

Society5.0 実現のための IoT/CPS におけるアプリケーション・トラヒックの特性分析と推定

研究代表者 田村 瞳 福岡工業大学 工学部 電子情報工学科 准教授
共同研究者 塚本 和也 九州工業大学大学院 情報工学研究院 情報・通信工学研究系 教授

1 はじめに

Internet of Things (IoT) が一般化し、スマートフォンや PC のように 1 人 1 台が基本ではなく、1 人が複数の IoT デバイスを利用するようになった。IoT デバイスは、低価格で広く普及している無線 Local Area Network (LAN) で收容されることが多く、1 台の無線 LAN Access Point (AP, 親機) には、スマートフォン、PC だけでなく多くの IoT デバイスが收容されるようになってきている。従って、無線 LAN 上では、従来から利用されているリッチコンテンツと呼ばれるアプリケーションや音声トラヒックに加え、IoT デバイスから発生する IoT トラヒックが收容されるようになった。

動画や World Wide Web (WWW) 等のリッチコンテンツと呼ばれるトラヒックでは、大容量ファイルを扱うことが多く、ユーザが必要なときに通信が生じるユーザ主導のトラヒックである。一方、小型でコンピューティング資源が乏しい IoT デバイスからのトラヒックについては、取り扱うファイルサイズが小さい可能性があり、さらに、物理事象のセンシングデータの送受信や物理デバイスの操作に利用されることを考えると、ユーザの操作によって発生するトラヒックのみではなく、物理事象を契機にトラヒックが発生する可能性がある。このように、コンピューティング資源や用途が異なることにより、取り扱うファイルサイズや通信の契機が異なるため、パケットの発生状況やパケットサイズなどのトラヒック特性が異なることが想定される。

次に、これらのトラヒックを收容する無線 LAN について、最新の IEEE802.11ax 準拠の無線 LAN では、Orthogonal Frequency Division Multiple Access (OFDMA) が採用され、複数の無線子機 (Station, STA) との効率的な通信のため、複数端末との同時通信が可能となった。このとき、大容量のリッチコンテンツと小容量の IoT デバイスによる通信が混在することによって、ユーザが感じるサービス品質の指標である Quality of Experience (QoE) が低下することが予想される。そこで無線 LAN においてリッチコンテンツや音声、IoT デバイスから発生するトラヒックを同時に転送処理する際、適切な QoE を提供するための新たなトラヒック制御技術が必要である。しかし、現状では無線 LAN 上でリッチコンテンツや音声、IoT のトラヒックにどのような特性の違いがあるかは明確にされていない。また、アプリケーション毎に適した制御を実現するために、無線 LAN AP に到着したパケットについてアプリケーションを判別し、リアルタイムな制御を実現するための、トラヒック推定手法が確立されていない。

そこで本研究では、リッチコンテンツ、音声や様々な IoT デバイスからトラヒックについて、IEEE802.11ax 無線 LAN 上でのトラヒック特性を明らかにするために、パケットサイズ、パケット到着時間間隔、プロトコルの種類に注目してトラヒック特性の違いを実験により調査した。さらに、調査結果をベースに、トラヒック発生時からの一部のパケットのみを利用したリアルタイムなトラヒック推定を行うため、機械学習を適用して、トラヒックの推定精度について検証した。

以降、2 章では IoT と IEEE802.11ax 準拠の無線 LAN の技術について説明し、3 章で本研究の目的について説明する。4 章では各種アプリケーションのトラヒック特性の調査、調査結果について説明している。5 章では、各種アプリケーションにおける通信開始時の一部のパケットを用いた機械学習によるトラヒック推定手法と推定結果を示す。最後に 6 章で本研究についてまとめる。

2 IoT と無線 LAN

2-1 IoT における通信技術

IoT とは様々なモノがインターネットに接続され、相互に情報交換をする状態のことを指す [1]。IoT によってモノの遠隔での操作や監視、自動化を行うことが可能になる。IoT デバイスの数は年々増加傾向にあり、2024 年には 398 億台にのぼると予想されている [2]。一人一台が基本であるパソコンなどのコンピューター市場は飽和状態であるが、家電などのコンシューマー製品や工場の製造ラインなどの産業用途で使われる

