

# Federated Learning over DTN によるオブジェクト認識モデルの地域間での共有手法の検討

A method for sharing object recognition models among regions with Federated Learning over DTN

富田 周作<sup>†</sup> 中村 優吾<sup>†</sup> 諏訪 博彦<sup>‡</sup> 安本 慶一<sup>‡</sup>  
Shusaku Tomita Yugo Nakamura Hirohiko Suwa Keiichi Yasumoto

## 1. はじめに

この数年間に、スマートフォンが一般に普及したことで、人々が情報通信技術 (ICT) を利用する頻度が高くなった。ICT の利用が容易になったことにより、その利便性が一般社会に普及し日常生活の様々な場面において利便性をもたらしている。観光分野においても ICT の活用が進んでおり、観光エリアに関する情報の広範囲への提供や観光客からのフィードバックの獲得が容易となった。更に、スマートフォンの GPS を用いた位置情報や SNS への投稿等のデータに基づき、観光客の行動原理等の把握が可能になると考えられている。ICT を利用して観光に関わる現象を把握することによって、外国人観光客や日本人観光客のリピータの増加に繋がる企画の立案が促されると期待されている [1]。また、ICT の普及に貢献しているスマートフォン等のスマートデバイスの性能も改善しており、バッテリーの持続時間やデータの処理性能が年々向上している。デバイスの種類も、スマートウォッチやスマートグラス等、多様性に富むようになり我々の生活に浸透しつつある。近年、ビッグデータ分析とその活用に対する社会の注目度が高くなっており、データ収集やその分析結果に基づくサービスの提供が前述のスマートデバイスを通して行われている。本研究で対象とする観光分野においても今後ビッグデータ分析の技術が応用され、より高度な観光サービスが社会に普及していくと予想される。しかし、ビッグデータ分析には膨大な量のデータが必要となる。そのような大量のデータは大企業や行政機関等大きな組織が所有することが多いが、プライバシーの保護や組織間の競合等の観点から外部に公開されることはほとんどない。しかし、組織が所有するデータにも、量・多様性において限りがあり、機械学習により訓練したモデルを構築しても、その汎化性能に限界がある。この課題の改善には、組織が所有するビッグデータの他にスマートフォンユーザー等の個人が収集・所有するデータの使用が有望であるが、プライバシー保護やリソースの制限の観点で困難である。

上記の問題に対して Google は Federated Learning という呼ぶ手法を提案している。Federated Learning は、複数のデバイスが分散して持つデータをモデルの訓練に使用する手法である [2]。この手法の利点として、ローカルにあるデータをオンデバイスで訓練し、デバイスごとに訓練したモデルを外部で統合するため、プライバシー情報を含む生データを外部に提供する必要がないことが挙げられる。プライバシー情報の有無に依存しない機械学習が可能になれば、多様で膨大なデータに対応可能なモデルを獲得することが容易になり、汎化性能の高いモデルによって様々な分野での応用範囲が広がると期待されている。しかし、Federated Learning のオリジナルの文献 [2] に述べられている手法では、外部サーバが必要であり、デバイスの数や分布範囲が大きくなる程、広域ネットワークへの依存性が高まる。従って、広域通信が利用できないあるいは不安定な場所や状況においては Federated Learning を行うことが困難となる。また、ユーザは WiFi などが使えない環境にいる場合、4G などの広域通信を利用してサーバとの通信を行う必要が生じ、それには費用がかかることから、ユーザが Federated Learning の利用を望まないことも考えられる。そのため、Federated Learning を実行するタイミングが制限される。特に、観光分野での利用を想定した場合、観光客は広範囲を移動することも多いので、Federated Learning を行うためにはユーザは通信のコストを負担しなければならない。

