

# ROS モジュールにおけるメタ学習による 機械学習アルゴリズム選定の実現と評価

阿部秀尚<sup>†1</sup> 森田武史<sup>†2</sup> 山口高平<sup>†2</sup>

**概要:** ロボットの動作をより専門家の持つ専門知識に沿って作成するためには、人間同士の教示とは異なる定数による制御値の決定などを行っていく必要がある。一方、ロボットを動作させる環境においては、動作の各種ログを収集する機能が用意されているが、これらが制御値の決定や動作の教示のための利用は限られた動作環境に依存するなど、一般的に利用されるには至っていない。そこで、本研究では、ロボット・アプリケーションの作成支援を行うミドルウェアとして広く普及している ROS 環境において、入力となるデータセットと要求されたタスクに応じて、より適切な機械学習アルゴリズムを選定するメタ学習機構を ROS モジュールとして適するよう実現する。本稿では、分類学習タスクを実行するアルゴリズムの選定を行うメタ学習タスクを設計、実装する。評価実験では、画像分類問題を用いて、選定される機械学習アルゴリズムの評価、および従来型の機械学習アルゴリズムとの比較を示す。

**キーワード:** 機械学習, メタ学習, ROS, 分類学習

## Evaluating Meta-Learning Method for Selecting Machine Learning Algorithm on ROS Environment

HIDENAO ABE<sup>†1</sup> TAKESHI MORITA<sup>†2</sup>  
TAKAHIRA YAMAGUCHI<sup>†2</sup>

**Abstract:** In the robot application environment, developers often face on try-and-error to adjust the robot operation as static values or/and decisions in their computer programming codes. This adjustment process is not so important for human expert of the target task, and it is not affected to their expertise. In order to reduce the cost of the adjustment, people want to utilize machine learning algorithms for automating the adjustment of the values and the decisions. However, it is not so easy to introduce the machine learning applications to the process, because the developers have to know the characteristics of the algorithm and their input dataset. On the other hand, to solve the machine learning algorithm selection problem, some meta-learning frameworks have been developed. Thus, in this study, we developed a framework for performing more adequate machine learning algorithms to each given dataset, focusing on classification learning applications. We propose a combination of the tasks consists of meta-learning framework for determining classification learning applications, classification learning model generation task with the determined feature selection and machine learning algorithms, and classification label prediction task with the generated classification learning models. After implementing the tasks as ROS (Robot Operating System) modules, we perform an experimentation to compare their accuracies, execution times to the conventional machine learning algorithms on a small benchmark datasets.

**Keywords:** Machine Learning, Meta-Learning, ROS, Classification Learning

### 1. はじめに

ロボットを動作させて業務を遂行するロボット・アプリケーションの作成では、作成支援環境を用いてプログラミングにより動作を作成する。その際、動作をより専門家の持つ専門知識に沿って作成するためには、人間同士の教示とは異なる定数による制御値の決定などを行っていく必要がある。

一方、ロボット・アプリケーションを動作させる環境においては、動作の各種ログを収集する機能が用意されている。しかしながら、制御値の決定や動作の教示のための利

用は限られた動作環境に依存するなど、一般的に利用されるには至っていない。

以上のような現状に対し、本研究では、ロボット・アプリケーションの作成支援を行うミドルウェアとして広く普及している ROS 環境[1]において、入力となるデータセットと要求されたタスクに応じて、より適切な機械学習アルゴリズムを選定するメタ学習機構を ROS モジュールとして適する実現する。

本稿では、まず、分類学習タスクを実行するアルゴリズムの選定を行うメタ学習タスクを設計し、メタ学習機構である AutoWeka[2]と基盤となる Weka[3]を用い、選定された機械学習アルゴリズムの実行モジュールを実装する。評価実験においては、画像分類問題を用いて、データセットごとに AutoWeka により選定された属性選択手法を含む機械学習アルゴリズムを評価し、予め機械学習アルゴリズムと

