

IoT デバイスの自動ネットワーク設定のための 通信パターン分析

丹羽 美乃¹ 梶 克彦²

概要：現在多くの IoT デバイスが存在し、多くの IoT デバイスは起動する、通知するなど 1 つのデバイスに対し 1 つの機能を持つ。しかし今後増大する IoT デバイスとしてコネクテッドカーや AI 機能を搭載したロボットなど複数機能を持つデバイスが予想される。複数機能を持つデバイスは機能ごとに通信手段や通信経路が変わり、開発側の IoT デバイスのネットワーク設定は複雑になる。我々は IoT デバイスのデータ量の時系列変化パターン (通信パターン) を使った自動ネットワーク設定を目標としている。先行研究として通信パターンから機械学習を使い、IoT デバイスの識別に関する研究が行われている。しかし我々は IoT デバイスの識別ではなく IoT デバイスに含まれる機能ごとの認識を目指している。我々は複数機能を持つ IoT デバイスのトラフィックデータから機能ごとに通信パターンを分けクラスフィケーションを行なった。IoT デバイスは機能や目的によって通信先が変わる。そのため本稿では通信先の IP アドレスごとに 1 機能とみなし、通信先の IP アドレスごとに通信パターンの分析を行なった。通信パターンの分析の結果、データ量、通信のタイミング、通信先の距離、通信にかかる時間を特徴量とした。また大容量高速通信、低遅延高信頼通信などといった特徴的な IoT デバイスの機能を正解ラベルとした。SVM(サポートベクトルマシン) を使い、機能ごとに分けられた通信パターンのクラシフィケーションの評価をした。

Communication Pattern Analysis for Automatic Network Configuration of IoT Devices

YOSHINO NIWA¹ KATSUHIKO KAJI²

1. はじめに

インターネット技術や各種センサ類の技術の進化により様々な分野で多くのモノがインターネットにつながっている。インターネットにつながるモノ (Internet of Things) の数は、2020 年までには 300 億個まで増大すると予想されている [1]。IoT デバイスの中で多くを占める分野はコンシューマである。コンシューマ向けの IoT デバイスは人口約 70 億人の規模に近づいている。他の分野としてコネクテッドカーや通信機能を搭載された工場オートメーション (FA) など産業の分野での IoT 化が進んでいる。またウェアラブル端末を使った健康管理や、多種多様なセン

サを使った保守管理システムなど幅広い分野での IoT デバイスが活用されていく。

現在の多くの IoT デバイスが 1 つのデバイスにつき 1 つの機能を持つ場合が多い。しかしこれから増大する IoT デバイスは、ウェアラブル端末やコネクテッドカーなど 1 つのデバイスに対し複数機能を持つ。複数機能を持つ IoT デバイスの例としてコネクテッドカーがある。コネクテッドカーは事故時の緊急連絡や、自動運転のための周辺情報の取得、また地図の自動更新といった様々な機能が含まれる。これらの機能に対してそれぞれ通信手段や通信相手が変わる。緊急連絡の場合はキャリア A の 4G を利用しインターネット越しのサーバへ通信する。周辺情報の取得の際は、Bluetooth を使い車車間もしくは路車間で通信をする。地図の自動更新は Wi-Fi を使いインターネット越しのサーバへ通信する。

¹ 愛知工業大学大学院 経営情報科学研究科
Aichi Institute of Technology

² 愛知工業大学大学 情報科学部
Aichi Institute of Technology

また、2枚のSIMカードを入れ、切り替え操作なしで利用できるDSDS(Dual SIM Dual Standby)対応端末が2016年後半に登場した。DSDSの利用によって通信内容に合わせて利用キャリアの変更が可能である。複数キャリアの選択ができるため、混雑している通信経路を意図的に回避し別の通信経路の選択が可能となる。