そこで、本研究では、観光分野を対象として、地域内の観光オブジェクト認識モデルを Federated Learning と DTN を用いて地域間で共有する手法について検討する。DTN (遅延耐性ネットワーク) とは、長時間に渡る遅延や過酷な通信環境でもノード間の情報通信を可能とする技術である。DTN を用いてデバイス間で通信を可能とすれば、インターネットへの通信環境に依存しないモデルの共有が可能になると考える。更に、上記の問題について DTN によるデバイス間の通信を行う事で、外部サーバへの通信コストを削減できると考える。本稿では、その共有手法を実現するための問題設定を述べ、観光エリア間を移動するデバイスユーザのモデル共有シナリオに対して 3 つのヒューリスティック手法を導入し、有効性を評価する。

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

<sup>‡</sup> 理化学研究所 革新知能統合研究センター (AIP), RIKEN, Center for Advanced Intelligence Project (AIP)

## 2. 関連研究

本研究が対象とする Federated Learning の概念は、データセンタ以外の場所に分散しているデータを漏洩のリスクを最小限に抑えた上で機械学習モデルの訓練に用いるために Google により提案された。YANG[3] らは Federated Learning の先行研究について調査しており、その概念、分類、定義、応用事例を述べている。YANG[3] によると、Federated Learning は Horizontal Federated Learning, Vertical Federated Learning 及び Federated Transfer Learning の 3 種類に分類される。これらの手法は訓練対象のデータとその内部に存在する特徴量の取りうる範囲の違いによって分類されるが、いずれも外部サーバが存在するという共通点を持ち、全体の処理に重要な役割を担っている。

デバイスの状態に配慮した手法が Nishio[4] らによって提案されている。この手法では、通信状態や性能が良いデバイスを Federated Learning に参加するデバイスとして採用しており、効率的なモデルの訓練を行っている。状態の良いデバイスの選択方法として、モデル集約サーバから任意のデバイスへリソース状態のリクエストを送信しており、その情報からモデルを配布するデバイスの選択をしている。これらのデバイスを用いてモデルの学習を行うことにより、従来手法 [2] と比較して短時間でのモデルの性能向上を実現している。しかし、Federated Learning に参加するデバイスをリソース情報を基準に選択しているため、訓練に有用なデータを保持しているデバイスが選択されない可能性がある。そのため、有用なデータによるモデルの訓練が十分に行われない。

Feng[5] らの研究では、Federated Learning を用いて人間の移動予測モデルを構築しており、デバイス-サーバ間のモデルの送受信におけるプライバシー保護の手法について述べている。この手法では、移動予測モデルの中で通信時にプライバシー保護に関して問題のある部分と、プライバシーの問題がない部分をそれぞれ個別に訓練する。プライバシーに問題がある部分はノイズ付きのデータで訓練を行い、プライバシーの問題がない部分はノーマルなデータで訓練を行う。個人情報漏洩の可能性がある部分のセキュリティを強化する事で、Federated Learning を実世界で実行する上でのプライバシー漏洩のリスクを低減している。この研究では時系列モデルに対してのみ有効であるので、本研究で対象とするオブジェクト認識モデル等他の種類のモデルには対応できない。

Caldas[6] らは、モデルの集約の際に生じる通信コストと、エッジデバイスでの計算コストを削減する手法を提案している。通信コストの削減では、モデルのパラメータに対して量子化をすることで、サーバとエッジデバイス間の通信データの量を削減している。また、サーバから

モデルを送信する際、パラメータの一部を省き、小さいサイズのモデルをエッジデバイス上で訓練する Federated Dropout という手法が提案されている。省略されたパラメータは集約時に復元される。Federated Dropout により訓練時の計算コストが削減される。これらのコスト削減手法によって、エッジデバイスからサーバへの通信コストを 1/14、逆方向の通信コストを 1/28、エッジデバイスの計算コストを 1/1.7 にそれぞれ削減できたという結果が得られている。この論文では、Federated Learning における通信コストと計算コストの削減を目的としており、本研究の目的とは異なる。

