

# 観光地オブジェクト認識モデル構築のための 端末間通信型連合学習におけるデジタルサイネージ活用法の検討

## Exploring Utilization of Digital Signage in Inter-device Communication Federated Learning for Tourism Object Recognition Model Construction

酒井 裕基<sup>†</sup>  
Yuki Sakai

Francis Jerome Tiausas<sup>†</sup>

諏訪 博彦<sup>†</sup>  
Hirohiko Suwa

安本 慶一<sup>†</sup>  
Keiichi Yasumoto

### 1. はじめに

新型コロナウイルス感染症 (COVID-19) の世界的な拡大により、経済的に最も大きな影響を被った業界のひとつである観光業においては、IoTを活用した新たな付加価値を観光客に提供するサービスが求められている。特に、スマートフォンに代表されるエッジデバイスのハードウェア性能向上や5Gなどの帯域幅の広い次世代ネットワークの普及により、観光客のスマートフォン上で動作する、人工知能 (AI) を活用した多様な観光サービスが提案されている [1][2]。

AIサービスの高度化に伴い、AIを構築する技術である深層学習においては、訓練データの規模や、訓練データを提供する学習参加者数が、年々増加している。しかし、クラウドサーバ (以降、単にサーバと呼ぶ) が各学習参加者から収集した訓練データを自身の学習モデルに投入することでモデルの学習・構築を進める従来の中央集中型の学習手法では、サーバ内でのモデルの学習過程や訓練データの送信過程において、訓練データに含まれる学習参加者のプライバシー情報がサーバや他の学習参加者に漏洩する恐れがある。

上記の問題を解決する深層学習手法として、GoogleはFederated Learning (連合学習) を提案している [3]。連合学習では、学習参加者が自身の訓練データを用いてデバイス内に存在するローカルモデルの学習を行ったのち、サーバが各学習参加者から学習済みのローカルモデルのパラメータを収集・統合することにより、グローバルモデルの構築を行う。各学習参加者の訓練データは外部に対して秘匿されると同時に、最終的にサーバで構築されるグローバルモデルは、各学習参加者の訓練データを間接的に利用しているとみなせることから、連合学習はモデルの精度向上とプライバシー保護を両立した学習手法といえる。

我々の先行研究 [4] は、観光分野へ連合学習を適用することを前提に、従来の連合学習フレームワークを改良し、遅延耐性ネットワーク (DTN) を活用することにより、サーバが介在することなくモデルの構築を行う端末

間通信型の連合学習を提案している。しかしながら、簡単な分類問題であっても、モデルの精度が向上しにくいという欠点を有している。

そこで、本研究では、近隣のモバイル端末から送信されたモデルパラメータを保管するデジタルサイネージを各観光スポットに配置することで、各モバイル端末が間接的に取得することのできるモデルパラメータの個数を増加させることにより、最終的に構築されるモデルの精度向上を図る手法について提案する。また、その有効性について簡易的な評価を行った結果を報告する。

本稿の構成は以下の通りである。まず、2章で本研究の関連研究について述べ、3章では問題設定を提示する。4章では本提案手法が採用する、統合後モデル精度予測に基づくモバイル端末の操作選択手法について述べる。5章ではシミュレーションの概要とその結果を紹介し、最後に、6章で本稿をまとめる。

### 2. 関連研究

本章では、関連研究として、観光地オブジェクト認識モデルを構築する上で適用可能な連合学習手法について述べる。

#### 2.1 階層型連合学習

モデルの学習に参加するモバイル端末の移動に対応した連合学習の手法として、モバイル端末とサーバが直接的に接続されておらず、階層的なネットワークにより接続された階層型連合学習 (Hierarchical Federated Learning) があげられる。

Yuら [5]、および Farcasら [6] は、現実的な階層型連合学習フレームワークを提案している。この階層型連合学習のシステムアーキテクチャは、従来の連合学習の構成要素であるサーバ、モバイル端末に加え、ゲートウェイまたはアクセスポイント (以降、単にゲートウェイと呼ぶ) により構成されている。指定エリア内の複数個所に配置されたゲートウェイでは、各時刻ごとに近隣のモバイル端末を選択し、そのモバイル端末群からモデルパラメータを収集し、集約したうえでサーバへと送信することにより、グローバルモデルを得る。この手法は、ネットワーク構成の変化に柔軟に対応できる一方で、従来手

