

エッジセンサのための能動学習を用いた 車両状態識別モデル更新手法

安齋 凌介^{1,a)} 水谷 伸² 白井 良成² 大塚 琢馬² 岩井 将行¹ 岸野 泰恵^{2,b)}

概要：機械学習によって状況を識別してその結果を送信するエッジセンサでは、環境の変化に応じて識別モデルを逐次的に更新する必要がある。しかし、ネットワーク帯域の制約や、ラベリングにかかるコストを考慮すると、すべてのデータをサーバに送信することは現実的ではない。また、すべてのデータを識別器の逐次的な更新に利用することも現実的ではない。そこで我々は、能動学習を利用し識別器の精度を向上させる可能性の高いデータのみを送信する手法を提案する。ここで精度向上の可能性が高いデータというのは、既存のモデルによる識別境界付近のデータのことである。さらに本研究では、ごみ収集車に搭載したエッジセンサのデータを用いた車両の状態推定の課題に対して検証を行い、提案手法とランダムにデータを選択する場合とを比較して、提案手法が効率よく識別器の精度を向上させられることを確認した。

1. はじめに

IoT (Internet of Things) の普及に伴い、さまざまな場所でのセンシングやデータ収集が可能になってきた。また一方で、近年の計算機の小型化に伴い、IoT の末端の端末でも様々な計算が可能になり、機械学習の識別器を搭載させる、といった高度な処理も可能になってきた。これにより、単に IoT 端末を用いてデータをサーバに収集してまとめて分析するだけでなく、端末上でその場で状況推定を行うなど設計の自由度が高まり、IoT 技術活躍の場が広がるのが期待されている。

これに対して、筆者らは神奈川県藤沢市のゴミ収集車にセンサノードを設置し、センサデータからゴミ収集車の状態識別を行う研究を行なっている [1]。これまでに、ゴミ収集業務の効率化を図るため、ゴミ収集車にセンサノードを搭載し、センサノード上で車の状況を識別してサーバへ送信し、集約したデータを用いた地区別のゴミ量推定を行い、地区別のゴミ排出の特性の分析を行えることを示した。

このような状況識別を行う際には、一般的に教師あり学習が用いられることが多い。教師あり学習を行うためには、大量の学習データが必要とされている。学習データの準備には、データを入手し、それに対するアノテーション

(データに対応した状況ラベルを付与すること) の両方が必要となるが、それぞれには時間と労力 (コスト) を要する。データ入手のコストとは、大量のデータを得るために要するコストであり、アノテーションのコストとは、データに対してラベルを付与するために要するコストである。機械学習分野では学習データ量の Log スケールと教師あり学習の学習器の認識精度は比例することが知られている [2]。したがって、教師あり学習を行う際には膨大なデータがあれば、より高い精度で認識できる可能性が高く、それにはデータ入手にも、アノテーションにも大きなコストを要する。逆に、少量の学習データのみで学習した場合、それよりも多くの学習データで学習した場合に比べて、認識精度が低下することが予測される。

しかし、実際のフィールドでセンシングを行う際に十分な量の学習データをあらかじめ用意することは難しい。例えば筆者らのゴミ収集車における実験では、数十台のゴミ収集車の加速度とジャイロのセンサデータを用いて車の状態識別を行ったが、すべての車から十分な量のデータを収集し、それに対してアノテーションを行って状況認識を行うおうとすると、センシングを開始する前に膨大なコストが必要となる。さらに、車 1 台 1 台の挙動の変化や、各センサの特性のばらつき、センサの劣化などの特徴は各車両によって異なり、データの分布が異なる場合もある。このため、データ量に関わらず汎化が困難であり、数台の車のデータのみを学習データとして共通の識別モデルを生成することも難しい。また、ゴミ収集車に搭載されたセンサノードとサーバの通信に制限があるため、送信可能なセンサデー