上記の関連研究では、Federated Learning に関する概念や手法について研究されているが、いずれも広範囲に分布したデバイスのモデルを集約するサーバが設けられており、アクセスするためにインターネットを経由する必要がある。本研究で提案する手法においては、DTN によってデバイス間のモデル共有を行うことで、インターネット環境に依存しないエッジデバイス間での Federated Learning の手法について検討する。

## 3. 問題設定

本章では、地域間での観光オブジェクト認識モデルの共有手法における要素、制約条件、目的関数を定式化する。

### 3.1 想定環境の要素

本研究では、Federated Learning による観光オブジェクトの認識モデルの学習を DTN を用いたデバイス間通信で行う手法の実現を目指している。本節では、その手法を検討する上で必要となる想定環境について述べる。

表 1 に想定環境に現れる要素とその説明を示す。想定環境として、観光エリアの集合を  $A$  とする。それぞれの観光エリア  $a \in A$  には認識したい観光オブジェクトの集合  $O_a$  が存在している。 $O_a$  には移動するオブジェクト（動物、群衆、屋台など）と固定されたオブジェクト（建物、灯籠、樹木など）が含まれる。 $A$  のエリアには複数の観光客が滞在及び移動をしており、各観光客はスマートフォン等のモバイルデバイスを所持して活動する。モバイルデバイスの集合をデバイス  $C_{mobile}$  とする（各観光客は 1 台のモバイルデバイスを持つとする）。観光客が持つデバイスの他にもサイネージ等の位置が変化しないデバイスの集合  $C_{stationary}$  がある。以上より、想定環境内のデバイスの集合  $C$  を式 (1) で表す。

$$C = C_{stationary} \cup C_{mobile} \quad (1)$$

タイムスロット（時刻）の集合を  $T$  とする。 $c \in C_{mobile}$  は、時刻によって位置が変化する。そのため、 $c$  の時刻  $t \in T$  における位置を  $pos(c, t)$  と表記する。時刻  $t$  にデ

デバイス  $c$  と他のデバイス  $c'$  が互いに通信可能な範囲  $R$  にいる場合、それらのデバイスが互いにコンタクトしているとみなす。各コンタクト  $ct_t(c, c')$  を式 (2) に定義する。全てのデバイスの全ての時刻におけるコンタクトの集合  $CN$  を式 (3) として定義する。

$$ct_t(c, c') = \{(c, c', t) | c, c' \in C, |pos(c, t) - pos(c', t)| \leq R\} \quad (2)$$

$$CT = \{ct_t(c, c') | c, c' \in C, t \in T\} \quad (3)$$

各移動デバイス  $c \in C_{mobile}$  が収集・所持しているデータを  $D_c$  と表記する。固定デバイスはデータを収集しない。そのため、 $c \in C_{mobile}$  においては  $D_c \neq \phi$ 、 $c \in C_{stationary}$  においては  $D_c = \phi$  としている。以上より、想定環境内の全データ  $D$  を式 (4) として定義する。

$$D = \bigcup_{c \in C_{mobile}} D_c \quad (4)$$

各デバイス  $c \in C$  はオブジェクト認識モデル  $M_c$  を保有しており、モデル  $M_c$  のパラメータ  $W_c$  を Federated Learning に基づいた手法で他のデバイスと共有する。ここで、各デバイス  $c$  が持つモデル  $M_c$  には認識能力を強化したいエリアが設定されており、それを  $A_c \subseteq A$  として表記する。 $A_c$  内のオブジェクトの集合  $O_c$  を式 (5) で定義する。モデル  $M_c$  はオブジェクト集合  $O_c$  の認識能力を強化するものとする。

