

# ローカル環境での効果的な動画解析を実現する 分散処理システムの提案

中村 優吾<sup>1,a)</sup> Tony Shi<sup>2</sup> 諏訪 博彦<sup>1</sup> 荒川 豊<sup>1</sup> 山口 弘純<sup>3</sup> 安本 慶一<sup>1,b)</sup>

概要：実世界に設置された多種多様なネットワークカメラから収集された膨大な動画を即時的に処理・認識し、コンテキストウェアな IoT サービスに活用することが期待されている。しかしながら、従来のクラウド依存な動画解析アーキテクチャでは、データ量の増加による計算量の爆発に対応することが困難であり、処理遅延の増大やシステム運用コストの高騰を招いてしまう。そこで本研究では、来る IoT 時代に向けて、動画の発生源に近くに設置された複数の IoT デバイスを用いて目的の動画を効率的に解析する自律分散型動画収集システムを提案する。提案システムには、効率的な動画解析に向けた 2 つの機能として (a) 対象オブジェクトの分類器を対象エリアに存在するノードに分配し、目的の画像を検出する機構、(b) 近隣の IoT デバイス間で段階的に画像を流通・加工する機構を設計する。本稿では、屋内施設における個人認証アプリケーションを題材として、提案システムのプロトタイプを Raspberry Pi や Intel Nuc 等の小型デバイス上に実装し、実機による動作検証実験を行った。実験では、クラウド側に送信するデータ量を効率的に削減することを目的として、2 つのデータ削減手法について評価を行った。手法 1 は、人感センサにより人を検出したシーンの動画だけを抽出すると共に、抽出シーンのフレームレートを間引いて送信する方式、手法 2 は、生成される動画ストリームに対して、逐次、IFoT によるローカル側での解析処理を行い、顔が検出されたシーンのみを抽出し、顔画像部分のみを送信する方式である。実験の結果、IFoT により効果的な画像データの加工処理を施すことで、手法 1 に比べてクラウド側に伝送するデータ量を 94 %削減すると共に、通行者の顔画像を 90 %以上の精度で検出できることを確認した。

## 1. はじめに

Internet of Things (IoT) の急速な発展により、実世界に存在するあらゆるデバイスがインターネットに接続されるようになった。それに伴い、実世界で発生する多様な事象を把握、記録することを目的として様々な施設にネットワークカメラが設置されている。今後は、そこから収集された膨大な動画を蓄積・監視するだけでなく、機械学習技術により分析・認識することで、瞬時に人や街の状況を把握することが可能になる。また、それらの情報を用いてコンテキストウェアな IoT サービスを実現することが期待されている。

現状、撮影された動画データから価値ある情報を自動で抽出するためには、ルールベースの機械学習や Deep Learning を用いたオブジェクト認識など計算負荷が高く、

膨大なデータ数を必要とする画像解析処理を施すのが主流となりつつある。そのため、これらの動画は、遠隔の大規模データセンター(クラウド)に伝送・蓄積し、クラウド側の強力な計算資源を用いて処理することが推奨されている。しかし、現状のクラウド依存な動画解析アーキテクチャでは、逐次アップロードされるデータ量が増加する毎に、通信帯域の逼迫やシステム運用コストの高騰を招いてしまう。実際のところ、クラウド側に、伝送・蓄積されているデータには、その後、活用されることのない不要データが多く含まれているという調査結果も報告されている [1]。そのため、来る IoT 時代に向けて、クラウド一極集中型のデータ処理アーキテクチャを見直し、効率的にデータを収集・処理する新たな仕組みを検討する必要がある。

これらの背景を踏まえて、我々の研究グループでは、データの発生源に近い IoT デバイスの計算資源を活用して、逐次生成される雑多な IoT データストリームを分散処理する次世代型 IoT ストリーム処理基盤：IFoT (Information Flow of Things) の研究開発を進めている [2][3]。IFoT のイメージを図 1 に示す。IFoT では、ローカル側に存在する IoT デバイスを計算資源とみなし、データの取捨選択やク