ネットワークに関する研究も進み、第5世代移動通信システム(5G)の導入に向けての取り組みが加速している[3]。5Gの特徴として「高速・大容量」「超遅延・高信頼性」「同時多数接続」の3点がある。最大通信速度は10ギガビット/秒以上とLTEの約100倍の速さとなる。ネットワークの遅延は4Gの約10分の1に相当する1ミリ秒まで短くなる。産業機器や医療機器、遠隔操作などに低遅延のネットワークが不可欠となる。また4Gでは1カ所の基地局に一度に接続できる端末の数が、1平方キロメートルのエリアに当たり1万台程度に対し、5Gは4Gの100倍に当たる約100万台を目指している。そのためスマートフォンやPCだけではなく、多数のセンサ類の接続が可能となる。5GはIoTの通信インフラを支えていく。

通信の多様化が進む中、現在同一ネットワーク上で全ての通信が行われている。図1に、機能やデバイスごとにネットワークサービスが存在する。ARを用いたリアルタイムのスポーツ観戦は高速大容量なネットワークサービスを求める。ロボットやドローン、遠隔手術などの遠隔操作では超高信頼性低遅延なネットワークサービスを求める。スマートシティやスマートキャンパスでは超大量端末を収容できるネットワークサービスを求める。このようにネットワークのサービス化が求められている。しかし今後はネットワークサービスごとに通信に必要な要求条件を合わせてネットワークスライスを仮想的に構築して対応する[4]。




図1: 多種多様なトラフィック需要を持つネットワークサービスの例

このように複数機能を持つIoTデバイスや複数通信手段を持つ端末が増えてきている。またネットワークのサービス化により機能ごとに使用するネットワークが変わる。そのためIoTデバイスの開発者側は、機能ごとの適切な通信手段や通信経路の設定が困難となる。




図2: ネットワークスライシング

我々はIoTデバイスの通信パターンを使った自動ネットワーク設定を目標としている。研究の全体像を図3に示す。各端末から発生するトラフィックを知的トラフィック解析層で分析を行いオーバレイオフローディング層で通信手段の切り替えを行う。我々は図3中の知的トラフィック解析層の研究を担当する。

知的トラフィック解析層では図4に示すように機械学習を用いて機能ごとの通信パターンに適切な通信手段、通信経路を与える。IoTデバイスごとではなく機能ごとの通信パターンに通信手段を与えるため、機能ごとの通信パターン分析が必要である。本稿では複数機能を含む通信パターンから、機能ごとに通信パターンを分類した。




図3: 研究の全体像

2. 関連研究

IoTデバイスの増加に伴いモバイルデータ通信の需要が今後増え続け、モバイルデータ通信網の負荷を分散する研究が行われている。

端末や基地局からデータを収集・分析し、自律的にネットワークを調節し最適化するSON(Self Organizing Network)がある[5]。また5Gでのスモールセル活用効果の研究が活発に行われている[6]。モバイルデータ通信網の負荷を分散するために、IoTデバイスの通信のネットワークの最適




図 4: 機械学習による行動認識

化を目的として行われている。これらの研究は主に下り方向のトラフィックが想定されている。しかし今後センサ系の IoT デバイスなど上り方向のトラフィックも意識した通信制御を行わなければならない。

IoT デバイスの通信内容の特徴を使い、通信負荷を削減する研究が行われている。義久らの研究では IoT デバイスのストリーミング処理の時間短縮し、通信負荷を削減している [7]。西岡らの研究では遅延耐性のあるモバイルトラフィックデータを適切に遅延させ通信インフラの負荷を分散させている [8]。遅延耐性とは、データの同期やシステム更新など通信が多少遅延しても許容されるトラフィックか、ユーザ間の通信や動画視聴など遅延が許されないトラフィックかを表す。西岡らは通信手段を変える方法ではなく通信自体を遅延する方法を行っている。

行動のセンシングデータの時系列パターンを用いた機械学習の研究が行われている。小川らの研究では加速度や角速度などの行動センシングデータを用いた機械学習によって行動認識を行っている [9]。図 6 に研究概要を示す。歩行者から得られた行動センシングデータをパターン分析し正解データ (行動) をラベルリングする。生成された識別器に未知の行動の行動センシングデータを入力し正解の行動内容をアウトプットとしている。行動認識の機械学習アプローチを本稿の通信パターンの機械学習に適用する。