<sup>†1</sup> 文教大学情報学部情報システム学科  
Department of Information Systems, Faculty of Information and Communications, Bunkyo University  
<sup>†2</sup> 慶應義塾大学理工学部管理工学科  
Department of Administration Engineering, School of Science and Engineering, Keio University

の比較を示す。本結果に基づいて、選定された機械学習アルゴリズムの特徴と正解率の差異について考察する。

## 2. メタ学習機構に対応した ROS モジュールの設計と実装

我々は、先行研究[4]において、決定木や分類ルール学習といった従来からよく知られている機械学習アルゴリズムについて、「分類学習モデル生成タスク」と「分類予測ラベル付与タスク」の2タスクに分割を提唱し、実装を示した。

従来型の機械学習アルゴリズムについては、適用するデータ集合とユーザからの要求に応じて、適切な機械学習アルゴリズムを選定することを課題としたメタ学習機構[5]の研究がおこなわれてきた。本章では、メタ学習機構による機械学習アルゴリズム、機械学習アルゴリズムに入力する直前の訓練データ集合の属性（特徴）を選択する属性選択アルゴリズム、およびそれらの各アルゴリズムのパラメータ類を選定することを想定し、図 1 に示すタスク構成を提案する。さらに、各タスクを ROS モジュールにする際にインタフェース定義となる .srv ファイル内の構成、およびモジュール間の通信に用いられる .msg ファイルの構成について述べる。

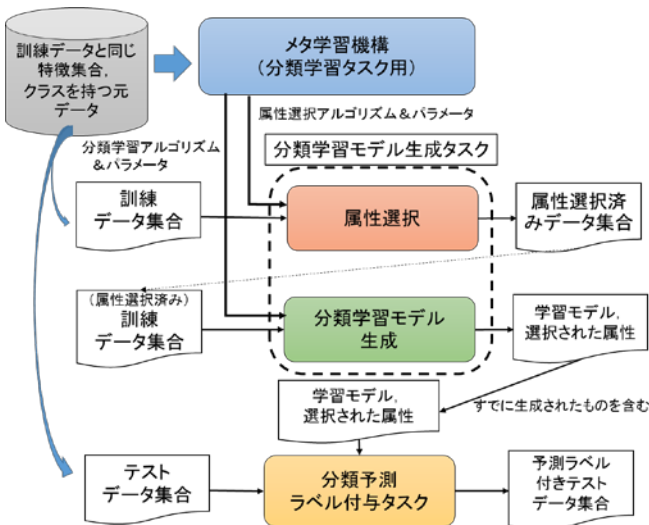


図 1 メタ学習機構を含む分類学習タスク実行の概観  
 Figure 1 Task Flow Overview of Classification Learning Tasks including Meta-Learning Framework.

### 2.1 分類学習を行う機械学習アルゴリズムのためのメタ学習機構

分類学習を行う機械学習アルゴリズムは、従来、決定木学習、分類ルール学習、ベイズ型分類器学習、SVM、誤差逆伝播を利用したニューラルネットワークの学習など、数多くのアルゴリズム（以降、従来型機械学習アルゴリズム、と呼ぶ）が開発されてきた。メタ学習機構は、これらの機械学習アルゴリズムの中から、入力されるデータ集合とユ

ーザからの要求に最も適した学習アルゴリズムを選択、あるいは再構成して提示する機構である。ユーザからの要求は、分類予測ラベルの付与の精度である正解率がよく用いられるが、ユーザの要求が異なる場合は、他の評価基準を用いる必要がある。

従来型機械学習アルゴリズムの選定は、入力されたデータ集合の分類対象や属性集合の数などによる定性的な性質を用いたアルゴリズム単位の選択する方法[6]をはじめ、複数のアルゴリズムの構成を分析し、メソッドと呼ばれる部品単位に分割して再構成する方法などが開発されてきた。後者は、機械学習アルゴリズムの各機能部品を組み合わせることができる“仕様空間”を探索する必要があり、遺伝的プログラミングによる探索[7]や SMAC (Sequential Model-Based optimization for general Algorithm Configuration) による探索[2]を用いたメタ学習機構が開発・実装されてきた。