<sup>†</sup> 奈良先端科学技術大学院大学, Nara Institute of Science and Technology

法と同様に最終的なモデルの構築にサーバを要するのに加え、モバイル端末・ゲートウェイ間の通信範囲に特段の制約がなく、場合により4G LTE, 5G等の広域・遠距離通信を用いることから、サーバを活用することなくDTNのみでモデルの構築を図る本研究の目的とは異なる。

## 2.2 端末間通信型連合学習

富田ら [4] は、観光オブジェクト認識モデルを構築することを念頭に、DTNを活用したすれ違い通信により、近隣のモバイル端末間でローカルモデルのパラメタの交換・統合操作を繰り返す連合学習フレームワークを提案している。この手法は、複数のモバイル端末のみでモデルの学習・構築が完結し、サーバとの広域・遠距離通信を必要としないことから、低コストかつロバストなモデル学習を実現している。

一方で、評価のためのシミュレーション実験では、現実のAIサービスで用いられているデータセットと比してカテゴリサイズの小さいデータセットであるCIFAR-10[7]を用いているにもかかわらず、最終的に各モバイル端末内で構築されるモデル精度は60%前後にとどまっている。このモデルの精度は、他端末とのコンタクト回数や、すれ違い通信によって入手したモデルの訓練データの多様性に依存していると考えられることから、さらにモデルの精度を向上させるためには、より多様なモデルのパラメタを入手できる機会を設けることが必要である。

そこで、本研究では、富田ら [4] の想定環境を拡張し、モバイル端末のモデルを保管するデジタルサイネージを各観光エリア内に配置し、各モバイル端末が他のモバイル端末に加え、デジタルサイネージとも通信することにより、より多くのモデルパラメタを入手できる連合学習の手法について検討する。

## 3. 問題設定

本研究が想定する環境の要素とその定義を、表1に示す。

観光エリア  $A$  内には、連合学習に参加できる十分な性能を有したスマートフォン等のモバイル端末（移動端末）を保有する観光客が複数存在する（一人あたり1台保有とする）。 $A$  内のモバイル端末の集合を  $C_m$  とする。各観光客は  $A$  内を自由に移動することが可能である。

観光スポット  $a \in A$  は、観光客が認識したい固有の認識オブジェクト種類の集合  $O_a$  を有する。また、 $a$  は、特定の場所に固定設置された、内部ストレージを有する1台のデジタルサイネージ（固定端末）を有する。 $A$  内のデジタルサイネージの集合を  $C_s$  とする。デジタルサイネージは、近隣のモバイル端末と通信し、そのモバイル端末が保有しているモデルを取得・保管することが可能であるが、他のデジタルサイネージと通信することは

できない。

以上より、 $A$  内の全端末の集合  $C$  は、式 (1) のようにあらわされる。

$$C = C_m \cup C_s \quad (1)$$

想定環境における時間を一定時間間隔の時刻の有限集合  $T$  として表す。 $t \in T$  における  $c_m \in C_m$  の位置を  $pos(c_m, t)$  とする。時刻  $t$  において、二つのモバイル端末  $c_m, c'_m$  が互いに通信可能な範囲  $R_{mm}$  にいる場合、互いにコンタクトしているとみなし、そのコンタクトを  $cn_{mm}(c_m, c'_m, t)$  と表すと、二つの移動端末間のコンタクトの集合  $CN_{mm}$  は、式 (2) のように表される。

$$CN_{mm} = \{cn_{mm}(c_m, c'_m, t) \mid c_m, c'_m \in C_m, t \in T, |pos(c_m, t) - pos(c'_m, t)| \leq R_{mm}\} \quad (2)$$

また、 $c_s \in C_s$  の位置を  $pos(c_s)$  とおく。時刻  $t$  において、デジタルサイネージ  $c_s$ 、モバイル端末  $c_m$  が互いに通信可能な範囲  $R_{sm}$  にいる場合、互いにコンタクトしているとみなし、そのコンタクトを  $cn_{sm}(c_s, c_m, t)$  と表す。このとき、二つの移動端末間のコンタクトの集合  $CN_{sm}$  は、式 (3) のように表される。

$$CN_{sm} = \{cn_{sm}(c_s, c_m, t) \mid c_s \in C_s, c_m \in C_m, t \in T, |pos(c_s) - pos(c_m, t)| \leq R_{sm}\} \quad (3)$$