<sup>1</sup> 奈良先端科学技術大学院大学  
Nara Institute of Science and Technology

<sup>2</sup> Unitec Institute of Technology

<sup>3</sup> 大阪大学  
Osaka University

a) nakamura.yugo.ns0@is.naist.jp

b) yasumoto@is.naist.jp

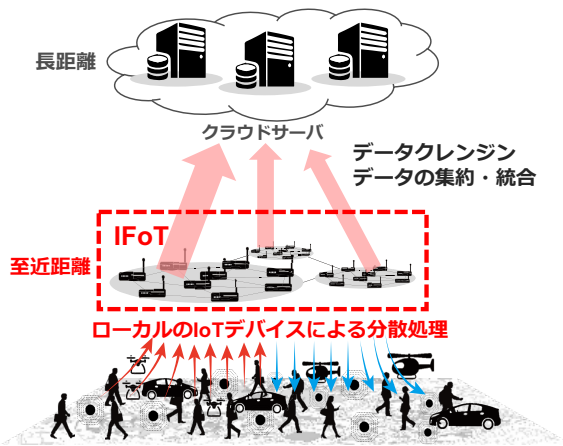


図 1 IFoT (Information Flow of Things) のイメージ

レンジングといった処理タスクを分担することによって、システム全体の処理を効率化する。これにより、クラウド側で全ての処理を行う従来のアーキテクチャと比べて、(1) ローカル-クラウド間のデータ通信負荷、(2) クラウド側の処理負荷、(3) システム運用コストという3項目の削減を目指す。

本稿では、IFoT の概念に基づき、文献 [3] で提案する IFoT ミドルウェアをベースとして、目的の動画像を効率的に集約する自律分散型動画像収集システムを提案する。提案システムでは、2つの課題、(a) 応用目的に応じた対象画像の抽出、(b) 資源効率の良い画像集約を解決することを目標としている。(a) の解決に向けて、対象オブジェクトの分類器を対象エリアに存在するノードに分配し、目的の画像を検出する機構、(b) の解決に向けて、近隣の IoT デバイス間で段階的に画像を流通・加工する機構を設計する。これにより、生の画像データから不要なデータを切り捨て、アプリケーションの目的に応じた、必要最小限の情報のみを集約する。

屋内施設における個人認証アプリケーションを題材として、提案システムのプロトタイプを Raspberry Pi や Intel Nuc 等の小型デバイス上に実装し、実機による動作検証実験を行った。その結果、ローカル側での効果的な画像データの加工処理を施すことで、クラウド側に伝送するデータ量を 94% 削減し、通行者の顔画像を 90% 以上の精度で検出することを確認した。

以降 2 章では関連研究について述べ、3 章では、提案システムに求められる要件、4 章に提案システムの詳細を述べる。5 章では、評価実験について述べ、6 章でまとめとする。

## 2. 関連研究

### 2.1 屋内施設向け監視カメラシステム

防犯や監視を目的として、店舗やビル、マンション、大型商業施設に多くの監視カメラシステムが設置されてい

る [4]。これらのシステムの多くは、カメラ、映像監視ソフト、サーバ、大規模ストレージといったモジュールが一つにパッケージ化され、ローカルに閉じたシステムとして提供されている。そのため、設置するためには専用の工事が必要であり、導入コストが大きいという課題が存在する。また、リアルタイムな動画像解析を実現するためには、専用の大規模サーバを設置する必要があり、設置コストの増大を招いている。

一方、近年では、IoT 対応のクラウド監視カメラシステムとして、ABEJA Platform[5] や Safie[6]、アロパビュー [7] が注目を集めている。ABEJA では、店舗に設置されたカメラの映像から、来店者数や店内の滞在動態、顧客属性といった情報を明らかにし、業務改善に向けたマーケティング施策を提案するといったサービスを実現している。また、ディープラーニングを応用した高度な映像解析処理は、全てクラウド側で実行されており、インターネット回線があれば初期コストゼロでシステムを導入することが可能である。Safie やアロパビューは、クラウド側でのデータ集中管理により、スマホやタブレットを用いてどこからでも監視や見守りができる仕組みを実現している。これらのシステムは、データの蓄積や解析処理をクラウド側に集約することで、従来の課題であったシステム設置コストの削減を図り、監視システムを導入できなかった一般家庭や小規模店舗などへの普及を実現している。

このように、屋内監視カメラに関しては、オープン化、クラウド集約化の流れが起こりつつある。しかし、IoT の概念のもと、日本に数百万台以上設置されている監視カメラの全てをインターネットに接続し、クラウド上での高度な解析処理を実現する場合、既存の通信・計算資源では対応しきれず、大きな遅延が発生する可能性がある。そのため、ローカル側での効果的な加工処理により、通信・計算・記憶資源の浪費を減らしつつ、クラウドコンピューティングを活用するためのアーキテクチャが求められる。