さらに、従来型機械学習アルゴリズムによる分類予測ラベル付与タスクの精度である正解率を向上させるため、属性選択アルゴリズムが開発され、より適切な属性（特徴）部分集合を得ることが求められる。この属性選択アルゴリズムの選定についても、入力されるデータに応じて、より適切な属性選択アルゴリズムを選定する手法がメタ学習機構として開発されてきている。属性選択アルゴリズムの選定については、Weka による属性選択アルゴリズムの設定に従って、その仕様探索空間を「属性部分集合評価」と「属性部分集合探索」から構成することが多い。

以上より、分類学習を行う機械学習アルゴリズムの選定の結果については、機械学習アルゴリズム（の仕様）とパラメータ、属性選択アルゴリズムの属性部分集合評価手法、属性部分集合探索手法、とそれらの各パラメータ群が分類学習モデル生成タスクへの入力として必要となる。

### 2.2 メタ学習機構からの出力を利用した分類学習モデル生成タスクの設計と実装

2.1 で述べたメタ学習機構の出力を利用して、入力される訓練データ集合により適切な機械学習アルゴリズムを実行する ROS モジュールとしての分類学習モデル生成タスクを設計する。

本提案手法では、分類学習モデル生成アルゴリズムの入力として、訓練データ集合に加え、メタ学習機構により選定された分類モデルの学習を行う機械学習アルゴリズムおよび属性選択アルゴリズムの仕様を入力する。このため、図 2 に示すように、メタ学習機構から選定される分類学習を行う機械学習アルゴリズムの仕様、およびそのパラメータ、属性選択アルゴリズムの各手法とそれらのパラメータを格納するメッセージを .msg ファイルとして作成する。機械学習アルゴリズムと属性選択アルゴリズムをデータに応じて組み合わせた仕様のため、これを“分類学習アプリケーションの仕様”とする。

データ型	変数名
string	classifier
string	classifier_param
string	attsel_eval
string	attsel_eval_param
string	attsel_search
string	attsel_search_param

図 2 メタ学習機構により選定された従来型機械学習アルゴリズムと属性選択アルゴリズムの仕様（分類学習アプリケーションの仕様）を格納する ROS のメッセージ

Figure 2 ROS Message for Describing Classification Learning Algorithms and Attribute(Feature) Selection Algorithms Chosen by Meta-Learning Framework.

本 ROS メッセージ (.msg) を利用して、メタ学習機構により選定された各アルゴリズムとパラメータ群により、分類モデル生成タスクを ROS サービスとして設計し、実装する。メタ学習機構によるアルゴリズムの仕様選定では、属性選択アルゴリズムの適用の有無を含めて選定するため、属性選択アルゴリズムの仕様の指定が無い場合は、先行研究[4]に示した従来の分類学習モデル生成タスク実行モジュールと同様になる。図 3 にメタ学習機構による機械学習アルゴリズムの仕様選定に対応したサービスの仕様 (.srv の定義) を示す。

入力	出力
訓練データ集合	各学習アルゴリズムの出力モデル
パラメータ(String型)	実行出力(String型)
分類学習アプリケーションの仕様	選択された属性(String型)

図 3 メタ学習機構による従来型機械学習アルゴリズムの仕様選定に対応したサービスの仕様

Figure 3 Interface Specification of ROS Service for Classification Model Generation Task Applied to Meta-Learning Framework.

分類学習モデル生成タスクにより出力される分類学習モデルは、その種類が事前に指定できなくなる。このため、分類学習モデルのファイルなどと同時に適用するための分類学習アルゴリズムを指定するため、分類学習モデルを表す ROS メッセージ (.msg ファイル) を図 4 のように作成する。また、属性選択アルゴリズムが選定（入力）され、実行の結果、選択された属性は分類予測の際に事前に選択

しておく必要がある。このため、タスク実行モジュールの出力として定義する。

データ型	変数名
string	type
string	file_name
string	url
string	str
string	classifier_className