¹ 東京電機大学
Tokyo Denki University

² NTT コミュニケーション科学基礎研究所
NTT Communication Science Laboratories

a) anzy@cps.im.dendai.ac.jp

b) yasue.kishino.eu@hco.ntt.co.jp




図 1 能動学習のイメージ図




図 3 能動学習を用いた識別器の更新

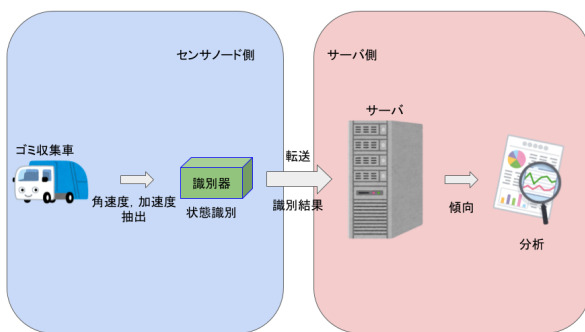


図 2 想定環境

タの量に限りがあるため、多くのデータを入手すること自体も難しい。

これらの問題は、能動学習 [3] を用いることで解決することが期待できる。機械学習の分野において、アノテーションコストを下げることに着目して能動学習を用いた研究は盛んに行われている。これに対して、この枠組みをセンサノードとサーバの間の通信に取り入れ、アノテーションを行うデータのみをサーバへ送信し、他は識別結果のみをサーバへ送信することとすれば、通信量も大幅に削減することができる。

そこで、本研究では既存の識別器に対してただデータを追加するのではなく、能動学習を用いてモデルの学習に最も有用であるデータを抽出し、抽出したデータのみをサーバに送信してアノテーションすることでより効率的にデータ収集と学習が行える手法を提案する。提案モデルの概要は図 3 に示す。

さらに、本研究では神奈川県藤沢市のゴミ収集車 4 台分のデータを 4 日分用いて学習を行い、提案モデルを評価した。検証の結果、

- 状況識別に対して、提案モデルが無作為にデータを選んで学習したモデルよりも高い精度で状況識別ができること
- 状況識別に対して、提案モデルが単純に全てのデータを追加したモデルよりも少ないデータ量で同等の精

度で状況識別が可能であり、効率的に学習できていること

を示した。

本稿では、2 章でアノテーションコストを下げる関連研究を俯瞰し本研究の学術的見地を明確にする。3 章で提案モデルについて説明し、4 章で提案モデルの検証実験について説明し、結果を述べる。5 章では、検証結果に基づいて提案モデルの有用性や今後の展望について考察する。最後に 6 章でまとめを述べる。

2. 関連研究

アノテーションコストの軽減に関する先行研究は大きく 2 つに分類できる。(i) アノテーションを行う際にユーザを支援して労力を軽減する研究 [4], [5] と (ii) アノテーションを行うべきデータ数を少なくする研究 [6], [7] である。本研究で扱う能動学習は (ii) に分類される。能動学習とは、少量のラベル付きデータを学習データとして識別器を作成し、その識別器を元に、大量のラベル無しデータから、識別確信度が低いものを選択して、人が分類ラベルを付けて学習データに用いる方法である。能動学習を用いることで、選択されたデータのみアノテーションすることでコストを下げ、更にセンサノードからサーバに送るデータ量を抑えられる。また、増加する学習データで、逐次的に学習を行うことで、識別器の性能を向上させることができる。

アノテーションコストを軽減するためにラベル無しデータを学習データにする方法として、半教師あり学習 [8] が存在する。能動学習と異なり、半教師あり学習は、初期の識別器を元にラベル無しデータから、識別確信度が高いものを選択し、その識別結果と同じ分類ラベルを自動的に付与して、新たに学習データにする。この方法では、分類ラベルは自動的に付与できるが、識別の正確さに大きく関連する確信度が低い識別境界付近のデータは、学習データに選択されない問題点がある。

また、アノテーションコストを軽減するため、学習済みの識別器を用いる方法として、転移学習 [9] が存在する。

転移学習は、ある領域のデータで学習された識別器を基本にして、別の領域のデータに合わせて学習する手法である。例えば、ある領域と別の領域でのタスクが異なっても、タスクを遂行するために使う低次の特徴量が似たものならば、特徴量を抽出する部分だけを再利用し、最終的なタスク遂行に関連する部分を変更し、再学習することで転移学習が可能である。この際、再学習に用いる学習データは、最初の基本学習器に比べ、少ないデータでも十分な精度を得られることが期待できる。転移学習で扱う領域の変化は、車の間の特徴の差を吸収するという本研究のよりも、よりダイナミックに環境が変化することを想定しており、本研究で扱う課題に対しては転移学習を用いずとも若干の追加学習で対応できる可能性が高い。また、転移学習では、アノテーションデータの量を抑えられるが、データの選択方法によって、より少ないデータでも十分な精度の識別器を構成できるようにする、という点は検討されていない。

2.1 能動学習

能動学習では、既存の識別器に対してどのようにデータを選択するかが重要であり、さまざまな手法が提案されている [3].