以上より、全ての端末間で発生するコンタクトの集合  $CN$  は、式 (4) のように表される。

$$CN = CN_{mm} \cup CN_{sm} \quad (4)$$

モバイル端末  $c_m \in C_m$  はモデル学習用の訓練データを持つ一方で、デジタルサイネージは訓練データを収集しない。このことから、 $A$  内の端末が保有する訓練データの集合  $D$  は、式 (5) のように表される。

$$D = \bigcup_{c_m \in C_{mobile}} D_{c_m} \quad (5)$$

各モバイル端末  $c_m \in C_m$  は、自身の保有する訓練データ  $D_{c_m}$  で学習した観光オブジェクト認識モデル  $M_{c_m}$  を所持している。 $M_{c_m}$  にはユーザがオブジェクト認識したいエリア  $A_{c_m} \subseteq A$  が設定されている。その観光オブジェクトの種類集合  $O_{c_m}$  を式 (6) で定義する。

$$O_{c_m} = \bigcup_{a \in A_{c_m}} O_a \quad (6)$$

モバイル端末  $c_m \in C_m$  は、連合学習開始時点で、ベースモデルとして自身のオブジェクト認識モデル  $M_{c_m}$  を

表 1: 想定環境の要素一覧及びその定義

要素	定義
$A$	観光スポットの集合 (観光エリア)
$A_{c_m}$	移動端末 $c_m$ が認識能力を強化したいスポット
$O_a$	認識オブジェクトの集合
$O_{c_m}$	移動端末 $c_m$ の認識対象オブジェクトの集合
$C_m$	移動端末の集合
$C_s$	固定端末の集合
$C$	全端末の集合
$R_{mm}$	移動端末間の通信可能範囲
$R_{sm}$	移動端末・固定端末間の通信可能範囲
$D_c$	端末 $c$ 内の訓練データ
$D$	環境内の訓練データの集合
$M_{c_m}$	移動端末 $c_m$ が所有するモデル
$M_{c_s}$	固定端末 $c_s$ が所有するモデルの集合
$W_c$	モデル $M_c$ の重みパラメタ
$T$	想定環境内の時刻 $t$ の集合
$pos(c_m, t)$	時刻 $t$ での移動端末 $c_m$ の位置
$pos(c_s)$	固定端末 $c_s$ の位置
$cn_{mm}(c_m, c'_m, t)$	時刻 $t$ での移動端末 $c_m$ , 移動端末 $c'_m$ のコンタクト
$CN_{mm}$	移動端末間のコンタクト集合
$cn_{sm}(c_s, c_m, t)$	時刻 $t$ での固定端末 $c_s$ , 移動端末 $c_m$ のコンタクト
$CN_{sm}$	移動端末・固定端末間のコンタクト
$CN$	全端末のコンタクト集合
$S_{c_s}$	固定端末 $c_s$ のストレージ容量

保有している。時刻  $t$  で他のモバイル端末  $c'_m \in C_m$  の間で1対1のコンタクトが発生した場合、モバイル端末  $c_m$  は、以下の操作のうちいずれかを実行することができる。

1. それぞれのモデルのパラメタである  $W_{c_m}, W_{c'_m}$  を統合する
2. 何もしない

各デジタルサイネージ  $c_s \in C_s$  は、自身のオブジェクト認識モデルを保有しない。時刻  $t$  でモバイル端末  $c_m$ , デジタルサイネージ  $c_s$  の間で1対1のコンタクトが発生した場合、モバイル端末  $c_m$  は、以下の操作のうちいずれかを実行することができる。

1. 自身のモデル  $M_{c_m}$  をデジタルサイネージに送信する
2. デジタルサイネージに保管されている、他モバイル端末  $c'_m$  のモデル  $M_{c'_m}$  を新たな自身のモデル  $M_{c_m}$  として置き換える
3. 何もしない