図 4 メタ学習機構によるアルゴリズム選定に対応した分類学習モデル

Figure 4 ROS Message for Classification Learning Model with Chosen Classification Learning Algorithm

### 2.3 メタ学習機構を利用したアルゴリズム選定に対応した分類予測ラベル付与タスクの設計と実装

2.2 において図 4 に示す分類学習モデルを参照し、入力されたテストデータ集合の各データに分類予測ラベルを付与するタスクを実行する ROS サービスを、図 5 に示すように .srv ファイルに定義し、実装した。

入力	出力
テストデータ集合	ラベル付きデータ集合
各学習アルゴリズムの出力モデル	実行出力(String型)
選択すべき属性(String型)	

図 5 メタ学習機構による従来型機械学習アルゴリズムの選定に対応した分類予測ラベル付与タスクを実行する ROS サービスの定義

Figure 5 Interface Specification of ROS Service for Predicting Classification Labels of Test Dataset Task Applied to Meta-Learning Framework.

## 3. 一般物体識別タスクにおけるメタ学習機構により選定された分類学習の評価

本節では、2 章に述べたメタ学習機構に対応した分類学習モデル生成タスクと分類予測ラベル付与タスクの ROS モジュールをサービスとして実装し、小規模な画像のカテゴリ分類問題を対象に評価実験を行う。

### 3.1 メタ学習機構 : AutoWeka

Weka を基盤としたメタ学習機構である AutoWeka (バージョン 2.6) では、30 種類の分類学習を行う機械学習アルゴリズムとそれらのパラメータ、1 種類による属性部分集

合評価法, 2 種類の属性部分集合探索法による仕様空間を SMAC と呼ばれるアルゴリズムを用いて探索する a. AutoWeka 2.6 において探索対象となっている機械学習アルゴリズムは, ベース学習器としてさらに分類学習アルゴリズムを指定できる Bagging や Boosting といったメタ学習スキームを 3 種類, 分類学習モデル生成時に適宜属性選択を学習毎に行うアルゴリズムを 1 種類がある.

各機械学習アルゴリズムとそのパラメータの組み合わせは, 約 150 程度あるが, メタ学習スキームや属性選択を含む学習スキームを含めると, 学習アルゴリズムとパラメータの組み合わせの段階で 1000 を超える組み合わせが可能となる. さらに, 各パラメータの設定可能値や地域があり, パラメータまでの探索空間を含めると, 再構成可能な機械学習アルゴリズムは膨大な数となる.

### 3.2 カテゴリ分類タスクの評価

本実験では, 画像認識・識別ベンチマークである Caltech101[8]より, 各カテゴリに属する画像数が 30 枚から 40 枚を対象に, カテゴリ間において, カテゴリ判別を行う分類問題を用いて評価を行う. 対象となるカテゴリ数は 17 であり, 各カテゴリ間の組み合わせのため, 136 ペアを分類する. 画像からの特徴量抽出は, [4]で述べたように, OpenCV3.1 に実装された ORB による特徴点抽出を行い, クラスタリングアルゴリズムとして scikit-learn に実装された k-means(k=256)を用いて, 256 次元の BoVW (Bag-of-VisualWords) を特徴集合とした.

#### 3.2.1 AutoWeka による機械学習アルゴリズムと属性選択アルゴリズムの選定結果

本実験では, AutoWeka (バージョン 2.6 および, 同梱の Weka は weka-3-8-2) を利用し, 選定のための制限時間の上限を 15 分として設定して, 136 データ集合全体に対してより適切な属性選択アルゴリズムおよび機械学習アルゴリズムの選定を行った. 各アルゴリズムの評価基準は, 訓練データ集合として用いたデータ集合全体に対する正解率を用いる.

以上の設定による, 画像カテゴリ分類問題 136 データ集合に対する各アルゴリズムの選定結果を表 1 に示す. なお, パラメータの探索も行われているため, 同一の機械学習アルゴリズム, および属性選択アルゴリズムに与えられるパラメータは異なっており, 各データ集合に対してより適した分類学習アプリケーションがそれぞれ選定された.