$$O_c = \bigcup_{a \in A_c} O_a \quad (5)$$

### 3.2 想定環境内の制約条件と目的関数

前節で述べた想定環境において、時刻  $t$  で任意のデバイスに対して1対1のコンタクトが生じた場合、互いが持つモデルの共有が可能であるとする。1対多でコンタクトした場合も、その中の1つのデバイスのみとモデルと共有をすることが可能であるとする。この制約を二値変数  $x_{cn_t(c, c')}$  を用いて式 (6) として定義する。式 (6) において、 $x_{cn_t(c, c')}$  はモデル共有の判断に用いる変数であり、デバイス  $c$  と任意のデバイス  $c'$  との間でモデル共有を行う場合は  $x_{cn_t(c, c')} = 1$ 、共有しない場合は  $x_{cn_t(c, c')} = 0$  となる。

$$\sum_{cn_t(c, c') \in CN, c \neq c'} x_{cn_t(c, c')} \leq 1, \forall c \in C, \forall t \in T \quad (6)$$

モデルの共有時は、共有後のモデルが共有前のモデルと比較して性能が向上している場合と低下する場合がある。また、共有を行うデバイス間で  $O_c$  もしくは  $A_c$  が異なる場合がある。そのため、モデルのパラメータの損失  $L$  と、式 (7) に示す Jaccard 係数に基づく  $O_c$  及び  $A_c$  の

表 1: 想定環境に登場する記号一覧

要素	定義
$A$	観光エリアの集合
$A_c$	認識能力を強化したいエリア
$O_a$	認識オブジェクトの集合
$O_c$	認識強化オブジェクトの集合
$C_{stationary}$	固定デバイスの集合
$C_{mobile}$	移動デバイスの集合
$C$	全デバイスの集合
$R$	デバイスが通信可能な範囲
$D_c$	デバイス $c$ が持つデータの集合
$D$	全データ
$M_c$	デバイス $c$ が持つモデル
$W_c$	モデル $M_c$ のパラメータ
$T$	想定環境内の時間 $t$ の集合
$pos(c, t)$	デバイス $c$ の時刻 $t$ の位置
$cn_t(c, c')$	時刻 $t$ でのデバイス $c, c'$ のコンタクト
$CN$	全デバイスのコンタクト

類似度  $dup(A_c, A_{c'}, O_c, O_{c'})$  を用いて共有後のデバイス  $c$  の利得  $G(c, cn_t(c, c'))$  を式 (8) として定義する。式 (7) において  $\beta \in [0, 1]$  はシステムパラメータであり、エリア、オブジェクトのどちらを重視するかに応じて予め与えられるものとする。

$$dup(A_c, A_{c'}, O_c, O_{c'}) = \beta \frac{|A_c \cap A_{c'}|}{|A_c \cup A_{c'}|} + (1 - \beta) \frac{|O_c \cap O_{c'}|}{|O_c \cup O_{c'}|} \quad (7)$$

$$G(c, cn_t(c, c')) = (1 - (L(W_c) - L(W_c \oplus W_{c'}))) \cdot dup(A_c, A_{c'}, O_c, O_{c'}) \quad (8)$$

モデル共有時において、互いのデバイスはモデルの送受信及びパラメータの統合で電力を消費する。送受信にかかる電力コストを  $SC$ 、モデルパラメータの更新処理にかかる電力コストを  $PC$  と表記する。

電力コスト  $SC + PC$  を考慮しながら、利得  $G(c, cn_t(c, c'))$  を最大化することを目的とするため、全体的な利得関数  $U$  を式 (9) として定義する。ここで  $\alpha \in [0, 1]$  はシステムパラメータであり、電力コストをどれだけ重要視するかに応じて予め与えられるものとする。

$$U = \alpha x_{cn_t(c, c')} G(c, cn_t(c, c')) + (1 - \alpha) x_{cn_t(c, c')} (SC + PC) \quad (9)$$

本問題では、式 (6) の制約条件下で、 $U$  を最大化することであるため、目的関数を式 (10) として定義する。

$$\text{Maximize } \sum_{cn_t(c, c') \in CN} U \text{ subject to (6)} \quad (10)$$