### 2.2 スマートシティの実現に向けた監視カメラの利活用

街に設置されたカメラを用いたアプリケーションに関して、Cisco は、地面に設置された圧力センサと監視カメラを用いて自動車の認識率を高め、駐車場の収益増加と管理費の削減を目指すスマートパーキングシステム、バス停に設置したカメラや音声センサ、WiFi ホットスポットを用いて待っている乗客数のカウントやバス停周辺の治安監視を行うスマートバス停システムを提案している [8][9]。これらのシステムは、Cisco が提唱する Fog Computing[10] の概念のもと、センサやカメラにより得られたデータを近隣のフォグサーバや遠隔のクラウドサーバに集約し、解析処理を行うシステムアーキテクチャを採用している。

また、General Electric (GE) は、街灯に設置された環境センサとカメラを用いて、天候や状況に合わせた明るさ

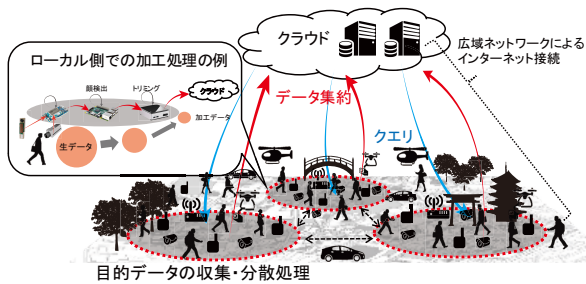


図 2 システムの想定環境

調整や路上駐車スペースの監視を行う、スマート街灯システムが提案している [12]。このシステムは、GE の IoT 向けクラウド Predix[13] をベースに構築されており、取得された動画の解析処理は、クラウド側で行なわれている。

また、IP カメラ向けの動画解析サービスとして placemeter[11] がある。placemeter では、歩道などに設置された IP カメラの映像をクラウド側の動画解析プラットフォームに送信することにより、歩行者数や自動車の交通量を算出している。料金体系はデータ量に応じた課金制になっており、クラウド側に伝送するデータ量に応じて、システムの運用コストが高む仕組みになっている。

このように、街に設置された複数の監視カメラから得られる動画データ解析するためには、フォグサーバやクラウドサーバといった設備が必要不可欠である。しかし、フォグやクラウド側で行っている解析処理タスクの一部をローカル側（データストリームの発生源の近く）で担うことが可能になれば、遅延時間の低減やコストの削減といった改善が見込める。我々の提案する IFoT では、既に設置されている IoT デバイスの計算資源を用いて、撮影された動画の効果的な加工処理を行い、フォグサーバやクラウドサーバの負担を減らすことにより、低コストな動画解析の実現を目指す。

### 3. システム要件

#### 3.1 想定する環境

本研究で想定する提案システムの動作環境を図 7 に示す。ローカル側には、カメラやセンサなど実環境の情報を収集する設置型センサノードおよびスマホやカメラを保持した人、車、ドローン（移動型センサノード）、収集した情報を流通、加工するプロセッシングノードが存在している。各ノードは広域ネットワークおよび端末間のアドホックネットワークと接続しており、相互に通信可能である。一方、クラウド側には、大量のデータを蓄積・処理するデータセンタが存在する。莫大な数の教師データと時間を必要とする機械学習（モデルの構築作業）等はクラウド側で行う。ローカル側では、クラウド側で構築された学習モデルを基に、対象物が写っている画像の収集や加工処理を行う。

#### 3.2 アプリケーションシナリオと要件

提案システムが想定するアプリケーション例を示し、その実現に向けて求められる機能を述べる。

##### (1) 施設の訪問者分析サービス

施設に複数配置された固定カメラによって訪れた来場者を逐次撮影する。そして、撮影された画像から来場者の年齢層や性別を認識する。これにより、エリア毎、時間帯毎に訪れる来場客の違いや来場者数の変動といった情報をリアルタイムに抽出し、可視化できるサービスを実現する。

このサービスを実現するには、対象エリアに存在する固定カメラから生成される動画ストリームをリアルタイムに解析し、来場客が写っている動画を抽出する機能が必要である。また、撮影された生の動画をそのままクラウド側に送信するのは、通信・計算・記憶資源の浪費につながるため、何らかの解析処理を施し、目的の情報だけを送信する機能が求められる。