1. の操作により、モバイル端末  $c_m$  からモデル  $M_{c_m}$  を受信した場合、デジタルサイネージ  $c_s$  は、 $M_{c_m}$  を新たに

内部ストレージに保存する。なお、新たにモデルを保管しようとするストレージ容量  $S_{c_s}$  を超えると判断される場合は、 $c_m$  は1. の操作を実行することができない。

1 台のモバイル端末が複数の端末とコンタクトした場合、その中から1台の端末と通信し、その端末の種類に対応する操作を実行することが可能であるとする。この制約を二値変数  $x_{cn_{mm}(c_m, c'_m, t)}$ ,  $x_{cn_{sm}(c_s, c_m, t)}$  を用いて式 (7)(8) で定義する。

$$\forall c_m, c'_m \in C_m, \forall t \in T$$

$$\sum_{cn_{mm}(c_m, c'_m, t) \in CN_{mm}, c_m \neq c'_m} x_{cn_{mm}(c_m, c'_m, t)} \leq 1 \quad (7)$$

$$\forall c_s \in C_s, \forall c_m \in C_m, \forall t \in T$$

$$\sum_{cn_{sm}(c_s, c_m, t) \in CN_{sm}} x_{cn_{sm}(c_s, c_m, t)} \leq 1 \quad (8)$$

これらの二値変数は、モデル共有の判断に用いる変数であり、2 端末間でモデル共有を行う場合は1、共有しない場合は0の値をとる。

本研究では、各モバイル端末の通信回数、消費電力を最小化しながらモデルの改善度合いを最大化することを目指しているため、モバイル端末は、コンタクト発生時にモデル精度向上に効果的な操作の選択を行うことが必要となる。 $M_c$  に  $M_c'$  のパラメタを統合することによるモデル精度の改善度合いを  $Improve(M_c, M_c')$  として、本問題の目的関数を式 (9) に表す。

$$\begin{aligned} \text{maximize} \{ & \sum_{c_m \in C_m} \sum_{c'_m \in C_m} \sum_{t \in T} \sum_{cn_{mm}(c_m, c'_m, t) \in CN_{mm}} \\ & x_{cn_{mm}(c_m, c'_m, t)} \cdot Improve(M_{c_m}, M_{c'_m}) + \\ & \sum_{c_s \in C_s} \sum_{c_m \in C_m} \sum_{t \in T} \sum_{cn_{sm}(c_s, c_m, t) \in CN_{sm}} \sum_{m_{c_s} \in M_{c_s}} \\ & x_{cn_{sm}(c_s, c_m, t)} \cdot Improve(M_{c_m}, m_{c_s}) \} \quad (9) \\ \text{subject to} & (7), (8) \end{aligned}$$

なお、本研究では、デジタルサイネージの通信回数や消費電力については、議論の対象外である。

#### 4. 精度予測に基づく操作選択

富田ら [4] は、自分と相手のモデルの精度から統合前後の精度の変化を予測する回帰モデルを作成し、このモデルを活用することにより、モデルの精度情報を端末間で交換することで自身にとって有用なモデルパラメータを選択する手法を提案している。

本提案手法においても、この統合後モデルの精度予測手法を活用してコンタクト発生時のモバイル端末の操作選択を実施する。具体的には、他モバイル端末とのコンタクト発生時には、自身のモデル精度と相手のモデル精度を精度予測回帰モデルに投入し、自身のモデルの精度が向上されると判断される場合のみモデルパラメタの統合を実施する。また、デジタルサイネージとのコンタクト発生時には、サイネージの内部ストレージに保存されている全てのモデルパラメタの精度情報を取得し、最も統合後のモデル精度が向上すると考えられるモデルパラメタを選択して、自身のモデルに統合する。なお、統合後に作成されるいずれのモデルよりも、現時点での自身のモデルの精度が明らかに高いと判断される場合は、モデルの統合を行わず、自身のモデルパラメタをデジタルサイネージに送信する。

## 5. シミュレーション実験と評価

端末間連合学習にデジタルサイネージを導入することの有効性を評価するために、現実的なユースケースシナリオに基づいたシミュレーション実験を実施し、端末間のコンタクト回数の評価を実施した。本章では、ユースケースシナリオと実験概要、評価結果について述べる。