表 1 画像カテゴリ分類問題における分類学習アプリケーションとして AutoWeka により選定された機械学習アルゴリズムと属性選択アルゴリズム

Table 1 Statistics of Machine Learning Algorithms and Attribute Selection Algorithms as Classification Learning Applications Chosen by AutoWeka

機械学習アルゴリズム <sup>a</sup>	選定された回数
trees.RandomForest	27
lazy.IBk	17
meta.AdaBoostM1	12
meta.Vote	10
meta.Bagging	10
trees.RandomTree	9
functions.MultilayerPerceptron	5
meta.RandomSubSpace	5
rules.OneR	5
trees.LMT	5
lazy.LWL	5
lazy.KStar	4
functions.SMO	3
bayes.NaiveBayes	3
trees.REPTree	3
rules.JRip	3
meta.AttributeSelectedClassifier	2
bayes.BayesNet	2
trees.DecisionStump	1
trees.J48	1
functions.SGD	1
functions.Logistic	1
rules.DecisionTable	1
functions.VotedPerceptron	1

属性部分集合評価法	選定された回数
なし	78
.CfsSubsetEval	58

属性部分集合探索法	選定された回数
なし	78
GreedyStepwise	41
BestFirst	17

表 1 の結果から, 24 種類の機械学習アルゴリズムが選定

a AutoWeka 2.6 Manual:  
<https://www.cs.ubc.ca/labs/beta/Projects/autoweka/manual.pdf>

b trees. や lazy. などは Weka の分類器パッケージ(weka.classifiers パッケージ)における分類を表す.

される結果となった。なかでも、Random Forest が最も多く選定され、AdaBoostM1, Vote (複数分類器による投票)、Bagging といったメタ学習スキームやアンサンブル学習と呼ばれる複数の分類器による分類予測ラベルの付与を行う機械学習アルゴリズムが分類学習アプリケーションとして選定された。また、属性選択アルゴリズムを含む分類学習アプリケーションは 58 であり、約 3 分の 2 は属性選択を伴わなくとも分類精度は低下しないことが示唆された。

### 3.2.2 AutoWeka により選定された分類学習アプリケーションと従来型機械学習アルゴリズムの比較

本実験では、136 のカテゴリのペアの各カテゴリ間での分類予測の精度である正解率を用いて評価する。各カテゴリ間の分類を行うデータ集合を訓練データ集合とテストデータ集合にランダムに 10 等分し、9:1 の割合で訓練データ集合とテストデータ集合に割り当てる 10 回交差検証により、17 カテゴリ間の 136 ペアをクラスとした各データ集合についての正解率を算出する。

評価実験においては、下記の代表的な 6 種類の機械学習アルゴリズムを ROS モジュール (サービスノード) として実行した。各モジュールは Python による実装され、Weka に Java により実装された各アルゴリズムは Python からのコマンド呼び出しを用いて実行される。

- 事例ベース学習 : k-NN ( $k=3$ )
- 決定木 : J4.8
- ベイズモデル学習 : Naïve Bayes
- サポートベクターマシン : SMO
- 従来型 (3 層) ニューラルネットワーク : MLP(epoch=100)
- アンサンブル学習 : Random Forest (n=100)
- AutoWeka により選択された分類学習アプリケーション (属性選択アルゴリズム+機械学習アルゴリズム) : AutoWekaSpec

表 2 に各アルゴリズムを実行する ROS モジュールによるカテゴリ間認識精度の全平均正解率、各タスクの ROS サービスノードの平均実行時間、分類モデル生成時間を示す。ROS モジュールの実行環境は、Xeon Gold 5122 を搭載したサーバ(Ubuntu 16.04 LTS)上に Docker (docker-ce) を用いて構築した ROS 環境(Ubuntu を基盤とした nvidia/cuda-8.0 + ROS Kinetic)である。なお、ROS のマスターノードおよび各サービスノードは同一の Docker コンテナ上で動作させた。