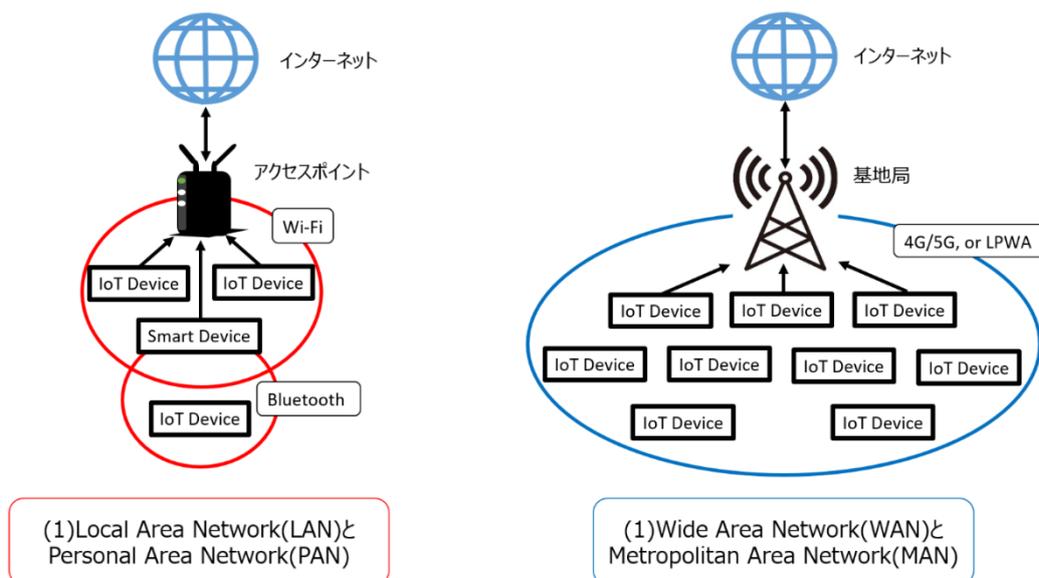


図1 IoTにおける通信方式

IoT デバイスは今後大きな増加が見込まれる。その結果、これらの IoT デバイスから生成されるトラフィックは、多様で膨大なものになる可能性が高い。

図1に、多数のIoTデバイスをインターネットに接続するためのネットワークポロジータを示す。IoTデバイスは、(1)Local Area Network (LAN)またはPersonal Area Network (PAN)、(2)Wide Area Network (WAN)またはMetropolitan Area Network (MAN)のネットワーク技術のいずれかによってインターネットに接続することができる。WANまたはMAN技術、すなわち4G、5G、またはLPWA (Low Power Wide Area) では、基地局の広い通信範囲内にある多くのIoTデバイスがインターネットに直接接続するが、通信コストが高額である。一方、IoTデバイスはLANやPAN技術、例えばWi-FiやBluetoothを使ってインターネットに接続することも可能である。Wi-FiやBluetoothの通信範囲は4G、5G、LPWAに比べて小規模であるが、導入が容易で通信コストが低いため、広く普及している。なお、IoTデバイスがBluetoothを使用する場合、インターネットに直接接続することはできない。そのため、インターネットへの接続を確立するには、まずBluetoothでスマートフォンやタブレットに接続し、そのスマートフォンやタブレットが無線LANルータの役割を担い、Wi-Fiなどを使用することでインターネットに接続される。このように、IoTデバイスから発生するトラフィックは、主に無線LAN上で伝送されることになる。以上の理由から、IoT時代には無線LANが最も重要なアクセスネットワークとなるため、本研究ではIoTデバイスのアクセスネットワークとして無線LANが一般的に利用されることを想定している。

2-2 無線LANにおけるIoTトラフィックの収容

無線LANでは、接続台数 n が増加すると共に各端末のスループットが $1/n$ になる。これは、従来から無線LANのMedium Access Control (MAC)として使用されているCarrier Sense Multiple Access with Collision Avoidance (CSMA/CA)によるオーバーヘッドが大きく影響している。今後、IoTデバイスの増加とCSMA/CAによる通信機会の均等割当によって、様々な通信のQoEが低下する可能性がある。そこで、無線LANの最新規格であるIEEE802.11axでは、複数の端末の効率的な通信のために、Orthogonal Frequency Division Multiple Access (OFDMA)が導入された[3]。OFDMAでは、周波数帯域内のサブキャリアを束ねたResource Unit (RU)と呼ばれるサブキャリアの束を各ユーザに割り当てることで、複数端末の同時通信が可能である。これによって20MHz帯域の場合で最大9端末が同時に通信可能であり、CSMA/CAによるスループットの低下を抑制することができる。一方で、OFDMAではサブキャリアの束を各端末に割り当てることから、各端末が利用できる帯域幅がIEEE802.11ac以前で採用されていたOrthogonal Frequency Division Multiplexing (OFDM)適用時と比べて狭帯域となる。よって、IEEE802.11ax無線LANにOFDMAを適用した無線LANとそれ以前のOFDMによる無線LANでは、接続するSTA数によって1端末あたりの可用帯域とCSMA/CAによるオーバ