### 5.1 ユースケースシナリオ

本シミュレーションは、想定環境として、奈良市内の特定の観光エリア集合(図1)内に存在する3つの観光スポット、奈良公園・東大寺・春日大社を対象としている。モバイル端末を保有した観光客は、各観光スポットを巡りながら、自らの撮影した画像データにラベリングを行い、訓練データとして自身が予め受け取ったベースモデルの学習に利用する。観光客のモバイル端末は、移動中10秒おきに近隣のモバイル端末やデジタルサイネージのうちのひとつと相互に通信し、必要に応じてモデルパラメタの取得・自身のモデルの更新を行うことで、最終的に各スポットに固有のオブジェクトを認識できるモデルの構築を目指す。

具体的なオブジェクトとしては、以下のようなものを想定している。

- $O_{奈良公園}$ : { 牡鹿, 牝鹿, 小鹿, 鹿煎餅の売店, ... }
- $O_{東大寺}$ : { 仏像, 池, 鯉, 桜, 牡鹿, 牝鹿, ... }
- $O_{春日大社}$ : { 藤, 鳥居, 池, 鯉, 社, ... }

3つの観光スポットには、人流が多いと考えられる地点にサイネージ  $c_{奈良公園}$ ,  $c_{東大寺}$ ,  $c_{春日大社}$  がそれぞれ配置されている(図2)。各サイネージの具体的な配置場所を、以下に示す。

- $c_{奈良公園}$ : バス停「県庁東」付近

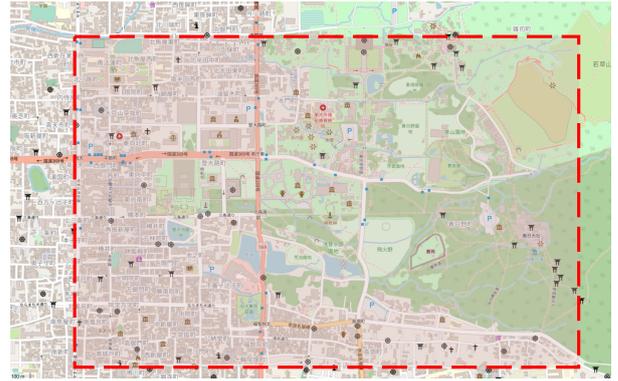


図1: 本シミュレーションが想定する観光エリア

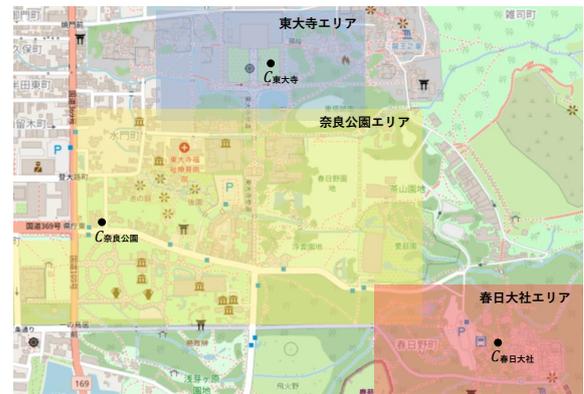


図2: デジタルサイネージの配置図

- $c_{東大寺}$ : 東大寺中門付近
- $c_{春日大社}$ : 春日大社車御祓所付近

各サイネージは、モデルの学習に用いる訓練データは保有していないが、近隣のモバイル端末から送信されたモデルを内部ストレージに保管している。それぞれのサイネージは、要求のあったモバイル端末に対し、保管しているモデルの複製を送信することができる。デジタルサイネージが保管しているモデルは、取得後1日を経過した時点で消去される。

### 5.2 シミュレーション実験の概要と評価方法

シミュレーション実験では、ユースケースにおけるモバイル端末間のコンタクト回数、およびモバイル端末・デジタルサイネージ間のコンタクト回数を評価した。

シミュレーションに当たっては、株式会社Agoopが提供するモバイル端末の移動軌跡データ、ポイント型流動人口データ[8]を使用した。2020年11月1日から2020年11月30日までの6時から18時の時間帯で、図1のエリア内に存在したユーザの中から、観光客と推測されるものを抽出し、1876人分の移動軌跡データを得た。ポイント型流動人口データで得られる軌跡データは、実世界の軌跡データと比べて少ないことから、これら1か月