図 5: 機械学習による行動認識

通信量の時系列変化パターン (通信パターン) による機

械学習の研究も多く行われている。鈴木らの研究では、スマートフォンの通信パターンを使いフォアグラウンド通信かバックグラウンド通信かを識別した [10]。鈴木らはモバイルコアネットワークからパケットキャプチャし、通信量や通信時間を特徴量として分類を行なっている。

Sivanathan らの研究では通信パターンを使い IoT デバイスと非 IoT デバイスの分類を行なっている [11]。Sivanathan らは通信量や通信時間の他に通信にかかる負荷や使用されているプロトコルも特徴量とした。Sivanathan らが提案した分類では特定の IoT デバイスを 95% の精度で識別可能である。

これらの研究は、特定のデバイスの通信内容の分類や、特定 IoT デバイスの分類を行なっている。我々は 1 つの IoT デバイスに含まれる複数の機能に対し、それぞれに適切な機能の割当を目指している。そのため 1 つの IoT デバイスの機能ごとの通信パターンの分類を行う。

3. 既存の IoT デバイスの通信パターンに関する調査

現在多くの場面で IoT デバイスが使われている。表 1 に現在使われている場面ごとの IoT デバイスを列挙した。身近な住宅だけではなく、産業や医療など多方面の分野で幅広く使われている。例えば医療の分野では患者側はウェアラブルデバイスを使った健康管理や通信機能が埋め込まれた人工臓器などがある。病院側は遠隔で診療や手術、医療現場での VR の活用がある。また交通分野では道路の維持管理などのセンサを使った管理、自動車や道路から得られる情報からの交通状況の発信などの IoT がある。このように様々な場面で多種多様な IoT デバイスが存在している。

多くの IoT デバイスがある中、単機能の IoT デバイスや複数機能の IoT デバイスが混在している。図 7 に単機能の IoT デバイスと複数機能の IoT デバイスの例を示す。単機能の IoT デバイスの例として家電制御や様々なモニタリングがあげられる。家電制御はスマートフォンからの家電の電源の On/Off 制御をさす。モニタリングは映像や各種センサなどのセンシング機能を示す。複数機能の IoT デバイスの例としてコネクティッドカーがある。表 1 の自動車に書かれている機能は全てコネクティッドカーという 1 つのデバイスに含まれている。またウェアラブルデバイスや AI スピーカも複数の機能が含まれている。コネクティッドカーやウェアラブルデバイスは IoT の進展等による成長が期待される市場である [1]。そのため、今後複数機能を持つ IoT デバイスが増加数と予測される。

複数機能の IoT デバイスのそれぞれの通信について説明する。カメラ付きドローンを使用する場合、リアルタイムの映像配信と遠隔操作の 2 つの機能の同時利用が考えられる。リアルタイムに映像配信の機能は高速に大容量のデータを通信しなければならない。高速に大容量のデータを通

表 1: 各場面ごとの IoT 例

	患者側	病院側	
医療	・患者のモニタリング ・人工臓器 ・健康管理	・遠隔診療 ・遠隔手術 ・手術中 VR	
	道路	自動車	
交通	・道路の維持管理 ・交通状況 ・バスの運行管理	・緊急通報 ・運転記録 ・地図の自動更新	
	畜産	農業	工場
産業	・家畜位置管理 ・飼育環境管理 ・出荷管理	・病害虫発見 ・栽培管理 ・生産管理	・ラインのモニタリング ・設備のモニタリング ・製品管理
	屋内		屋外
住宅	・統合リモコン ・家電制御 ・音声アシスト		・セキュリティ管理 ・ネットワーク管理 ・監視システム
	環境		街
自治体	・自然環境センシング ・空気環境センシング ・環境整備		・見守り ・治安管理 ・地域情報発信

信する場合はモバイル通信の利用は不向きである。この場合 Wi-Fi の利用が最適だと考えられる。遠隔操作は正確に遅延なく通信する必要がある。正確に遅延なく通信する場合、低遅延の通信を得意とする 5G の利用が最適と考えられる。またコネクティッドカーの場合、緊急通報は低遅延で行わなければならないが、地図の自動更新は通信が遅れても構わない。複数機能を持つ IoT デバイスの場合、このように同一の IoT デバイスでも機能によって通信手段が変わる場合がある。