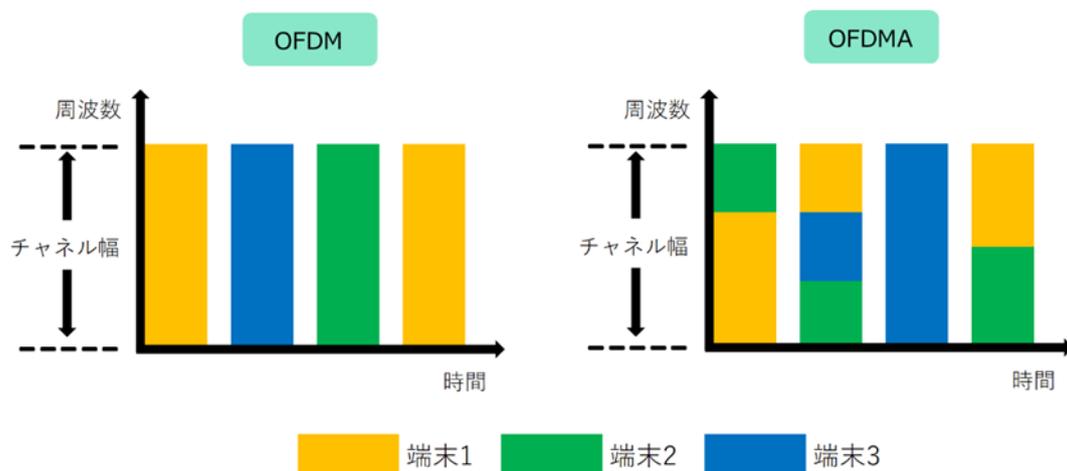


図2 OFDM と OFDMA におけるチャンネル利用例

ヘッドに起因してそれぞれの有効性が異なることが、実機を用いた実証実験によって明らかにされている [4].

無線 LAN 上で交換されるトラフィック特性の面からは、リッチコンテンツと呼ばれる動画や Web ブラウジングなどのトラフィックはパケットサイズが大きく、ユーザが必要ときにアクセスすることから、ユーザ主導でトラフィックが生成されることが予想される。一方、IoT トラフィックはパケットサイズが比較的小さく、物理事象のセンシングや物理デバイスの遠隔操作などで使用されることから、物理的な事象の変化によって、もしくは、ユーザがデバイスを遠隔操作するなどの用途でトラフィックが発生する。さらに、デバイスが小型であることが一般的で、計算機資源に制限があるため、パケットの生成タイミングや継続時間はリッチコンテンツとは大きく異なると予想される [5]。そのため、今後増加することが予想される IoT デバイスが無線 LAN に接続されることで、従来のリッチコンテンツとは異なる特性を持つトラフィックが無線 LAN 上に混在することになる。

このとき、無線 LAN が OFDM を使用した場合、データの大きさに関係なく全ての周波数帯域を割り当てるため、IoT のような小さなパケットが混在しやすい通信環境下では帯域の利用に関して非効率となる可能性がある。一方、無線 LAN が OFDMA を使用した場合、周波数帯域を複数端末に分割して割り当てるため、リッチコンテンツのようにパケットサイズが大きい通信環境下では OFDM よりも送信時間が増加する事が考えられる。これによって、ユーザが感じるサービス品質の指標である QoE が低下することが考えられる。そこで無線 LAN においてそれぞれの特性に適応したリアルタイムなトラフィック制御技術が必要である。

そこで、本研究ではまず、従来のリッチコンテンツや IoT のトラフィックの特性を理解することが重要になる。しかし、無線 LAN における IoT トラフィックの特性の調査に焦点を当てた文献はほとんどない。さらに、無線 LAN におけるリアルタイムなトラフィック制御を実現するためには、トラフィックのリアルタイムな分類や推定を実施することが重要である。