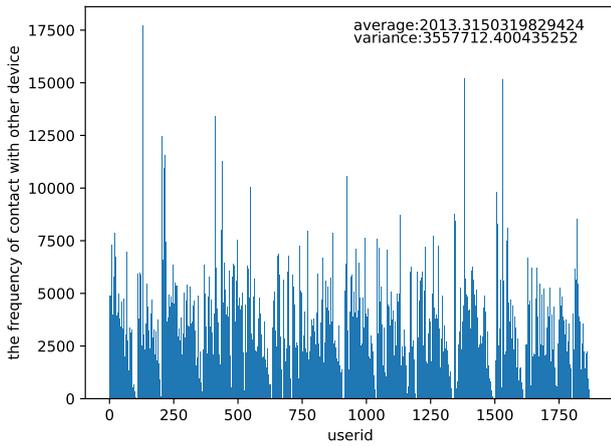


図 3: 端末別の他モバイル端末とのコンタクト回数

分のデータを1日分のデータとして扱い、実世界における観光客の移動データとした。10秒おきに各ユーザの座標を取得し、半径50m以内に他のユーザまたはデジタルサイネージが存在する場合にコンタクトが発生したとみなし、その回数を計測した。

### 5.3 シミュレーション結果

モバイル端末間のコンタクト回数は、合計で3,772,350回となった。モバイル端末1台ごとの他モバイル端末とのコンタクト回数を、図3に示す。グラフの横軸は、端末に固有のユーザIDを表している。なお、ここでは、文字列のユーザIDを0から1875までの整数に置換している。また、縦軸は、他モバイル端末とのコンタクト回数を表している。他モバイル端末とのコンタクトが1回以上発生したモバイル端末は、全1,876台のうち1,755台であった。

一方で、モバイル端末・デジタルサイネージ間のコンタクト回数は、合計で72,472回となった。モバイル端末1台ごとのデジタルサイネージとのコンタクト回数を、図4に示す。グラフの横軸は、端末に固有のユーザIDを表している(図3と同様)。また、縦軸は、デジタルサイネージとのコンタクト回数を表している。デジタルサイネージとのコンタクトが1回以上発生したモバイル端末は、全1,876台のうち1,289台であった。また、デジタルサイネージ1台ごとのモバイル端末とのコンタクト回数を、表2に示す。

以上の結果から、モバイル端末・デジタルサイネージ間のコンタクト回数は、モバイル端末間のコンタクト回数と比べて小さいものの、全体の約2/3のモバイル端末がデジタルサイネージとコンタクトできていることが分かった。デジタルサイネージは複数のモデルを保管できるため、デジタルサイネージを人流の多い適切な場所に

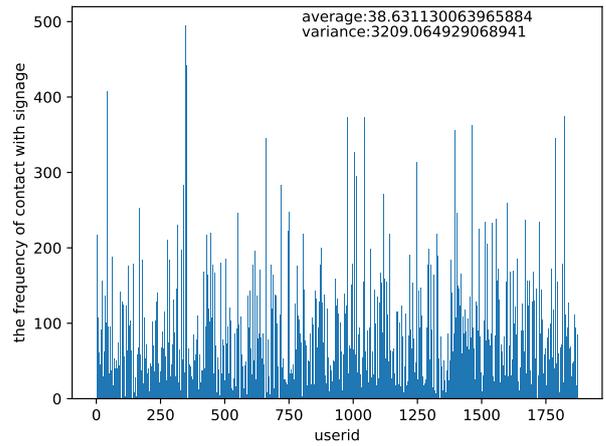


図 4: 端末別のデジタルサイネージとのコンタクト回数

表 2: 各サイネージのコンタクト回数

サイネージ	コンタクト回数
C奈良公園	13598
C東大寺	53296
C春日大社	5578

配置すれば、各モバイル端末がより多様なモデルパラメータを取得できると考えられる。また、デジタルサイネージとのコンタクトを経験したモバイル端末が他のモバイル端末とコンタクトすることで、デジタルサイネージを設置したことによる影響が、エリア内のモバイル端末全体に波及することが予想される。その結果として、モデルパラメータの交換・統合回数が増加し、最終的に各モバイル端末内で構築されるモデルの精度が向上すると考えられる。