各機能に対して通信に必要な要件条件が違うため、複数機能の IoT デバイスは 1 つの通信手段では対応できない。またコネクティッドカーの場合は、通信相手も車と車の間での通信や、サービス提供元のサーバへ通信する場合がある。通信先の変更によって経由する通信媒体も変わる。このようにそれぞれの機能がそれぞれの通信手段だけではなく通信経路も持つ。開発側は 1 つのデバイスでも機能ごとに適切な通信手段や通信経路を設定しなければならない。複数機能の IoT デバイスは 1 つの通信手段では対応できないため、1 つのデバイスでも機能ごとに通信手段や通信経路を使い分ける必要がある。

表 2: IoT デバイスの代表的な機能と典型的な通信パターン

IoT デバイスの機能例	典型的な通信パターン	通信手段
・ストリーミング ・ビデオ通話	大容量・不定期	Wi-Fi
・音声アシストによる検索 ・スマートウォッチによるナビ検索	中容量・不定期	4G
・音響センシング ・環境センシング	低容量・持続的	LPWA

4. IoT デバイスの機能ごとの通信パターン分類

本研究の最終目的は機械学習を用いて複数機能を含む通信パターンを入力し、適切な通信手段、通信経路を出力する。IoT デバイスは IoT 最適化モジュールをつけ、IoT 最適化モジュールを通し通信する。IoT の代表的な通信手段として以下の 5 点を示す。

- ・ モバイル通信 (5G, 4G, etc.)
- ・ Wi-Fi
- ・ Bluetooth
- ・ BLE
- ・ LPWA

本稿では複数機能を持つ IoT デバイスの通信パターンを機能ごとに分類する。機械学習を利用する際、入力データは複数の機能を含む通信パターンを用いる。入力データを機能ごとに分離し、機能ごとの通信パターンから特徴量を抽出する。適切な通信パターンのラベル付けを行う。様々な特徴量を持つ機能の通信パターンを SVM を使い

図 7 に機能ごとに通信パターンを分類する際に必要な学習データの生成の流れを示す。図 8 に機能ごとに通信パターンを分類する学習フェーズと識別フェーズを示す。機能ごとに通信パターンを分類する処理は 4 つに分かれる。

- (1) 機能ごとに分離
- (2) 特徴量の選定
- (3) 学習用データの生成
- (4) 通信パターンの分類

はじめに複数通信パターンを含む機能ごとに分離する。機能ごとに分離する処理は図 7 に示す。本稿では通信先の IP アドレスを 1 機能とみなしたため、通信先の IP アドレスごとに通信パターンを分離した。

分離した機能ごとの通信パターンの特徴量を求める際、各通信パターンを通信量を用いてクラスタリングした。特徴量の抽出の処理は図 7 に示す。クラスタごとに特徴量を求めた。トラフィックデータからの情報を使い通信のタイミング、通信量、通信先、リアルタイム性特徴量を提案する。本稿では特徴量として通信のタイミングの平均・標準偏差、通信量の平均・標準偏差、クラスタ数を用いた。

クラスタごとに求めた特徴量に対し、ラベル付けを行い学習データを生成する。学習データの生成の処理は図 7 に示す。⑤-⑦の部分である。現状の IoT デバイスの通信パターンに注目し、典型的な通信パターンをラベルとした。

最後に SVM(Support Vector Machine) を使い、生成された学習データを機能別に通信パターンを分類した。通信パターンの分類は図 8 に示す。Sivanathan らがキャンパス内で収集した 2 週間分の様々な端末のトラフィックデータを提供している [11]。本稿では上記のデータの中から Amazon が開発したスマートスピーカ Echo のトラ

フィックデータを入力データとして用いた。2週間分のトラフィックデータから生成された学習データを SVM で学習させ正解率を求める。以下の節で各処理について詳しく述べる。