3 研究目的

本研究では、最新の規格である IEEE802.11ax 無線 LAN に接続されたリッチコンテンツ (YouTube および Web ブラウジング) と音声、IoT デバイスから発生するトラフィックをフロー毎に全てキャプチャし、各アプリケーションのトラフィック特性、特にパケットサイズ、パケット到着時間間隔、プロトコルの種類に関する特徴を調査する。さらに、実験によってパケットの一部、特に、通信開始時の一部のパケットのみを利用して、機械学習を用いたリアルタイム、かつ、高精度なトラフィック推定を行うために有効となるトラフィック特性を調査し、トラフィック推定精度について明らかにする。

表 1 調査対象のアプリケーション種別

アプリケーションの種類	調査内容
リッチコンテンツ(動画)	Google Pixel で YouTube3 分の動画
	Google Pixel で YouTube20 分の動画
	Alexa で YouTube3 分の動画
	Alexa で YouTube20 分の動画
リッチコンテンツ(Web)	Google Pixel で Yahoo 検索
	Alexa で Yahoo 検索
IoT	SwitchBot の見守りカメラで何も操作を行わない
	SwitchBot の見守りカメラをスマホで操作
	SwitchBot の見守りカメラで動体検知を行う
	Alexa で何も操作しない
	Alexa で SwitchBot の見守りカメラを操作
	Alexa でスマートプラグを操作
	Alexa に交通情報を聞く
	Alexa に天気を聞く
音声	Alexa で Amazon Music を聴く
	Alexa で Spotify を聴く
	Google Pixel で Spotify を聴く
	Discord 通話
	LINE 通話

4 IEEE802.11ax 準拠無線 LAN におけるトラフィック特性の分析

4-1 実験環境と実験方法

実験の調査対象は表 1 の通りである。実験において使用したデバイスについては、動画トラフィックと Web トラフィックの場合、Google Pixel 6a と Amazon Echo Show 5 with Alexa, IoT トラフィックでは SwitchBot 見守りカメラと Amazon Echo Show 5 with Alexa を使用した。音声トラフィックでは音楽を流す場合に Google Pixel 6a と Amazon Echo Show 5 with Alexa を使用した。Discord 通話は 2 台の PC 間で通話を実行した。LINE 通話では iPhone 14 と iPhone 14 Pro を使用して実験を行った。

図 3 に、実験環境を示す。IEEE802.11ax 準拠の無線 LAN AP に有線 LAN 接続したパケットキャプチャ用 Linux PC をブリッジ接続し、当該 PC のさらに上流で研究室のルータである Yamaha FWX120 に接続されている。このとき、AP と有線接続しているパケットキャプチャ用 PC において tcpdump コマンドを実行し、有線 LAN インターフェースを経由してインターネットへと各デバイスが通信する様子をパケットキャプチャした。トラフィック分析のための評価指標として、パケットサイズ、パケット到着時間間隔、プロトコルの種類に注目して調査した。

4-2 実験結果

(1) パケットサイズ

表 2 に各アプリケーションにおける最頻パケットサイズを示す。表 2 より、動画や Web のリッチコンテンツにおいて最頻パケットサイズは 1300~1400[byte]と大きく全体の 40%以上を占めている一方、IoT デバイスの場合は 100~200 [byte]のパケットが全体の 60%以上を占めており、パケットサイズに大きな違いがあることがわかった。また、音声トラフィックでは、音楽の場合に Web トラフィックと類似したパケットサイズとなっており、通話の場合は全体の 90%以上が 100~300 [byte]であり小さなパケットが発生することがわかった。