表 2 の結果から、平均正解率においては、Random Forest が 88.98% と最も高い値を示している。AutoWeka により選定された機械学習アルゴリズムを用いた結果は、

RandomForest や MLP を含む分類学習アプリケーションもあったが、それ以外のアルゴリズムを選定したにもかかわらず、MLP による平均正解率と統計的に差があるとは言えない ( $p=0.57$ ) 平均正解率が得られた。

さらに、AutoWeka により選定された分類学習アプリケーションは、機械学習アルゴリズムに加え、属性選択アルゴリズムを選定し、実行している。このため、平均分類学習モデル構築時間だけを見ると、ほぼ k-NN と同等の 0.57sec. であり、より少ない計算時間でより精度の高い機械学習アルゴリズム (分類予測ラベル付与タスクでの正解率が高くなる) が得られたといえる。

しかしながら、Random Forest では、より短い学習モデル生成タスクの実行時間で、高い平均正解率が得られる結果となった。このため、総合的な観点からは、正解率だけではなく、実行時間を含めた、より長い時間をかけた分類学習アプリケーションの選定が必要であることが示唆された。

表 2 各機械学習アルゴリズムによる平均正解率, ROS サービスにおける平均分類モデル生成時間, 平均分類予測ラベル付与時間の結果

Figure 2 Results of Averaged Accuracies, Averaged Classification Learning Model Build Time, and Averaged Classification Prediction Time of The Machine Learning Algorithms

Algorithms			
アルゴリズム名	平均正解率(%) ±標準偏差	平均 分類学習 モデル生成 時間(sec)	平均 分類予測 ラベル付与 時間(sec)
k-NN	76.52±10.51	0.52	0.33
J4.8	75.26±12.24	0.88	0.56
Naïve Bayes	71.25±12.01	0.90	0.62
SMO	71.69±12.00	0.65	0.54
MLP	82.59±9.45	11.89	0.45
RandomForest	88.98±7.05	0.91	0.34
AutoWekaSpec	82.33±11.65	5.70	0.67

## 4. 関連研究

2 章および 3 章では、より正解率の高い (エラー率の低い) 従来型機械学習アルゴリズムと属性選択アルゴリズム、その有無を含めた分類学習アプリケーションの選定を行うメタ学習機構を導入した。しかし、より高い正解率を求め、入力されるデータ集合に適応的に分類学習を行うアルゴリズムを選定するとなると深層学習と呼ばれる種々の入力データ集合への分類・識別に対して、複雑な構造をもつ深層ニューラルネットワークの選定についても、メタ学習としての機構が必要と考えられる。本節では、その方向性について、従来型機械学習アルゴリズムに対するメタ学習機構の発展を基に、考察する。

#### 4.1 従来型機械学習アルゴリズムに対するメタ学習機構

従来型機械学習アルゴリズムの選定は、主に分類学習における分類予測の精度（正解率，エラー率など）を向上させるため、経験的に用いられていたデータの大きな特徴と与えられた分類タスクによる機械学習アルゴリズムの選択表を拡張する形で開発が行われてきた。これらは、基盤となる学習アルゴリズムに対して、選択を行う動作を行うため、メタ学習と呼ばれる。Brazdilらは、DCT (Dataset Characterizing Technique)と呼ばれるデータ集合の特徴量を各種の指標として表して分類学習における機械学習アルゴリズムの選定を行う手法[6]を開発した。また、選択ではなく、基盤となる学習モデル（ベース学習器）による分類予測結果を統合することで正解率を高めるメタ学習スキームとして、Bagging や Boosting (AdaBoost) , Voting, Stacking[9]といったアンサンブル学習アルゴリズムも開発された。

一方、機械学習アルゴリズムは複雑な制御構造を持つプログラムとして記述されるため、それぞれの機能単位に着目し、それらを部品化して整理することで、より適切な機械学習アルゴリズムを開発することを目指す研究もおこなわれてきた。阿部らは、このようなアプローチを構成的メタ学習と呼び、機能単位であるメソッドを体系化したメソッドリポジトリから入力されたデータ集合に適した属性選択アルゴリズムと分類学習についての機械学習アルゴリズムを特定のライブラリに依存せず再構築するメタ学習機構[7][10]として開発した。