##### (2) 混雑度や景観状況に応じた観光ナビゲーション

街に設置された固定ノードおよび、そこに存在する人や車が所有する移動ノードを用いて、観光スポットの混雑度や景観（桜の咲き具合）状況といった目的の情報をセンシングする。そして、得られた情報を素早く集約し、地図上に反映することにより、経路情報だけでなく、現在の混雑度や景観状況に応じた観光ナビゲーションを実現する。

このサービスを実現するには、対象エリアに存在するセンサノードに対して、目的データの収集を指示するクエリを伝達する機能が必要である。また、クエリを受けたノード群が自律分散的に協調しながら目的データを収集する機能が必要である。

##### (3) オフィスにいる従業員トラッキングサービス

オフィスに設置されているカメラにより従業員のトラッキングを行う。これにより、どの従業員がどこで仕事を行い、誰と打ち合わせを行ったのかといった情報を把握することが可能になる。また、誰が居るのかという情報をシステムが認識することにより、従業員の好みや体質に応じて、部屋の温度や明るさの自動調節するなど、気の利いたサービスを提供することが可能になる。加えて、施設の省電力化や快適度の向上、仕事の効率化などオフィスの業務改善に役立てることも可能になると考えられる。

このサービスを実現するには、誰が通ったのかという情報をデータの発生源に近い端末側で即時的に認識する機能が必要である。また、認識した情報を端末間でダイレクトに流通し、即時的に活用する仕組みが必要である。

## 4. 自律分散動画収集システム

本章では、目的の動画を効率的に収集することを目的として、IFoT ミドルウェアをベースとして設計した、自律分散型動画収集システムについて述べる。

### 4.1 IFoT ミドルウェアの概要

ここでは、IFoT ミドルウェアの概要を示す（詳細は文献 [3] を参照）。

#### 4.1.1 アーキテクチャ

IFoT システムの階層アーキテクチャを図 3 に示す。このように、IFoT システムは、アプリケーション層、IFoT ニューロン層、センサ/アクチュエータ層の 3 つに階層化される。提案する IFoT ミドルウェアは、複数に分散された IFoT ニューロンモジュール上で動作し、レシピの要求に応じて、相互に連携、協調しながら、同時並行的に生成されるセンサデータストリームを流通、処理する役割を担う。ここで、レシピとは、図 4 のように、入力データのストリームをどのように処理するかといった処理手順を示すタスクグラフが記述されたファイルを想定する。IFoT ミドルウェアの機能を以下に記す。

#### (1) タスクの分散実行

IFoT ミドルウェアでは、各アプリケーションレシピのタスクグラフを分割し、各ノードの処理能力に応じてタスクを割り当て、分散実行する。

#### (2) オンデマンドな情報流通

全ての生データをクラウドサーバに送信することは効率的ではないため、生成されるデータ流を需要に応じてデバイス間でダイレクトに流通する機能を提供する。

(3) オンラインな情報分析 IoT をデータストリームの即時的な利活用に向けて、各モジュール間で相互に流通するストリームデータを蓄積することなく流れのままに逐次処理・集約・分析する機能を提供する。

#### (4) 異種センサ/アクチュエータの統合

IFoT の想定環境では、異なるインターフェイスと通信規格を持っているセンサ/アクチュエータが存在するため、様々なデータストリームを Message Queue Telemetry Transport (MQTT) など統一的なプロトコル対応のパケットに変換し、処理する機能を提供する。