2.1.1 能動学習におけるシナリオ

[3] では学習データの入手方法及びアノテーションを行うための3つのシナリオが紹介されている。

(1) Membership Query Synthesis[10]

入力される可能性のある未知のデータに対してアノテーションを要求する。つまり、識別器によって仮定された入力データ空間上に人工的に生成させ、それに対して人がアノテーションすることで精度を上げようとする。

(2) Stream-Based Selective Sampling[11]

逐次的に送られてくる未知のデータに対してその都度アノテーションの必要性を決定してアノテーションを行う。

(3) Pool-Based Sampling[12]

未知の入力データ集合(プール)の中からデータに対して何らかの基準に関するランク付けを行い、そのランクを元にアノテーションを行う。

本研究では、センサノード内でのデータ入手処理を考える。このとき、(3)がもっとも近いシナリオであることから、本研究では Pool-Based Sampling を用いる。

2.1.2 データ選択手法

能動学習の主なデータ選択手法としては以下のようなものがある [3].

(1) Uncertainty Sampling[12]

識別器による推論で、不確実なデータを選択する手法。

(2) Query-by-Committee[13]

複数の識別器による推論でもっともばらつきのあるデータを選択する手法。

(3) Density-Weighted Methods[14]

データの分布に考慮することで外れ値を選択しないようにする手法。

その他にも様々な手法 [15], [16] がある。(2) Query-by-Committee では、複数の識別器を用いるため、計算能力の限られたセンサノードで実現することは困難である。また、(3) Density-Weighted Methods では、変化の多い実環境ではセンサデータの分布を把握することが難しく、やはりセンサノードへの実装は困難だと考えられる。したがって、最も単純であり、センサノードで容易に処理が可能である (1) Uncertainty Sampling を用いてアノテーションを行うデータを選択する。

このように、能動学習自体は様々な手法が研究されてきた手法であるが、本研究はこれをセンサノードとサーバの通信に組み込み、アノテーションコストの削減と同時に通信量削減にも取り組もうとするものである。また、変化の多い実環境を、限られた通信帯域でセンシングしようとするセンサネットワークと能動学習は非常に相性の良い技術の組み合わせだと考えられる。

3. 提案手法

ここまで述べたように、筆者らは、能動学習をセンサノードとサーバの通信に組み込むことによって、少量のデータで識別器の精度向上が期待できるのではないかと考えた。識別器の精度を向上させるためには、データ量が重要であることを1章で述べたが、実環境でのフィールドセンシングを行う際の問題として、

- (1) 一般に学習時での評価よりも推論時での評価が低くなること
- (2) 送信可能なセンサデータの量に限りがあること
- (3) アノテーションコストが高いこと

がある。(1)は、学習時と推論時でセンサノードの置かれた環境が若干異なる、などの要因で発生する問題であるが、一つの識別器に対してデータを逐次的に追加して学習を行うことで、精度向上を可能にする。(2)及び(3)は、センサノード側によるアノテーションを要するデータ選択を行うことで、通信量削減とアノテーションコストの削減が期待できる。

よって本稿ではそれらを解決する、エッジセンサのための能動学習を用いた車両状態識別モデル更新手法を提案する。

3.1 概要

提案する能動学習を用いた車両状態識別モデル更新手法の概要は図3に示す。提案するモデルはセンサノードとサーバを用いている。センサノード側では、車両の状態を




図 4 識別境界のイメージ図：赤○が正例、青×が負例のデータを表す。能動学習では緑円のデータのみを用いて追加学習を行い識別器の更新を行う。

センシングし識別器を用いて状態の識別を行う。識別結果はサーバに送信するが、センシングデータそのものは送信しない。こうすることで、限られた通信帯域下でセンサノードとサーバ間の通信量を軽減している。ただし、通信帯域に余裕がある場合には、センサノードに保存しているデータの中から一部のセンシングデータをアノテーションのためにサーバへ送信する。サーバ側では受け取ったセンシングデータに対して人手でアノテーションを行い、そのデータを用いて識別器の追加学習を行う。新しい識別器の重みのパラメータはサーバからセンサノードに送信し、センサノードの識別器を更新する。