Weka を基盤とする AutoWeka[2]は、Weka での分類学習モデル生成に関わる属性選択と機械学習の各アルゴリズム群の実装（部品化）を基に、機能仕様空間の探索を SMAC と呼ばれる手法で効率的に行う手法である。各アルゴリズムのパラメータの設定値についても、ある程度の範囲で探索可能なため、より多くの入力データ集合に適した分類学習アプリケーションの仕様を探索可能であると考えられる。

#### 4.2 深層学習におけるメタ学習機構

分類学習を行う機械学習としては、従来、入力層・隠れ層・出力層の3層からなる逆伝播におけるネットワークの重み学習を行うニューラルネットワーク (BPNN または MLP: Multi-Layer Perceptron) が利用されてきた。ニューラルネットワークの学習の基本は、ネットワークのノードとノード間の重みや結合を構築し、ノードの活性化関数を決定する「構造学習」とノード間の重みを誤差が小さくなるように修正する「重み学習」から成る。

近年、深層学習と呼ばれ、広く注目を集める深層ニューラルネットワークを使った分類・識別タスクの実行においても、ニューラルネットワークの学習の基本である「構造学習」と「重み学習」の課題は残されている。なかでも、「構造学習」は自動化が難しく、ハイパーパラメータの決

定問題、あるいは個々の研究対象への適用事例とともに新たなネットワーク構造の提案が行われている。

しかしながら、「構造学習」を人間の試行錯誤によって行うことは、コストが高く、従来の機械学習アルゴリズムの選定のように、メタ学習による自動化が求められる。この要求についても、従来型機械学習アルゴリズムに対するメタ学習と同様に、複数の分類器<sup>c</sup>を統合するようなアプローチと構成的に深層ニューラルネットワークを所与のデータ集合に合わせて再構成するアプローチがある。

前者のアプローチとしては、アンサンブル学習スキームのように、より複雑で基盤となるニューラルネットワークの結果をさらに統合するような大規模なニューラルネットワークを構築し、重みを再調整する方法で複数の入力データ集合に適応する手法[11]が画像分類・領域検出問題で実用化されようとしている[12]。しかし、深層ニューラルネットワークの統合によるネットワークの学習には、より多くの計算資源の投入が必要と考えられる。

後者の構成的アプローチとしては、ニューラルネットワークを構成するノードやネットワークの接続法、活性化関数を部品として、構造を遺伝的プログラミングにより最適化することで、入力データ集合と与えられた分類や識別などの問題により適したネットワーク構造を学習する手法[13]が開発されている。構成的アプローチは、大規模な深層ニューラルネットワークの学習に比べ、比較的少ない計算資源で、よりユーザからの分類問題への要求に柔軟に対応した深層ニューラルネットワーク構造の選定が実現可能なメタ学習手法と考えられる。

以上から、ROS における機械学習モジュールを拡充していくにあたって、構造学習を構成的に行うメタ学習機構の導入がより少ない計算資源で、より多様なユーザの要求に応えられる手法として、開発を進めていく必要があると考えられる。

### 5. おわりに

本稿では、従来型機械学習アルゴリズムを分類学習問題において、所与のデータ集合により適した分類学習アプリケーションとして選定するメタ学習機構の ROS モジュールとしての設計と実装について述べた。また、メタ学習機構に対応した ROS モジュールを分類学習モデル生成タスクおよび分類予測ラベル付与タスクについて実装し、小規模な画像カテゴリ分類問題に適用した。

この結果、分類予測ラベル付与タスクでの正解率は、単純に従来型3層型ニューラルネットワーク (MLP) を指定するのと同等の分類学習アプリケーションが得られることが示された。また、AutoWeka により選定された分類学習アプ