#### 4.1.2 アプリケーションの構築手順

IFoT ミドルウェアを用いたアプリケーション構築手順のイメージを図 5 に示す。

Step1: アプリケーション構築者は、アプリケーションのレシピを記述し、その設定ファイルを IFoT モジュールに送信する。

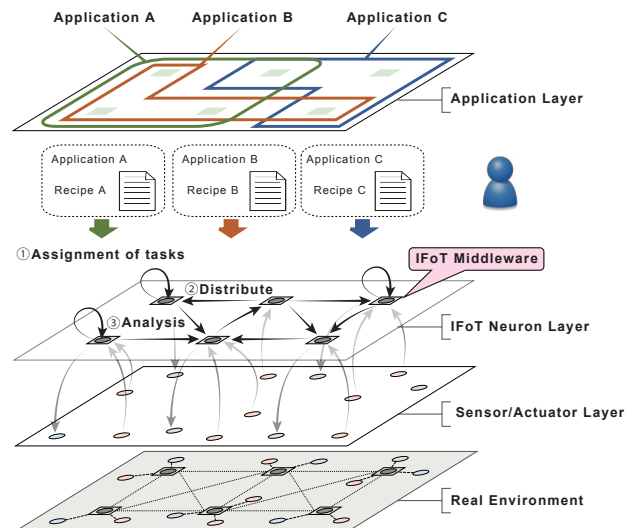


図 3 IFoT システムの階層構成

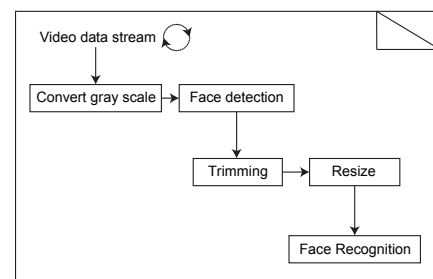


図 4 レシピのイメージ

Step2: レシピを受信した IFoT モジュールは、ファイルを読み込みレシピを分散可能なタスク単位に分割する。そして、センサの接続状況やリソース状況に応じて、各タスクを他の IFoT モジュールに割り当てる。

Step3: タスクを割り当てられた各 IFoT モジュールは、その内容に従ってクラスを起動し、相互に協調、連携しながらアプリケーションとしての動作を振る舞う。

### 4.2 自律分散型動画収集システムの概要

#### 4.2.1 モデルの分類

動画画像から対象物を検出するためには、あらかじめ検出したい物体の特徴を学習したモデル(分類器)を準備する必要がある。本システムでは、機械学習により生成されるモデルを、図 6 のような (a) 一般モデルと (b) 固有モデルの 2 つに分類する。

#### (1) 一般モデル

一般モデルとは、普通の一般的な名称の対象を検出するためのモデルと定義する。車や人、顔、犬の検出に用いるモデルが一般モデルである。一般モデルは、大量の学習データを WEB の検索エンジン等によって容易に収集することが可能であり、モデルの構築コストが低い。また、先人により既に構築されているモデ

ルを再利用できるため、あらかじめ準備できる可能性が高い。(例えば、顔や人を検出するためのモデルは、OpenCV に標準搭載されている。)

## (2) 固有モデル

固有モデルとは、個人など、それ以外には存在しない特定の対象を検出するためのモデルと定義する。対象が写っている動画を収集できる場所が限られており、大量の学習データを準備するのが容易ではなく、モデルの構築コストが高い。そのため、あらかじめモデルを準備するできる可能性が極めて低い。固有モデルは、プライバシーに関わるデータでもある為、あらかじめ作成してある場合でも、ローカルに留めて活用できることが望ましい。

対象物が一般モデルにより検出できる場合は、ローカルに存在するカメラデバイスにモデルを配布し、カメラ側で対象物のリアルタイム検出処理を行う。これにより、対象物が写っていないデータは破棄すると共に、目的のデータのみをクラウドに送信することによってデータ量や通信負荷を軽減することが可能にする。例えば、人物のカウントアプリケーションであれば、動画画像から歩行者が通過したシーンだけを抽出し、クラウド側に伝送する。