図 6: IoT 通信最適化モジュール




図 7: 機能ごとに通信パターンを分類する学習データの生成

4.1 機能ごとに分離

我々は IoT デバイスごとのネットワーク設定ではなく、機能ごとの自動ネットワーク設定を目標としている。自動ネットワーク設定は、図 4 に示すように通信パターンを学習させ識別器を生成する。その後未知の通信がきたとき識別器を通して適切な通信手段を推定する流れである。我々は機能ごとの通信パターンを学習させようと考えている。複数機能を含む通信パターンを機能ごとに分け、機能ごとの通信パターンの特徴量を求めたい。そのため、通信パターンを機能ごとに分類する必要がある。

IoT デバイスは機能によって通信先を変えようと考えた。例えば AI スピーカの場合、音声を常にセンシングし通信




図 8: 機能ごとに通信パターンを分類の学習フェーズと識別フェーズ

している時は各 AI スピーカの開発元のサーバに通信する。検索の機能は検索エンジンに通信する。音楽等のストリーミング機能は各ストリーミング配信サイトへ通信する。またコネクティッドカーの場合も機能によって通信先が変わる。事故を起こした際の緊急通報は緊急通報センターへ通信する。地図データ自動更新は各サービス提供元のサーバへ通信する。周辺情報を車車間・歩車間通信により入手する。このように機能によって通信先が変わる。

実際の IoT デバイスを用いて機能と通信先の関係について観察した。表 3 に Google Home のパケットキャプチャした際の機能と通信先をまとめた表を示す。Google Home は Google が開発したスマートスピーカである。表 3 では、Google Home の何もしていない時 (音声センシング)、検索、ストリーミング、の 3 つの機能と通信先の IP アドレスの関係について表している。各機能ごとに通信先の IP アドレスは変わっている。またセンシングと検索の機能を比べると通信先は同じ GOOGLE になっている。しかし通信先の IP アドレスに注目すると違う IP アドレスになっている。実際の IoT デバイスのパケットキャプチャから機能ごとに通信先が変わっていると確認できる。

本稿では通信先の IP アドレスを 1 機能とみなし、機能ごとに通信パターンを分ける。実際の処理の流れとして図 3 に示すように、①の通信パターンを IP アドレスごとにデータを分けた。そのため①の通信パターンは機能ごとに分離した。機能ごとに分けられた通信パターンから特徴量を抽出する。特徴量の説明を以下の節で述べる。

4.2 特徴量の選定

通信パターンから分離された、機能ごとの通信パターンの特徴量を抽出する。通信の時間と通信量が特徴量として、通信パターンを用いた通信やデバイスの分類の研究で

多く使われている。Sivanathan らの研究でも特徴量として通信している時の通信量の平均が使われている [11]。しかし図 7 の IP address:A のように 1 つの通信パターン内でも通信量にばらつきがでる。そのため機械学習を行った際の精度に影響がでる。

我々は図 7 に示すように各 IP アドレスの通信パターンから通信量を用いてクラスタリングをした。また図 7 にて実際のトラフィックデータを用いてクラスタリングを行った際のグラフを示す。今回クラスタリングに X-means を使用した。IP address:A を通信量でクラスタリングを行い、2 つのクラスが生成された。2 つのクラスの通信パターンから通信のタイミングと通信量の平均・標準偏差を求め IP address:A の特徴量とした。通信のタイミングは通信をしていないスリープ時間を用いた。クラス数が 3 つ以上の場合には通信量の平均が多いほうが通信パターンに影響を与えていると考え、通信量の多い 2 つのクラスを特徴量とした。クラス数が 1 つの場合、もう 1 つのクラスの通信のタイミングと通信量は 0 とみなした。また機能に含まれる通信パターンの数も特徴量の 1 つとした。各機能の通信パターンの特徴量は 2 つ分のクラスの通信のタイミングの平均・標準偏差、通信量の平均・標準偏差、通信パターンに含まれるクラス数とした。

4.3 学習データの生成

機械学習に必要な学習データを生成する。学習データの生成の処理は図 7 の⑤-⑦の部分である。クラスごとに求めた特徴量に対し、ラベル付けを行い学習データを生成する。第 3 章で行った調査をもとに、典型的な通信パターンをラベルとした。本稿で提案する典型的な通信パターンのラベルは以下の 3 点である。