#### 4. ユースケースによるアルゴリズムの検討

前章で定義した問題は、全てのデバイスの時刻毎の位置が事前にわかっている場合においても、組み合わせ最適化問題となり、コンタクト数が多い場合には、実用的な時間で最適解を求めることは難しいと考えられる。さらに、現実にはコンタクトの正確な予測は難しいという問題がある。そこで、本章では、幾つかのヒューリスティック手法を導入し、ユースケースを通じてそれらの有効性を確認していく。

##### 4.1 ユースケースのシナリオ

ユースケースについて述べるために、モデル共有が行われるシナリオを設定する。シナリオにおける想定環境を図1に示す。図1におけるシナリオでは奈良県を対象とし、その中で奈良公園、東大寺、春日大社を対象観光エリアとする。これらの観光エリアのオブジェクトの集合を  $O_{奈良公園}, O_{東大寺}, O_{春日大社}$  と表記し、以下に示すオブジェクトを含んでいるとする。これらのオブジェクトは一部が観光エリア間で重複している。

$$O_{奈良公園} = \{ 牡鹿, 牝鹿, 小鹿, 鹿煎餅の売店, \dots \}$$

$$O_{東大寺} = \{ 仏像, 池, 鯉, 桜, 牡鹿, 牝鹿, \dots \}$$

$$O_{春日大社} = \{ 藤, 鳥居, 池, 鯉, 社, \dots \}$$

観光エリア内では、デバイスのユーザ（が所持するデバイス） $c_1, c_2, c_3, c_4, c_5, c_6, c_7, c_8, c_9$  がモデル共有を行う。各ユーザのモデルはそれぞれが所持しているデータについて訓練済みであるとする。ユーザのペルソナを表2に示す。ユーザ  $c_3, c_8$  は、観光エリア付近に住んでいる ( $c_3$ ) もしくは勤務しており ( $c_8$ )、最初から観光エリア内に滞在しているとする。図1に示すように、各ユーザが所有しているデータの種類と数は不均一であるとする。また、それぞれの観光エリアには土産店や敷地内入り口にサイネージが1つ設置されており、これらを  $C_{奈良公園}, C_{東大寺}, C_{春日大社}$  とする。これらのサイネージは表3に示すオブジェクトを認識対象としており、データは保持していない。本シナリオでは、ユーザ  $c_1$  の行動に着目し、モデルの共有方法について検討する。ユーザは最初図2aのように分布しており、それぞれ移動していくものとする。 $c_1$  は図2a左端の近鉄奈良駅付近から図2a右下の春日大社まで移動し、その途中で奈良公園、東大寺、春日大社の順に訪問する。その移動の途中で図2bに示すように  $c_3, c_4, C_{奈良公園}, c_7, c_2, C_{東大寺}, c_5, c_6, c_9, c_8, C_{春日大社}$  の順にコンタクトし、互いのモデル共有が可能な状態になると想定する。

##### 4.2 共有手法の評価

以下に述べる各共有手法による利得  $G(c, cnt_t(c, c'))$  の計算において、損失の項  $1 - (L(W_c) - L(W_c + W_{c'}))$  は、

認識対象のオブジェクトが類似する程損失の差が小さくなるとして扱い、この損失の項を  $\frac{|O_c \cap O_{c'}|}{|O_c \cup O_{c'}|}$  に代用して計算する。このユースケースでは、 $O_c$  は  $c_1$  が認識対象としたいオブジェクトの集合 (牡鹿, 牝鹿, 寺, 社, 桜, 池, 鳥居) とし、 $O_{c'}$  はコンタクトするユーザが認識対象とするオブジェクトの集合としている。式(7)の計算で必要となる  $A_c$  は  $c_1$  が観光するエリアの集合 (奈良公園, 東大寺, 春日大社) であり、 $A_{c'}$  は  $c_1$  とコンタクトするユーザが観光するエリアとして計算する。本ユースケースでは、経験的に、式(7)において  $\beta = 0.5$ 、式(9)において  $\alpha = 0.5$  に固定し、共有時の通信コスト  $SC$  及びモデルのパラメータの更新処理コスト  $PC$  をそれぞれ 0.1 とする。以上に基づき各共有手法における目的関数値を得て共有手法を評価する。