センサノード側でアノテーションを要求するデータを選択する際に、識別器の精度を向上させられる見込みの高いデータのみを選択することができれば、限られた通信帯域の中で効率的に識別器の追加学習が行えると期待できる。このように能動学習を利用する上では、識別器の精度を向上するためにどのように学習に用いるデータを選択するかが要となる。

図 4 にデータを 2 つのクラスに分類する場合のイメージ図を示す。この図では、多くのデータは正例と負例に正しく分類できているが、識別境界付近では誤って状態識別を行っているデータが数多く見られる。一方で、識別境界から遠い部分では、誤りは減っている。したがって、識別境界付近のデータで学習器を逐次的に追加学習して識別境界を更新することで、精度の向上が期待できる。

3.2 データと状態推定

本稿では、藤沢市のゴミ収集車に搭載されたエッジセンサから得たセンサデータを扱う。センシングに関する詳細は [1] で述べている通りで、ゴミ収集車の運転席の上部に、モーションセンサ (MPU-9250)、GPS、Zynq7010 からなるセンサノードを設置した。Zynq で 3 軸の加速度センサと 3 軸のジャイロセンサのデータを 100Hz で取得し、これを Zynq で処理して車の状態を識別する。

車の状態として、回転板の動作中 (ROLL)、車の走行中 (RUN)、ドアを閉めた振動の発生中 (DOOR) の 3 つをマル




図 5 NN の入力部：A は振幅、t は時刻、f は周波数、 Δ は窓幅、 δ はそのスライド幅を表し、センサ数 $N = 6$ 、スライド幅 $\delta = 100$ 、窓幅 $\Delta = 128$ で、周波数スペクトルに変換する。この周波数スペクトルを 8 個を一つにまとめ、センサ数 6 個分のそれらを NN に入力する。

チタスクで各々正負で 2 値分類する。回転板の動作中には 47Hz 付近にエンジンの振動のピークが出るため、その 2 倍以上の周波数である 100Hz でモーションセンサのデータを取得することとした。車の状態を識別するニューラルネットワーク (以下、NN とする) の入力部分を、図 5 に示す。3 軸加速度と 3 軸角速度のデータをそれぞれ、以下のようにパワースペクトルに変換する。変換する時間領域は、窓関数を用いて $\Delta = 128$ とし、これを時間 (t) 軸方向にスライド幅 $\delta = 100$ で 8 個ずつパワースペクトルに変換する。これを車の状態を識別する NN に入力する。ただし、図 5 でセンサの軸数 $N = 6$ 、変換後の周波数は $f = \Delta/2 + 1 = 65$ とする。

3.3 ニューラルネットワークの構造

使用する NN は、7 層からなるマルチタスクに対応した Convolutional Neural Network (CNN) である。センサデータに対して CNN を用いて波形の特徴量を抽出することで、時系列データを分類問題として扱える。4 層目より深層については、3 つの状態 (ROLL, RUN, DOOR) 毎の系統に別れる構造とすることでマルチタスクを可能としている。

この CNN の構成を図 6 に示す。出力層は 3 つありそれぞれの状態について評価を行うように構成されている。つまり、状況識別として同時事象の発生にも対応している。

3.4 能動学習を用いた車両状態識別モデル更新手法

2 章で述べた通り、既存のアノテーションコストの軽減に関する研究のモデルの多くは、センサノードを考慮したモデルではなかった。本研究では、Uncertainty sampling を用いてアノテーションを要求するデータを選択する。これによりアノテーションコストの削減と、センサノードとサーバ間の通信量を抑えることが可能となる。Uncertainty




図 6 NN の構成図：ただし、
1-2 層目の接続では $stride = (4, 1), padding = (4, 0)$,
2-3 層目の接続では $stride = (4, 1), padding = (28, 0)$,
3-4 層目の接続では $stride = (1, 1), padding = (0, 0)$

sampling の不確実性 (Uncertainty) は、以下のように計算する。

$$Uncertainty = \operatorname{argmin}(P(\text{positive}|x) - P(\text{negative}|x))$$

ただし、 x は未知の入力データ、 P は事後確率、 positive は正例、 negative は負例を表している。つまり、正例である確率と負例である確率の差が少ないデータから順にデータを選択すれば、それらのデータは識別の境界付近にあると考えられ、識別器の追加学習に用いることで識別精度の向上により貢献できると予測される。