## 6. おわりに

本稿では、観光地においてオブジェクト認識モデルを構築することを想定し、構成要素として新たにデジタルサイネージを追加した端末間連合学習の手法について提案した。この狙いは、近隣モバイル端末から送信されたモデルを一時的に保管するデジタルサイネージを追加することにより、学習に参加するモバイル端末が近隣端末との通信を通して得られるモデルパラメータの数を増加させることで、最終的に構築されるオブジェクト認識モデルの精度を向上させることにある。

本提案手法の有効性を検証するため、実際のユースケースを想定し、デジタルサイネージを追加した環境下での端末間のコンタクト回数を計測する簡易的な評価を実施した。その結果として、多くの端末がデジタルサイネージとコンタクトしていることが確認された。デジタ

ルサイネージは、多くのモデルを保管できるため、端末間でのモデルパラメータ統合回数が増加し、最終的にモバイル端末内で構築されるモデルの精度が向上すると考えられる。

一方で、本稿におけるシミュレーションは、端末間のコンタクト回数のカウントに留まっており、実際に行われるモデルの統合回数やモデル精度の変化については検証できていない。このため、今後は、各モバイル端末にオブジェクト認識モデルを対応付けてより実践的なシミュレーションを行い、どのようにモデルが交換され、モデルの精度が変化するかを分析することで、本提案手法の有効性を検証する予定である。

#### 謝辞

本研究は JSPS 科研費 JP21H03431 の助成を受けたものです。

#### 参考文献

- [1] Diego R Toubes, Noelia Araújo Vila, and Jose A Fraiz Brea. Changes in consumption patterns and tourist promotion after the COVID-19 pandemic. *Journal of Theoretical and Applied Electronic Commerce Research*, Vol. 16, No. 5, pp. 1332–1352, 2021.
- [2] Raffaele Filieri, Elettra D’Amico, Alessandro Destefanis, Emilio Paolucci, Elisabetta Raguseo. Artificial intelligence (AI) for tourism: an European-based study on successful AI tourism start-ups. *International Journal of Contemporary Hospitality Management*, Vol. 33, No. 11, pp. 4099–4125, 2021.
- [3] Liu Yang Chen Tianjian Yang, Qiang and Yongxin Tong. Federated Machine Learning: Concept and Applications. *ACM Transactions on Intelligent Systems and Technology (TIST)*, Vol. 10, No. 2, pp. 1–19, 2019.
- [4] Shusaku Tomita, Jose Paolo Talusan, Yugo Nakamura, Hirohiko Suwa, and Keiichi Yasumoto. Fed-Tour: Participatory Federated Learning of Tourism Object Recognition Models with Minimal Parameter Exchanges between User Devices. In *2022 IEEE International Conference on Pervasive Computing and Communications Workshops and other Affiliated Events (PerCom Workshops)*, pp. 667–673. IEEE, 2022.
- [5] Xiaofan Yu, Ludmila Cherkasova, Harsh Vardhan, Quanling Zhao, Emily Ekaireb, Xiyuan Zhang, Arya Mazumdar, and Tajana Rosing. Async-HFL: Efficient and Robust Asynchronous Federated Learning in Hierarchical IoT Networks. In *Proceedings of the 8th ACM/IEEE Conference on Internet of Things Design and Implementation*, 2023.
- [6] Allen-Jasmin Farcas, Myungjin Lee, Ramana Rao Kompella, Hugo Latapie, Gustavo De Veciana, and Radu Marculescu. MOHAWK: Mobility and Heterogeneity-Aware Dynamic Community Selection for Hierarchical Federated Learning. In *Proceedings of the 8th ACM/IEEE Conference on Internet of Things Design and Implementation*, pp. 249–261, 2023.
- [7] CIFAR-10 and CIFAR-100 datasets. <https://www.cs.toronto.edu/~kriz/cifar.html>. Accessed: 2023-07-18.
- [8] 流動人口データ. 株式会社 Agoop. <https://agoop.co.jp/service/dynamic-population-data/>. Accessed: 2023-07-18.