共有手法としては以下の3種類について考え、目的関数の出力値をそれぞれ得る。また、各手法において、電力コストを考慮し、モデルを共有可能なデバイス数は5までとしている。

1. ランダムに選択されたデバイスと共有
2. 先にコンタクトしたデバイスと共有
3. 認識対象オブジェクトのエリアのデータを一定数以上所有するデバイスと共有

1つ目の共有手法の場合、 $c_1$  はコンタクトしたデバイスに対してランダムに二値変数  $x_{cnt_t(c, c')}$  を決定する。その中で  $c_4, c_7, c_5, C_{東大寺}, c_8$  と共有した場合について検討する。この手法の場合、式(9)より各ユーザとのコンタクトの際に得られる利得関数値をそれぞれ  $U_{c_4}, U_{c_7}, U_{c_5}, U_{C_{東大寺}}, U_{c_8}$  とすると、それぞれ  $U_{c_4} = 0.193, U_{c_7} = 0.400, U_{c_5} = -0.0427, U_{C_{東大寺}} = -0.0830, U_{c_8} = -0.0877$  となる。よって、式(10)より  $c_1$  の目的関数値はこれらの総和であるため約 0.380 となる。

2つ目の共有手法の場合、先にコンタクトする5つのデバイス  $c_3, c_4, C_{奈良公園}, c_7, c_2$  と共有し、それ以降は共有をしないものとする。上記と同様に計算を行うと、各コンタクトでは  $U_{c_3} = -0.877, U_{c_4} = 0.193, U_{C_{奈良公園}} = -0.0635, U_{c_7} = 0.400, U_{c_2} = -0.0966$  の利得関数値を得る。そのため、この手法における目的関数値は約 0.444 となる。

3つ目の共有手法では、 $c_1$  が認識したいオブジェクトのデータを、一定数以上所持しているデバイスとモデルを共有する。この手法では、モデルの共有前に、デバイスが所有している画像データについての情報を DTN で共有する。この情報は、モデルのパラメータと比較して小さいデータサイズであるとして、通信コストはほとん