このように Uncertainty sampling を行って選択した追加データと、基となる識別器の作成時に用いたデータを用いて追加学習を行い、識別器の更新を行う。

3.5 データの特徴とモデルの評価方法

本研究で用いるデータは 3.2 節で述べた通りであるが、このデータは、表 1 に示す通り、各タスクの正例と負例の割合を比較すると、負例の方が多く、DOOR 状態と ROLL 状態ではその数十倍以上である。正例と負例の数に大きな差があるという特徴は、本研究で扱うデータに特異なものではなく、特に異常検知を行うようなセンシングでは、よく発生するものだと考えられる。このように負例が正例に比べて極端に多い場合、機械学習分野では、モデルの評価指標としては Area Under the Curve (AUC)[17] を用いることが一般的である。AUC は Receiver Operating Characteristic Curve (ROC 曲線) が描く曲線のもとに計算される。ROC 曲線は、予測値を正例とする閾値を 1 から 0 に動かし、そのときの偽陽性率/真陽性率を (x, y) としてプロットすることで描くことができる。この ROC 曲線の下部の面積が AUC である。AUC は 0 から 1 までの値をとり、値が 1 に近いほどモデルの性能が高いことを示す。偽陽性率とは、誤って正例と予測した負例の割合を示す。真陽性率とは、正しく正例と予測した正例の割合を示す。

表 1 各状態ラベルの正例と負例の割合 (%)

状態	正例	負例
ROLL	8.87	91.13
RUN	52.66	47.34
DOOR	2.72	97.28

本研究では、AUC を使うことで実際に正例であるデータの識別精度に強く影響される識別器を作ることが期待できる。また、負例であるデータの誤差には影響されづらい識別器を作ることにも期待できる。

3.6 通信方式

ここまでで述べた方法でアノテーションを行うデータを選択するが、センサノードへの実装としては以下のような手順で行う。

step1 センサデータを計測し、識別を行い、不確実性 u を算出。

step2 送信バッファで最大の不確かさ u_{max} と u を比較。

step3 $u < u_{max}$ であれば、送信バッファにデータを追加。そうでなければ Step4 へ。

step4 もし通信帯域に余裕があれば、 u が最小のデータを送信し、送信が完了したデータは送信バッファから削除。帯域に余裕がなければ Step5 へ。

step5 次のデータの計測のため、Step1 に戻る。

このような手順でデータを送信すれば、データ格納領域に制約のあるセンサノードにおいて、比較的単純なアルゴリズムで、通信帯域の許す限りのデータを送信できる。サーバでは受信したデータを蓄積し、人がアノテーションを行う際に不確実性 u の少ないものから順にデータを選択し、コスト、あるいは時間の許す限りアノテーションを行う。

この手順は 3.2 節で述べたセンサノードに試験的に軽量の識別器を用いて実装し、十分動作することを確認しているが、後述する実験では、提案手法の基本性能を確認するため、あらかじめ収集したデータを用いて実験を行った。

4. 実験

4.1 実験目的

提案手法に関して、実際のゴミ収集車から取得したデータを用いて評価を行うことによって、

- Uncertainty Sampling Model が Random Sampling Model と比較して効率よく精度向上を達成すること
- 状況推定に対して、提案モデルが単純に全てのデータを追加したモデルよりも少ないデータ量で同等の精度で状況識別が可能であり、効率的に学習できることを確認した。

表 2 データセットの詳細

項目名	サイズ	内容
前半データ	5400	各車両の 4 月の 2 日分のデータ
後半データ	5400	各車両の 5 月の 2 日分のデータ

4.2 データセット

実験では、藤沢市を実際に走行する 4 台のゴミ収集車にセンサノードを搭載して取得したセンサを用いて提案手法の評価を行った。実験では、2017 年 4 月と 5 月の 2 日ずつのデータを用い、このデータを表 2 に示すように前後半に分け、前半データで学習器を作り、後半データで状態識別及び評価することとした。

4.3 実験に使用したモデル

本研究では、以下のモデルの評価実験を行う。

BM 10 層からなる CNN モデル

FM BM を全てのデータで追加学習したモデル

RM BM をランダムデータで追加学習したモデル

CM BM を最も確かなデータで追加学習したモデル

UM BM を最も不確かなデータで追加学習をした提案モデル

(1) BM (Baseline Model)