- 大容量・不定期
- 中容量・不定期
- 低容量・持続的

4.4 通信パターンの分類

生成された学習データを SVM(Support Vector Machine)を用いて分類を行う。通信パターンの分類の学習フェーズについて図 8 に示す。機械学習は、機械学習ソフトウェア Weka を用いた。学習データから機械学習を用いて識別器が生成される。未知の IoT 機能の通信パターンは生成された識別器を通して正解の通信パターンが求えてくる。

表 3: 機能と通信先の IP アドレスの関係

機能	通信先の IP アドレス	通信先
センシング	172.217.266.99	GOOGLE(US)
ストリーミング(ラジオ)	203.211.199.187	ストリーミング事業者(JP)
検索	216.58.197.4	GOOGLE(US)

5. 評価実験

本稿で提案した特徴量を用いて機能ごとに通信パターンが分けられるか評価するため精度実験を行なった。本稿では学習データを作成する際、Sivanathan らが提供しているキャンパス内で収集した 2 週間分の様々な端末のトラフィックデータの中から、AI スピーカの AmazonEcho のトラフィックデータを利用した [11]。2 週間分のデータから生成された学習データのサンプル数は 493 となり、この学習データを用いて機械学習を行った。提案手法の評価のため、本稿では SVM を用いて 10 重クロスバリデーションによる評価を行った。

精度評価を行なった結果、精度は 98.8% となった。しかし AI スピーカは音声センシングをしている時間が多く、ラベルのサンプル数に差が出た。サンプル数の差が生じているため正確な精度とはならないため不均衡データを補正した。これらの不均衡データを補正するために over-sampling 手法を用いた。over-sampling により補正された学習データを用いて再度精度評価を行った。評価値として精度(正解率)、再現率、F 値を用いた。評価値の算出方法を以下に示す。

$$\text{再現率} = \frac{\text{対応関係ありと推定できた数}}{\text{実際に対応関係がある数}}$$

$$F \text{ 値} = \frac{2 \cdot \text{適合率} \cdot \text{再現率}}{\text{適合率} + \text{再現率}}$$

精度評価の結果、精度は 99.7% となった。補正されたデータの精度評価の結果を表 4 に示す。精度、再現率、F 値共に 99.7% と高い精度結果を得られた。

表 4: 提案手法での精度評価の結果

精度	再現率	F 値
99.7 %	99.7%	99.7%

次に本手法の特徴量と既存手法の精度の比較実験を行った。本手法では通信量のばらつきを考慮し、通信量を用いてクラスタリングを行ない、各クラスごとの特徴量を抽出した。しかし既存手法では通信量のばらつきに考慮せず、1 つの通信パターンの通信量を 1 つとみなし特徴量を抽出している。そのため既存手法では通信量のばらつきが精度に影響していると考えた。精度の比較のため各手法を用いて学習データを生成した。学習データは精度評価と同じく over-sampling により不均衡データが補正されたものとする。評価方式も精度評価と同じく SVM を用いた 10 重クロスバリデーションを行なった。

結果、既存手法よりも本手法の精度の方が高い値を出した。本手法と既存手法の精度比較の結果を表 5 に示す。既存手法の精度も 95.7% と高い精度を得られたが本手法と

4%の精度の差がでた。

表 5: 提案手法と既存手法の精度比較の結果

	精度	再現率	F 値
提案手法	99.7 %	99.7%	99.7%
既存手法	95.7 %	95.3%	95.3% %

6. おわりに

本研究は IoT デバイスの自動ネットワーク切り替えを最終目標としている。本稿では機能ごとの通信パターンの分類を行った。分類に使用する特徴量を求める際、通信量のばらつきを考慮し各機能の通信パターンを通信量を用いてクラスタリングした。各機能の通信パターンの特徴量を 2 つ分のクラスターの通信のタイミングの平均・標準偏差、通信量の平均・標準偏差、通信パターンに含まれるクラスター数を提案した。「大容量・不定期」、「中容量・不定期」、「小容量・持続的」の 3 つの典型的な通信パターンを正解ラベルとした。提案した特徴量をもとに、SVM を用いてクラシフィケーションを行なった