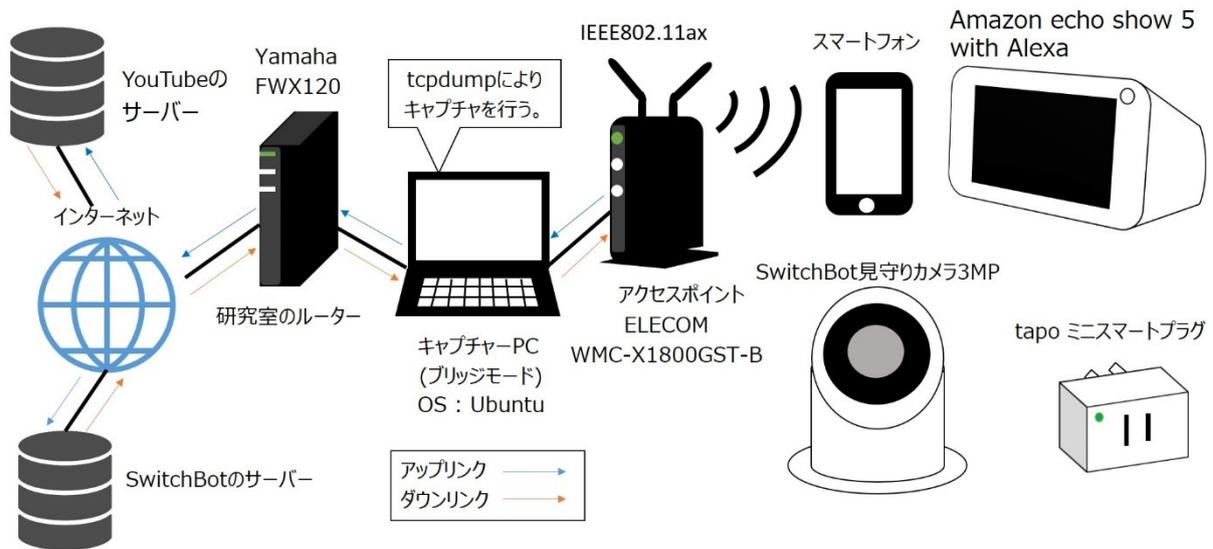


図 3 実験構成

(2) パケット到着時間間隔

表 3 に各アプリケーションにおけるパケット到着時間間隔の最頻値を示す。パケット到着時間間隔は、2つのパケット間の先頭ビットが到着した時刻の差分によって求めた。表 3 から、リッチコンテンツは大容量通信であり、ユーザの操作により通信が開始される。よって、通信開始時に大容量ファイルを構成するパケットが大量に発生することから、パケット到着時間間隔が 0.25 [msec]未満のものが全体の 50%以上となっていた。音楽トラフィックにおいても同様の傾向であった。一方、IoT や音声通話では短いものと長いものが混在していることがわかった。

(3) プロトコル

表 4 に各アプリケーションが使用するプロトコルの種類を示す。表 4 から、リアルタイム性を重視するアプリケーションには UDP、それ以外には TCP が主に使用されていることがわかった。また、リッチコンテンツや音声ではあるプロトコルの利用に偏る傾向があったが、IoT トラフィックでは様々なプロトコルが使用されており、その利用率に違いがあることがわかった。

以上より、動画、Web、IoT、音声のトラフィック特性に違いがあるが、Web と音楽は類似したトラフィック特性を有することがわかった。

5 機械学習を適用したリアルタイムなトラフィック推定

5-1 推定手法

本研究では、無線 LAN AP 上でトラフィックを推定し、推定結果を無線 LAN 上での帯域制御に活用することを想定している。よって、トラフィック推定では推定のリアルタイム性が重要である。そこで、トラフィックの一部からアプリケーションの種類を推定するために、4 章の実験において取得したトラフィックに基づいて、機械学習によるアプリケーションの推定を行った。

具体的には、本研究ではガウシアンナイーブベイズ分類器を用いて、スマートフォンや IoT デバイスなどの端末が通信を開始してから 1 秒間無線 LAN AP を通して送受信されるパケットをテストデータとした。このとき、トラフィックの送信方向として、端末からインターネットへ向かうアップリンク方向、インターネットから端末へ向かうダウンリンク方向のトラフィックを分けて、推定を実施した。

目的変数を動画、Web、IoT、音声の 4 クラスに設定し、説明変数として 4 章で実施した実験の評価指標であるパケットサイズ、パケット到着時間間隔、プロトコルの種類に加え、通信開始時からの受信バイト数を使用した。

表 2 各アプリケーションのパケットサイズ

アプリケーション	最頻パケットサイズ[byte]
動画	1300(全体の 40%以上)
Web	1400(全体の 40%以上)
IoT	100~200(全体の 60%以上)
音声	音楽では 1400(全体の 40%以上), 通話では 100~300(全体の 90%以上)

表 3 各アプリケーションのパケット到着時間間隔

アプリケーション	最頻到着時間間隔[ms]
動画	0.25(全体の 50%以上)
Web	0.25(全体の 70%以上)
IoT	0.25 以下と 20 以上が混在
音声	音楽では 0.25(全体の 50%以上), 通話ではまばら