<sup>c</sup> 深層学習では深層ニューラルネットワークの一部のニューラルネットワークを指す。

リケーションは、より少ない計算時間で分類モデルを生成し、分類ラベル付与を行うことができることが示唆された。しかしながら、最も平均正解率の優れた Random Forest を上回することはできず、最適な分類学習アプリケーションを選定するためには、より多くの時間を必要とすることが示唆された。

今後は、クラスルーム AI[14]等対人サービスを行うロボット・アプリケーションにおける自律的な機械学習アルゴリズムの選定と適用を行う ROS モジュールを PRINTEPS 上に実装する。これにより、例えば、児童の顔の向きを画像から識別し、集中度に応じてロボットによる異なる教示を行う PRINTEPS 上で作成したロボットサービスにおいて、顔の向きを識別するための分類学習アプリケーションをより適切に選定することが可能になるものと考えられる。

さらに、メタ学習機構による選定をアルゴリズムレベルとパラメータレベルの間である機能単位（メソッド）を考慮した手法の適用が必要となると考える。また、近年、精度の高い画像認識などで注目される深層ニューラルネットワークの構造決定やパラメータ選定を行うメタ学習機構との比較を行っていく。

**謝辞** 本研究の一部は、JSPS 科研費 JP 26240036、および JST/CREST 「実践知能アプリケーション構築フレームワーク PRINTEPS の開発と社会実践」の補助によるものである。

## 参考文献

- [1] ROS: <http://www.ros.org/>, (参照 2018-02-08)
- [2] Kotthoff, L., Thornton, C., Hoos, H. H., Hutter, F., & Leyton-Brown, K., Auto-WEKA 2.0: Automatic model selection and hyperparameter optimization in WEKA. *Journal of Machine Learning Research*, 2016, vol. 17, pp.1-5.
- [3] E. Frank, M. A. Hall, and I. H. Witten, *The WEKA Workbench. Online Appendix for "Data Mining: Practical Machine Learning Tools and Techniques"*, Morgan Kaufmann, Fourth Edition, (2016)
- [4] 阿部秀尚, 森田武史, 山口高平. ROS 環境上における機械学習タスク実行モジュールの実装と評価, 人工知能学会 第110回知識ベースシステム研究会予稿集, 2017, pp.18-23.
- [5] Grąbczewski, K.. Meta-Learning. In *Meta-Learning in Decision Tree Induction*, 2014, Springer Cham, pp. 233-317.
- [6] Brazdil, P., Gama, J., & Henery, B. Characterizing the applicability of classification algorithms using meta-level learning. In *European conference on machine learning*. 1994, pp. 83-102.
- [7] Abe H, Yamaguchi T. Constructive meta-learning with machine learning method repositories. In *Proc. of International Conference on Industrial, Engineering and Other Applications of Applied Intelligent Systems*, 2004, pp. 502-511.
- [8] Caltech101: [http://www.vision.caltech.edu/Image\\_Datasets/Caltech101/](http://www.vision.caltech.edu/Image_Datasets/Caltech101/), (参照 2018-02-08)
- [9] Wolpert, D. H.. Stacked generalization. *Neural networks*, Vol. 5, No. 2, 1992, pp.241-259.
- [10] Abe H., Yamaguchi, T. A Constructive Meta-Level Feature Selection Method based on Method Repositories, *Journal of Computers* vol. 1, no.3, 2006, pp. 20-26.
- [11] Szegedy, C., Ioffe, S., Vincent, V., and Alemi, A..Inception-v4,

- Inception-ResNet and the Impact of Residual Connections on Learning, *AAAI*, 2017.
- [12] Google Cloud AutoML, <https://cloud.google.com/automl/>, (参照 2018-02-08)
- [13] 平野廣美. 深層学習における遺伝的プログラミングによるモデル構成法の一手法, 第 79 回全国大会講演論文集, Vol. 1, 2017, pp. 53-54.
- [14] 菅陽哉, 西本智活, 赤柴駿介, 柗原礼士, 桑山美冴, 山口高平. PRINTEPS におけるクラスルーム AI の実現と評価, 2016 年度人工知能学会全国大会 (第 30 回), 2016, 4H1-1.