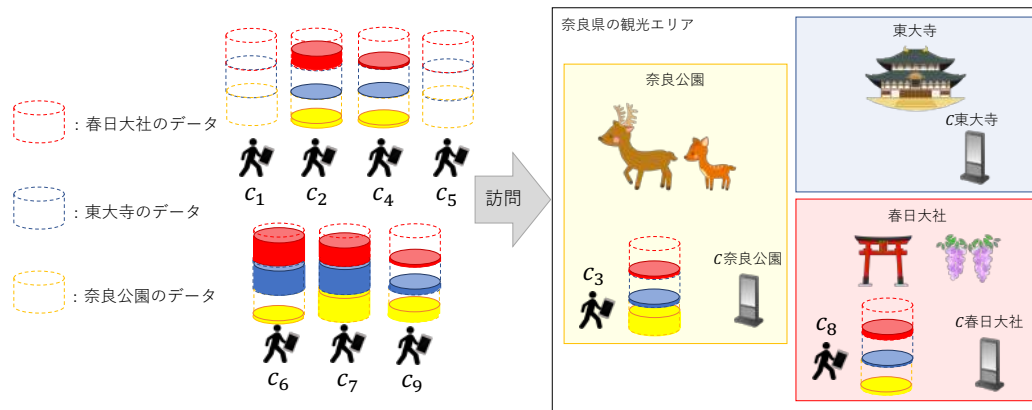


図 1: シナリオの概略図

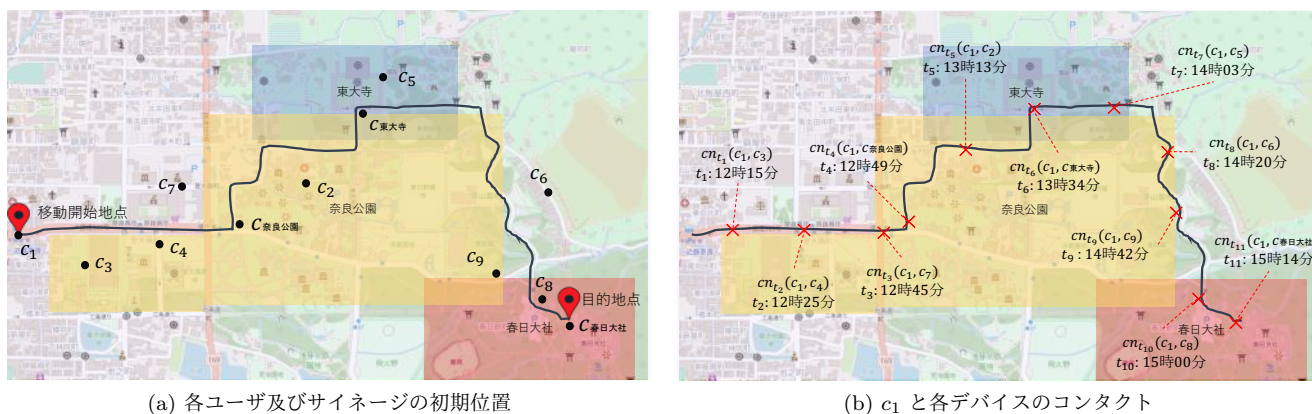


図 2: 各デバイスの位置とコンタクト

ど無いとする。共有する情報としては、簡単のために、デバイス内の各観光エリアに対する画像データ数を扱う。このユースケースにおいて、 $c_1$  が認識対象としているオブジェクトは各観光エリアに含まれている。そのため、各観光エリアのデータを閾値以上の枚数で所有しているユーザとモデル共有を行うものとする。この場合、10 枚以上所有しているデバイスと共有を行う場合を考える。 $A_{c_1} = \{ \text{奈良公園, 東大寺, 春日大社} \}$ なので、この手法の場合、該当するユーザは  $c_6, c_7, c_9$  である。これらのデバイスとモデル共有を実行すると、各コンタクトで  $U_{c_6} = -0.0320, U_{c_7} = 0.400, U_{c_9} = 0.116$  の利得関数値を得て、目的関数値は約 0.484 となる。

上記の 3 種類の共有手法で目的関数値を導出した結果、認識対象オブジェクトのデータを一定閾値以上所有するデバイスと共有する手法による目的関数値が最大となった。他の 2 つの手法と比較すると、デバイス内の情報を共有するコストが追加されるが、この情報の使用により共有することが望ましいモデルが適切に判断されたと考えられる。

## 5. おわりに

本稿では、Federated Learning を用いた観光エリアのオブジェクト認識モデルを地域間で共有する手法に関する問題設定について述べ、3 種類のモデル共有手法における効果をユースケースで確認した。問題設定では、想定環境内でコンタクトするデバイスに対して、通信および計算にかかる電力コストを抑えながらモデル共有後の利得を最大化する目的関数を定義した。この目的関数を最大化するにあたり、デバイスが 1 度に共有できるモデルは 1 つに制限している。ユースケースでは、これらの目的関数と制約条件に基づいて 3 種類の手法を用いて評価を行った。その結果として、認識対象のオブジェクトに関する所持データ数をもとにモデルを共有するかどうかを判断する手法が最良だった。この結果より、デバイス間で Federated Learning を実行する際は、モデルのパラメータ以外の情報も共有することで、効率的なモデル共有が可能となると考えられる。また、本稿では、移動オブジェクトと固定オブジェクトを認識対象として扱っており、将来的にそれらのオブジェクト認識に基づき、画像や動画から自動でキャプションを生成するモデルの

