ryoma Bise, "Cell Detection from Imperfect Annotation by Pseudo Label Selection Using P-classification", Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI2021), pp. 425–434.
4. Takanori Asanomi, Shinnosuke Matsuo, Daiki Suehiro, Ryoma Bise, "MixBag: Bag-Level Data Augmentation for Learning from Label Proportions", Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV), 2023 16570–16579. (加速フェーズ実施の成果)
入力としてインスタンスの集合 (bag) が与えられ、bag のラベルとしてインスタンスのクラス割合が与えられるような問題 (Learning from label proportion (LLP)) という問題を考える。従来研究ではバッグ内のインスタンス数が問題の難しさを決定しているという議論が主流であったが、本研究ではバッグ数こそが汎化性能に大きく寄与していることを明らかにし、バッグを人工的に拡張 (augmentation) する手法を提案。拡張したバッグに対してラベルが摂動する問題に対処するため、統計理論に基づき信頼度付き損失関数を与えた。最先端の手法と比べ高い実験性能を得た。
5. Kaito Shiku, Shinnosuke Matsuo, Daiki Suehiro, and Ryoma Bise, "Counting Network for Learning from Majority Label", IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP), 2024. 採録決定済み。 (加速フェーズ実施の成果)
入力としてインスタンスの集合 (bag) が与えられ、bag のラベルとして最も多数派のクラスが与えられるような問題 (Learning from Majority Label (LML)) という問題を考える。まず、

類似した設定である従来の MIL 手法では多数派ラベルの推定とインスタンスのラベル推定に矛盾が起きることを示した。また、多数派ラベルの推定とインスタンスのラベル推定に一貫性のある Counting Network (バッグ内にある推定クラスインスタンス数をカウントして多数派ラベルを一致させる)を提案した。提案法は既存の MIL 手法に比べ、高い性能を達成した。

(2) 特許出願

研究期間全出願件数: 0 件 (特許公開前のものも含む)

(3) その他の成果 (主要な学会発表、受賞、著作物、プレスリリース等)

1. DAS2022 Best Student Paper Awards
2. 第 46 回情報論的学習理論と機械学習研究会 (IBISML) 口頭発表 (査読なし)
3. 松尾 信之介, **末廣大貴**, 内田誠一, 伊藤寛朗, 寺田和弘, 吉澤明彦, 備瀬竜馬, WSI に対する部分的なラベル比率からの学習, MIRU 学生奨励賞, MIRU2023 (画像の認識・理解シンポジウム).