訓練データを用いて、学習を行ったモデル。評価対象の車のデータが学習データに含まれないため、最も評価が低くなると予測される。本稿ではこの BM を基準として各モデルを比較して評価を行う。

(2) FM (Full Dataset Model)

前半データ 4 台分全てを用いて、学習を行ったモデル。評価対象の車の追加データを全て入力して追加学習を行うため、最も評価が高いことが予測でき、この性能に到達することが提案手法の目標と言える。

(3) RM (Random Sampling Model)

追加データから無作為にデータを選択し、BM の追加学習を行ったモデル。評価対象の車の追加データから無作為にデータを選択しているため、BM よりは高い性能になるが、提案手法である CM と比較してやや低い性能となることが予測される。

(4) CM (Certainty Sampling Model)

BM を用いて評価対象の車の追加データから最も確信度の高いデータを選択し、BM の追加学習を行ったモデル。半教師あり学習の一種であり、識別境界から最も遠いデータを選択するため、UM よりは性能が劣るものの、無作為に抽出する RM よりは高い性能となることが予測される。

(5) UM (Uncertainty Sampling Model)

BM を用いて追加データから最も確信度の低いデータを選択し、BM の追加学習を行った提案モデルである。能動学習であり、選択するデータは識別境界に最も近

表 3 実験条件

項目名	内容
訓練データ	対象の 1 台分を抜いた 3 台分の前半データ
検証データ	対象の 1 台分を抜いた 3 台分の後半データ
評価データ	対象の 1 台分の後半データ
追加データ	対象の 1 台分の前半データから選択
問題設定	ROLL, RUN, DOOR を各々 2 分類
学習 Epoch 数	検証データで Early Stopping
損失関数	$-\log(S_{AUC})$ (S_{AUC} は AUC の値)
勾配法	Adam
バッチサイズ	1024
サンプリング数	ROLL, RUN, DOOR の各状態毎に 200

く、これらは識別器の学習で最も重要なデータと言える。したがって、CM よりさらに高く、FM には若干劣る性能を示すことが予測される。UM の作成手順は以下に示す通りである。

step1 訓練データを用いて学習を行った BM で、評価対象の車両の追加データを状態識別を行う。

step2 step1 の識別結果を用いて、Uncertainty sampling を行う。このとき、識別境界に最も近いデータを 200 件選択する。

step3 step2 で選択した 200 件のデータと評価対象の車両を抜いた訓練データを用いて BM の追加学習を行いパラメータを更新する。更新した識別器を UM とする。

4.4 実験の設定

評価指標については 3 章で述べた通りであるが、本稿では、評価方法については各検証モデルを比較するために各車両に対する AUC を用いる。車両 1 台のデータを評価対象とし、残りの 3 台のデータを訓練データと検証データとする交差検証を 4 回繰り返した。

4.5 評価実験結果

評価実験の結果を表 4、表 5 に示す。表 4、表 5 は、検証期間の 2 日間における、車両台数 4 台による評価結果であり、それぞれ各モデルの AUC の平均値と正答率を表している。

表 4 の状態識別における AUC の比較において、BM と UM を比較すると、3 つの状態のうち、ROLL, RUN の 2 つ状態で BM よりも UM の AUC の平均値が向上している。同様に、表 5 の状態識別における正答率において比較しても、ROLL, RUN の 2 つの状態では UM の方が正答率が高い。一方で、DOOR の状態では、BM のままの方が AUC の平均値、正答率ともに高いという結果になった。さらに、BM と FM を比較すると、表 4 の状態識別における AUC の平均値の比較において、ROLL, DOOR で FM の AUC の平均値が BM よりも向上している。

表 4 状態識別における AUC の平均値の比較

検証モデル	ROLL	RUN	DOOR
FM	0.9471	0.9255	0.9147
BM	0.8779	0.9268	0.8180
RM	0.8615	0.9267	0.7986
CM	0.8005	0.9245	0.6507
UM	0.9465	0.9274	0.6311

表 5 状態識別における正答率の平均値の比較 (%)

検証モデル	ROLL	RUN	DOOR
FM	96.93	88.52	98.80
BM	94.79	89.26	98.54
RM	94.78	89.25	98.36
CM	94.62	89.16	98.21
UM	95.13	89.36	98.25