表 2: ユーザのペルソナ

ユーザ	認識対象	観光するエリア	データ数 (奈良公園, 東大寺, 春日大社)
$c_1$ (外国人観光客)	牡鹿, 牝鹿, 寺, 社, 桜, 池, 鳥居	奈良公園, 東大寺, 春日 大社	(0,0,0)
$c_2$ (日本人観光客)	仏像, 池, 桜	東大寺	(26,5,30)
$c_3$ (奈良公園付近の住民)	小鹿, 桜, 鹿煎餅の売店	奈良公園	(65,10,9)
$c_4$ (京都府の住民)	桜, 藤, 社, 池	奈良公園, 春日大社	(14,4,16)
$c_5$ (建築学専攻の外国人学生)	寺, 社, 仏像	東大寺, 春日大社	(0,0,0)
$c_6$ (建物好きな外国人観光客)	寺, 社	東大寺, 春日大社	(10,98,91)
$c_7$ (タクシー運転手)	奈良県内のオブジェクト 全般	奈良公園, 東大寺, 春日 大社	(100,103,85)
$c_8$ (春日大社で働く人)	藤, 池, 鯉	春日大社	(12,6,20)
$c_9$ (日本人観光客)	小鹿, 寺, 社, 桜, 池, 鳥 居, 鹿煎餅の売店	奈良公園, 東大寺, 春日 大社	(46,23,19)

表 3: サイネージの認識オブジェクト

サイネージ	認識対象
$c_{\text{奈良公園}}$	牡鹿, 牝鹿, 小鹿
$c_{\text{東大寺}}$	寺
$c_{\text{春日大社}}$	藤, 鳥居, 社

実現に繋がると考えている。今後の研究では、実際に訓練するデータを用いてデバイス間でオブジェクト認識モデルを共有するシステムを構築し、シミュレーションを通してより有効な共有手法を検討する予定である。

## 謝辞

本研究成果の一部は国立研究開発法人情報通信研究機構 (NICT) の委託研究「スマートコミュニティを支える高信頼ネットワーク構成技術の研究開発」により得られたものです。

## 参考文献

- [1] 国土交通省. ICT を活用した訪人外国人観光動態調査に関する手引き. available from <https://www.mlit.go.jp/common/001179200.pdf>. accessed 2020-07-20.
- [2] H. Brendan McMahan, Eider Moore, Daniel Ramage, Seth Hampson, and Blaise Agüera y Arcas. Communication-efficient learning of deep networks from decentralized data. *Proceedings of the 20 th*

*International Conference on Artificial Intelligence and Statistics (AISTATS)*, Vol. 54, , 2017.

- [3] Qiang Yang, Yang Liu, Tianjian Chen, and Yongxin Tong. Federated machine learning: Concept and applications. *ACM Transactions on Intelligent Systems and Technology*, Vol. 10, No. 2, pp. 1–19, 2019.
- [4] Takayuki Nishio and Ryo Yonetani. Client selection for federated learning with heterogeneous resources in mobile edge. *Proc. IEEE ICC 2019*, 2019.
- [5] Jie Feng, Can Rong, Funing Sun, Diansheng Guo, and Yong Li. PMF : A privacy-preserving human mobility prediction framework via federated learning. *Proc. ACM Interact. Mob. Wearable Ubiquitous Technol.*, Vol. 4, No. 1, pp. 1–21, 2020.
- [6] Sebastian Caldas, Jakub Konečný, H. Brendan McMahan, and Ameet Talwalkar. Expanding the reach of federated learning by reducing client resource requirements. *arXiv preprint arXiv:1812.07210*, 2018.