## 5. 評価実験

### 5.1 実験概要

機械学習や Deep learning を用いて動画画像データを解析するためには、膨大なデータを収集し、強力な計算機によ

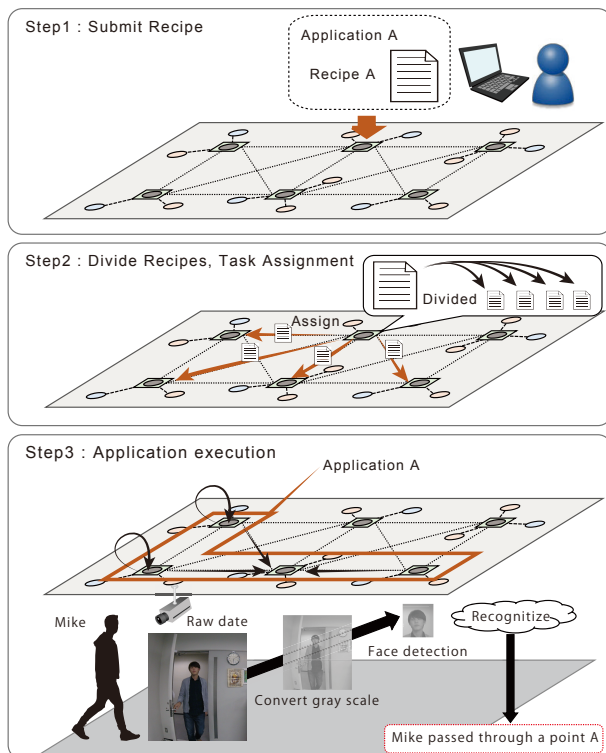


図 5 アプリケーションの構築手順

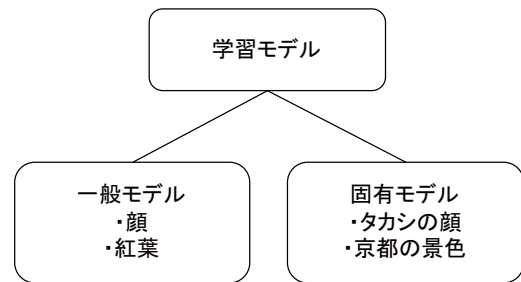


図 6 学習モデルの分類

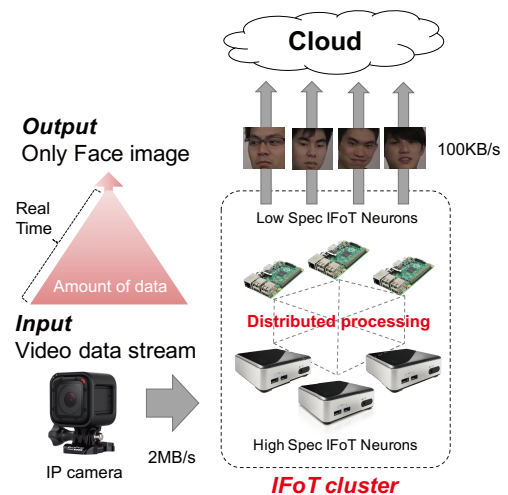


図 7 システムの構成

て処理する必要がある。そのため、単純な方法として、カメラから得られる動画画像データをすべてクラウド側に集約し、時間をかけて解析処理する手法がある。しかしながら、集められる全てのデータが学習に有効なデータとは限らない。例えば、屋内における個人認証トラッキングシステムであれば、得られた動画画像からその場を通過する人を検出し、個人を特定する必要がある。この場合、目的のデータは、人が写っているシーンの映像であり、人が写っていないシーンの映像は、必要がない。また、各ポイントにおいて、通過する人を検出するという目的であれば、すべてのフレームを送信する必要なく、データを間引いて送るのも有効である。つまり、ローカル側のデバイスで、人が写っているシーンだけを効率よく抽出することができれば、クラウド側へ送信するデータ量を削減することが可能になる。送信するデータ量の削減は、クラウド側のストレージ容量や解析に向けた計算量の削減にもつながるため、通信・計算・記憶資源の浪費防止になる。そこで本実験では、提案システムを評価するため、IFoT クラスタによる動画画像解析処理の有効性を評価するために、人物トラッキングシステムを例とした動作検証実験を行う。

### 5.2 実験条件

本実験では、クラウド側に送信するデータ量を効率的に削減することを目的として、2つのデータ削減手法を考

る．各手法のイメージを図 8 に示す．物体の検出に関しては，OpenCV3.0.0 の CascadeClassifier クラスを使用する．

(1) 手法 1

人感センサにより人を検出したシーンの動画像だけを抽出すると共に，抽出シーンのフレームレートを間引いて送信する．この手法は，人感センサの誤動作や抽出シーンのブレにより，収集する画像の質が低下する可能性がある．

(2) 手法 2

生成される動画像ストリームに対して，逐次，IFoT によるローカル側での解析処理を行い，顔が検出されたシーンのみを抽出し，顔画像部分のみを送信する．

表 2 各クラスの画像数

通行者	手法1 (人感センサ)				手法2 (IFoTによる処理)			
	総画像数	C1	C2	C3	総画像数	C1	C2	C3
A	5	4	0	1	34	2	11	21
B	7	2	1	4	28	1	2	25
C	7	3	2	2	40	2	3	35
D	7	4	1	2	43	1	6	36
E	7	3	2	2	27	4	0	23
F	7	3	3	1	48	3	12	33
G	8	5	2	1	49	1	8	40
H	7	5	1	1	44	6	11	27
I	7	4	3	0	22	2	0	20
J	8	5	3	0	22	2	9	11
K	7	2	2	3	77	2	12	63
合計	77	40	20	17	434	26	74	334