図 7 混同行列：上から BM, RM, UM の順でならんでいる。また、右から ROLL, RUN, DOOR の順で並んでいる。

次に、提案手法 UM と比較手法である RM, CM の評価結果を比較すると、表 4 より、ROLL, RUN で RM より UM の方が AUC の平均値が高くなった。

図 7 に、評価データにおける BM と UM と RM の混同行列を示す。ROLL と RUN の混同行列において、UM と RM の双方と BM を比較すると、UM と RM の真陽性 (TP) が優れている。また、UM と RM を比較すると、UM の真陽性 (TP) の値が高い。

5. 考察

実験で行った FM と BM の評価結果から、BM に対して追加学習を行うことで、精度が向上することがわかった。機械学習によって、およそ 4000 サンプルのデータセット

から BM が作成されるが、このデータに含まれていない車両のデータに対しては十分な学習が行えていないこと、そして、FM に全ての車両のデータを学習させることで、評価対象の車両のデータに対して十分に学習が行え、識別結果がより高い精度となったと考えられる。

RM と CM の双方と UM の評価結果から、提案モデルである UM がより高い精度で ROLL と RUN の識別が行えるようになることがわかった。特に ROLL は、本プロジェクト [1] においてゴミ量の推定を行うために ROLL の状況識別結果が利用するため、識別精度の向上が求められていた。UM を用いることで ROLL の状況識別の評価結果が FM の評価により近い値を示していることから、UM の有用性を示している。本研究で扱ったような、正例と負例の数が大きく異なるようなデータに対しても AUC を損失関数に活用することで、ROLL の識別精度を向上できたのではないかと考えている。

また、表 4 より、DOOR において BM が他のモデルに比べてより高い評価となったが、これは、機械学習分野では一般的にデータ量が多くなれば、精度も上がることが期待できるという知見に反する。DOOR の正例データと負例データの割合は、3 章で述べた通りであるが、そもそも正例が極端に少なく BM がうまく学習を行えていない可能性があり、BM によるデータ選択時に、うまくデータを選択することができていない可能性がある。このことから、能動学習は基となるモデルの識別結果に大きく左右されることがわかった。

さらに、RUN における各モデルの評価は UM がわずかに高いが、BM と FM の AUC の平均値を比べるとほぼ変わらない結果となった。つまり、選択できるデータを全て用いても、RUN の状態識別の精度向上に効果がない可能性がある。RUN の正例データは他の 2 つの状態の割合よりも多く、半分以上が正例データであるため、BM で用いた訓練データのみで十分に学習を行っていたのではないかと考えられる。

正答率の平均では、RUN は他の状態に比べて低い結果であった。特に DOOR と比較すると、AUC の平均では、RUN の方が高い評価となっているが、正答率では DOOR が高い値を示している。これは、DOOR や ROLL では正例データの割合が極端に少なく、状態識別の結果の多くを負例とすることで正答率が上がるため、状態識別の際に誤って解釈をしてしまう可能性がある。実際に正答率で 98% を超えている DOOR において、図 7 の混同行列を見ると、TP の値が偽陽性 (FP) の値より少なく、うまく学習出来ていないことがわかった。

このように本研究では、センサノードとサーバ間の通信帯域に制限のあるセンシング環境において、アノテーションコストの削減とそれぞれの識別器の精度向上に着目して、能動学習を用いることで、それらを解決することがで

き、少量の訓練データで学習した識別器の精度を効率的に向上させられる可能性を示せた。

6. まとめ

本研究では、識別器を作成するだけでなく、センサノードとサーバ間の通信帯域及びアノテーションコストに着目して識別器の更新を行う、エッジセンサのための能動学習を用いた車両状態識別モデル更新手法を提案した。

4台のゴミ収集車のセンサデータを用いて実験を行い、車両別に追加学習を行って状況識別に状態識別モデルを更新すると、認識精度が向上することを確認した。この結果、提案手法を用いて追加学習に用いるデータを選択すると、効率的に追加学習を行えることを示せた。そして、提案モデルを用いることで、実際にアノテーションコストを下げるだけでなく、センサノードとサーバ間の通信量を軽減できる可能性について述べた。