提案した特徴量を用いて機能ごとに通信パターンが分けられるか評価するため精度実験を行なった。結果は 99.7% と高い精度を得られた。また既存手法の特徴量を用いて精度評価を行なったところ、既存手法より本稿で提案した特徴量を用いた方が 4% 精度が高かった。

今後の課題として他の機能での通信パターンの分類を行う必要がある。本稿では AI スピーカのトラフィックデータのみを用いたため 3 つの典型的な通信パターンの分類を行なった。しかし他の IoT デバイスの機能として、監視カメラ等の「大容量・持続的」通信パターンや、毎日決まった時間に 1 日分のセンシングデータを送る「中容量・定期的」通信パターンなど様々な通信パターンがある。多くの通信パターンの識別器が今後必要となる。しかし実機での様々な通信パターンの適切な評価が規模的に困難である。そのための条件設定やモデル構築を現実に近いネットワークシミュレーションによる評価が求められる。今後、本稿で提案した特徴量をもとに通信パターンの再現を行いネットワークシミュレーションの作成を行っていく。

参考文献

- [1] 総務省情報通信白書平成 29 年版, <http://www.soumu.go.jp/johotsusintokei/whitepaper/ja/h29/> (参照日: 2018 年 1 月).
- [2] 櫻井康平, 片岡幹雄, 小高浩, 加藤淳, 寺岡秀敏, 木山昇, IoT 技術を活用したネクテッドカーソリューション, 日立評論, Vol.99, No.05, 518-519, pp.64-69, 2017.
- [3] 中村邦明, 5G 2019 年に先行スタート同時多数接続で IoT が広がる, NIKKEI COMPUTER, pp.94-97, 2018.
- [4] 安川正祥, 佐藤裕昭, 弘田武志, 東條琢也, 遠藤乾市, 笠原泰信, 鈴木裕志, 将来ネットワークアーキテクチャの具現化に向けた取り組み, NTT ジャーナル, pp.23-30,

- 2018.
- [5] 小西聡, 山本俊明, LTE/LTE-Advanced システムのための Self-Organizing Networks(SON) 技術による自動最適化の効果, 電子情報通信学会論文誌, Vol.J97-B, No.8, pp.599-610, 2014.
- [6] Chochliouros, I. P., Kostopoulos, A., Giannoulakis, I., Spiliopoulou, S. A., Belesioti, Maria., Sfakianakis, E., Kourtis, A., Kafetzakis, E., Using small cells for enhancing 5G network facilities, IEEE Conference on Network Function Virtualization and Software Defined Networks, NFV-SDN 2017, pp.264-269, 2017.
- [7] 義久智樹, 原隆浩, IoT 環境における処理削減によるストリーミング処理時間短縮手法, 情報処理学会論文誌, Vol.58, No.4, pp.898-907, 2017.
- [8] 西岡哲朗, 町田樹, 荒井大輔, 大岸智彦, 峰野博史, モバイルデータトラフィックの時間的局所性を解消するモバイルデータオフローディングプロトコルの提案. 情報処理学会論文誌, Vol.58, No.1, pp. 13-23, 2017.
- [9] Ogawa, N., Kaji, K. and Kawaguchi, N., Effects of Number of Subjects on Activity Recognition—Findings from HASC2010corpus, Proc. Workshop on Frontiers in Activity Recognition Using Pervasive Sensing (IWFAR), pp.48-51 (2011).
- [10] Suzuki, M., Watari, M., Ano, S., Tsuru, M., Traffic Classification on Mobile Core Network Considering Regularity of Background Traffic, IEE International Workshop Technical Committee on Communications Quality and Reliability(CQR),2015.
- [11] Sivanathan, A., Sherratt, D., Gharakheili, H. H., Radford, A., Wijanayake, C., Vishwanath, A., Sivaraman, V., Characterizing and Classifying IoT Traffic in Smart Cities and Campuses,IEEE Conference on Computer Communications Workshop(INFOCOMWKSHPS),2017.