5.3 実験方法

図 9 に示す位置にカメラを設置し，被験者 11 名に入口 A を自由に通過してもらい，その様子を撮影する．動画のフレームサイズは 1920 × 1080，フレームレートは 30fps とした．そして，撮影された映像から手法 1 と手法 2 によって抽出された画像に関して，データ総量と顔検出の精度を評価する．顔検出の精度は，抽出された全ての画像に対して，目視により表 1 にある 3 つの基準に分類することで確認する．各クラスの画像例を図 10 に示す．

5.4 実験結果

収集した画像に対する目視での分類結果として，表 2 に被験者 (通行者) ごとの各クラスの画像個数，図 11 に各クラスに分類された画像の割合を示す．なお，表 2 における，「総画像数」は顔ありと認識されたフレームの総数である．また，クラウド側に送信されるデータとして，撮影された Raw データ，手法 1，手法 2 によって抽出されたデータの各総量を図 12 に示す．実験結果より，手法 1 については，顔が写っている画像の精度が 50 % を下回る結果となった．一方，手法 2 については，顔が写っている画像の精度が 90 % を上回る良い結果となった．また，図 12 より，手法 1 と手法 2 のデータサイズを比較すると，手法 2 の方が高い検出精度を保ちながらも，データ量を 94 % 削減できていることが確認出来る．

表 1 クラス一覧

クラス名	選択基準
C <sub>1</sub>	画像内に顔が写っていない
C <sub>2</sub>	画像内に顔が写っている (ブレあり)
C <sub>3</sub>	画像内に顔がはっきり写っている

6. おわりに

本稿では，IFoT の概念に基づき，文献 [3] で提案するモデルウェアをベースとして，目的の動画を効率的に集約する自律分散型動画収集システムを提案した．提案シス

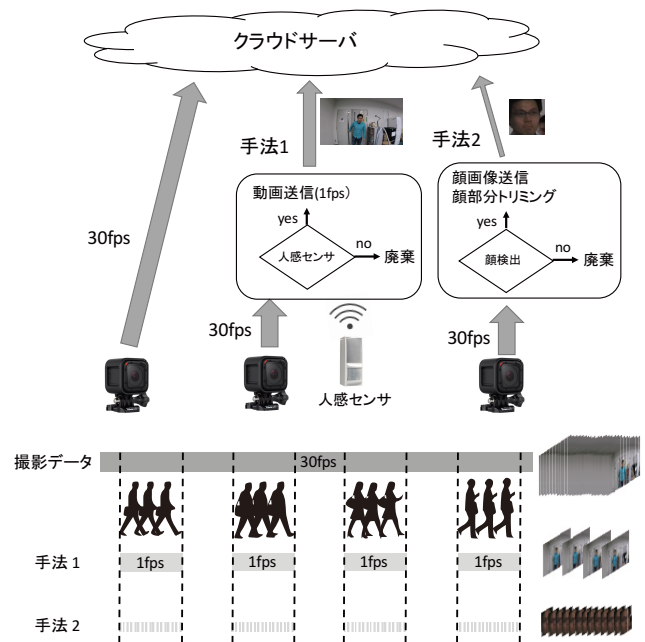


図 8 各手法のイメージ

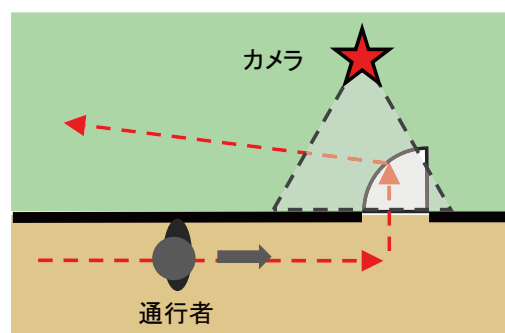


図 9 実験環境



図 10 各クラスの画像例

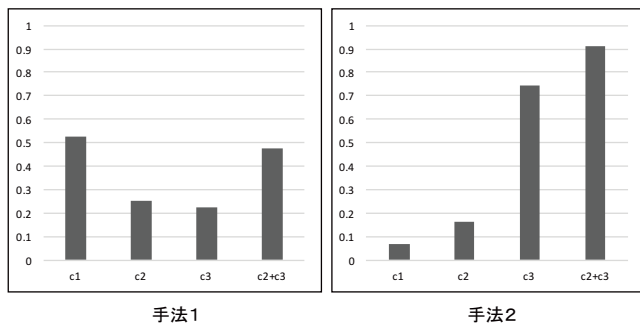


図 11 収集画像の評価 (各クラスへの分類)