今後の課題としては、実機での実行可能性の検証や適用範囲に関する調査が挙げられる。本稿で扱ったDNNモデルは、能動学習による識別器更新の可能性をまず示すため、非力なセンサノードでの実行を想定すると冗長な構成となっている。これを実際のセンサノードへ搭載可能なサイズに収め、実際に運行する車両へ搭載して実証実験を行いたい。さらに、多様な環境や車両以外のセンサを対象とした実験を行い、提案手法の適用範囲を明らかにしたい。

本研究は、車両のセンシング、機械学習の発展など、多分野にわたる様々な成果によって初めて可能になったものである。提案手法を実環境をセンシングするシステムに導入することで、実世界の状況の変化やセンサの劣化など、時間経過とともに発生する様々な事象に対応できるようになり、センシングシステムの継続的運用が可能になると考えている。

参考文献

- [1] 岸野泰恵, 白井良成, 水谷伸, 竹内孝, 須山敬之, 納谷太, 上田修功. ゴミ収集車に搭載したセンサを用いた状況識別による地区別ゴミ量推定と地区特性の分析. 研究報告ユビキタスコンピューティングシステム (UBI), Vol. 2019, No. 15, pp. 1–7, 2019.
- [2] Chen Sun, Abhinav Shrivastava, Saurabh Singh, and Abhinav Gupta. Revisiting unreasonable effectiveness of data in deep learning era. In *Proceedings of the IEEE international conference on computer vision*, pp. 843–852, 2017.
- [3] Burr Settles. Active learning literature survey. Technical report, University of Wisconsin-Madison Department of Computer Sciences, 2009.
- [4] Hao Su, Jia Deng, and Li Fei-Fei. Crowdsourcing annotations for visual object detection. In *Workshops at the Twenty-Sixth AAAI Conference on Artificial Intelligence*, 2012.
- [5] Huan Ling, Jun Gao, Amlan Kar, Wenzheng Chen, and Sanja Fidler. Fast interactive object annotation with curve-gcn. In *Proceedings of the IEEE Conference on*

- Computer Vision and Pattern Recognition*, pp. 5257–5266, 2019.
- [6] Burr Settles, Mark Craven, and Lewis Friedland. Active learning with real annotation costs. In *Proceedings of the NIPS workshop on cost-sensitive learning*, pp. 1–10. Vancouver, CA, 2008.
- [7] 渡邊正人, 菅原俊, 田口賢佑, 船津陽平. 能動学習のための教師なしアノテーション対象データ選択手法. 研究報告コンピュータビジョンとイメージメディア (CVIM), Vol. 2018, No. 38, pp. 1–8, 2018.
- [8] Olivier Chapelle, Bernhard Schölkopf, and Alexander Zien. *Semi-Supervised Learning*. The MIT Press, 1st edition, 2010.
- [9] Sinno Jialin Pan and Qiang Yang. A survey on transfer learning. *IEEE Transactions on knowledge and data engineering*, Vol. 22, No. 10, pp. 1345–1359, 2009.
- [10] Dana Angluin. Queries and concept learning. *Machine learning*, Vol. 2, No. 4, pp. 319–342, 1988.
- [11] David Cohn, Les Atlas, and Richard Ladner. Improving generalization with active learning. *Machine learning*, Vol. 15, No. 2, pp. 201–221, 1994.
- [12] David D Lewis and Jason Catlett. Heterogeneous uncertainty sampling for supervised learning. In *Machine learning proceedings 1994*, pp. 148–156. Elsevier, 1994.
- [13] H Sebastian Seung, Manfred Opper, and Haim Sompolinsky. Query by committee. In *Proceedings of the fifth annual workshop on Computational learning theory*, pp. 287–294. ACM, 1992.
- [14] Burr Settles, Mark Craven, and Soumya Ray. Multiple-instance active learning. In *Advances in neural information processing systems*, pp. 1289–1296, 2008.
- [15] D.Cohn. Neural network exploration using optimal experiment design. In *Advances in Neural Information Processing Systems (NIPS)*, Vol. 6, pp. 679–686, 1994.
- [16] M.Craven S.Ray. Supervised versus multiple instance learning: An empirical comparison. In *Proceedings of the International Conference on Machine Learning (ICML)*, pp. 697–704. ACM, 2005.
- [17] Tom Fawcett. An introduction to roc analysis. *Pattern recognition letters*, Vol. 27, No. 8, pp. 861–874, 2006.