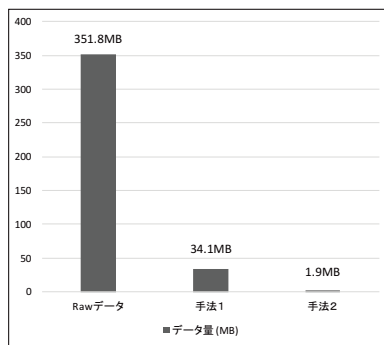


図 12 クラウド側に送信されるデータの総量 (MB)

テムでは、2つの課題、(a) 応用目的に応じた対象画像の抽出、(b) 資源効率の良い画像集約を解決することを目標としている。(a)の解決に向けて、対象オブジェクトの分類器を対象エリアに存在するノードに分配し、目的の画像を検出する機構 (b)の解決に向けて、近隣のIoTデバイス間で段階的に画像を流通・加工する機構を設計する。これにより、生の画像データから不要なデータを切り捨て、アプリケーションの目的に応じた、必要最小限の情報のみを集約する。

屋内施設における個人認証アプリケーションを題材として、提案システムのプロトタイプを Raspberry Pi や Intel Nuc 等の小型デバイス上に実装し、実機による動作検証実験を行った。実験では、クラウド側に送信するデータ量を効率的に削減することを目的として、2つのデータ削減手法について評価を行った。手法1は、人感センサにより人を検出したシーンの動画画像だけを抽出すると共に、抽出シーンのフレームレートを間引いて送信する方式、手法2は、生成される動画画像ストリームに対して、逐次、IFoTによるローカル側での解析処理を行い、顔が検出されたシーンのみを抽出し、顔画像部分のみを送信する方式である。実験の結果、IFoTにより効果的な画像データの加工処理を施すことで、手法1に比べてクラウド側に伝送するデータ量を94%削減すると共に、通行者の顔画像を90%以上の精度で検出できることを確認した。

## 参考文献

- [1] McKinsey Global Institute: Big data: The next frontier for innovation, competition, and productivity, <http://www.mckinsey.com/business-functions/business-technology/our-insights/big-data-the-next-frontier-for-innovation>, 2011.
- [2] K. Yasumoto, H. Yamaguchi, H. Shigeno: Survey of Real-time Processing Technologies of IoT Data Streams, *Journal of Information Processing*, Vol. 24, No. 2, pp.195-202, 2016.
- [3] Y. Nakamura, H. Suwa, Y. Arakawa, H. Yamaguchi, K. Yasumoto: Design and Implementation of Middleware for IoT Devices toward Real-Time Flow Processing, Proc. the 1st Workshop on Edge Computing (WEC 2016) (collocated with IEEE ICDCS 2016), 2016.
- [4] 橋本学: 安全・安心社会のための映像セキュリティ技術, システム/制御/情報, Vol.50, No.10, pp.388-393, 2006.
- [5] ABEJA Platform:  
入手先 < <https://service.abeja.asia/> >
- [6] Safie:  
入手先 < <https://safie.link/> >
- [7] Aroba:  
入手先 < <http://www.arobaview.com/> >
- [8] S Mitchell, N Villa, M Stewart-Weeks, A Lange: The Internet of Everything for Cities Connecting People, Process, Data, and Things To Improve the 'Livability' of Cities and Communities, [http://www.cisco.com/c/dam/en\\_us/about/ac79/docs/ps/motm/IoE-Smart-City\\_PoV.pdf](http://www.cisco.com/c/dam/en_us/about/ac79/docs/ps/motm/IoE-Smart-City_PoV.pdf), 2014.
- [9] Ruthbea Yesner Clarke: Smart cities and the internet of everything: The foundation for delivering next-generation citizen services, white paper sponsored by Cisco, 2013.
- [10] F. Bonomi, R. Milito, J. Zhu, S. Addepalli: Fog Computing and Its Role in the Internet of Things, Proc. of the First Edition of the MCC Workshop on Mobile Cloud Computing (MCC '12), pp. 13-16, 2012.
- [11] placemeter:  
入手先 < <https://www.placemeter.com/> >
- [12] GE Lighting:  
入手先 < <http://www.gelighting.com/LightingWeb/> >
- [13] predix:  
入手先 < <https://www.ge.com/digital/predix> >