表 4 各アプリケーションのプロトコルの種類

アプリケーション	累積 70%時のプロトコルの種類
動画	UDP, QUIC
Web	TCP
IoT	TCP, UDP, ICMP, MDNS, TLSv1.2 等
音声	音楽では TCP, 通話では UDP

次に、ガウシアンナイーブベイズの学習プロセスについて説明する。ガウシアンナイーブベイズではまず、式(1)から各クラスのサンプル数 $N(C_k)$ を用いて各クラスの事前確率 $P(C_k)$ を計算する。次に各クラス C_k ($k = 0, 1, 2, 3$) に属する各特徴の平均と分散からモデルを学習する。次に、未知データ x が与えられた場合に、 x があるクラスに属すると仮定して、学習で得た特徴の平均と分散からガウス分布の確率密度関数を算出し、式(2)から与えられた未知データが各クラスに属する事後確率を計算する。そして、最も高い事後確率を持つクラスを選択して推定を行う。本研究では各クラス 84 個、全部で 336 個のデータを用意し、全体の 7 割を教師データ、3 割をテストデータとしている。式(2)において x_i は未知データの特徴量、 μ_{ki} はクラス C_k に属する特徴量の平均、 σ_{ki}^2 は各クラス C_k に属する特徴量の分散である。各クラスの精度には適合率 (Precision, 式(3)) と再現率 (Recall, 式(4)) の調和平均を取った F-1 score (式(5)) を使用し、各クラスの精度の平均をモデル全体の精度と定義した。

$$P(C_k) = \frac{N(C_k)}{\sum_{k=0}^3 N(C_k)} \quad (1)$$

$$P(x|C_k) = P(C_k) \times \frac{1}{\sqrt{2\pi\sigma_{ki}^2}} e^{-\frac{(x_i - \mu_{ki})^2}{2\sigma_{ki}^2}} \quad (2)$$

$$Precision = \frac{TP}{TP + FP} \quad (3)$$

$$Recall = \frac{TP}{TP + FN} \quad (4)$$

$$\begin{aligned}
 F1\ score &= 2 * \frac{Precision * Recall}{Precision + Recall} \\
 &= \frac{2TP}{2TP + FP + FN} \quad (5)
 \end{aligned}$$

ここで、式(3)～(5)の各変数は以下の通り定義されている。

- ・ TP(True Positive, 真陽性): ポジティブサンプルに対して正しくポジティブと判定されたサンプル数
- ・ TN (True Negative, 真陰性): ネガティブサンプルに対して正しくネガティブと判定されたサンプル数
- ・ FP (False Positive, 偽陽性): ネガティブサンプルに対して誤ってポジティブと判定されたサンプル数
- ・ FN (False Negative, 偽陰性): ポジティブサンプルに対して誤ってネガティブと判定されたサンプル数

5-2 実験結果

5-1 節で説明したトラヒック推定を scikit-learn を用いて実施した。教師データとテストデータ共に、通信方向としてアップリンク、ダウンリンク、アップリンクとダウンリンクの両方向の packets を使用し、さらに、トラヒック特性として、packet size, packet arrival interval, protocol, 通信開始時からの受信バイト数を適用し、これらのトラヒック特性を組み合わせた場合も含めて合計 45 種類の説明変数による推定を実施し、各クラスの推定精度を求めた。

まず、通信方向による推定精度の影響を調査する。推定結果より、アップリンク通信では packet size + packet arrival interval + protocol の種類を組み合わせた場合、ダウンリンク通信では packet size + protocol の種類の組み合わせと、packet arrival interval + protocol の種類の組み合わせ、アップリンクとダウンリンク両方向の packets を使用した場合には、説明変数として packet size を適用した場合に最も高い精度を示した。

図 4 に、上記の説明変数の組み合わせと推定精度の関係を示す。図 4 からダウンリンクが最も精度が高くなっていることがわかる。これはアップリンクの packets のみの場合、ダウンリンクに比べてリッチコンテンツや音声の packet size が小さく、packet size においてトラヒック特性の違いが出にくく、精度が下がっていることが予想される。またアップリンクとダウンリンクの双方向の packets を使った場合、アップリンクとダウンリンクのトラヒック特性が大きく異なることが原因で精度が下がる。

次に、図 4 で最も精度が高いダウンリンク方向の packets のみに注目し、説明変数の個数と組み合わせに対する各クラスの推定精度を調査した。表 5 に、説明変数の個数と最も精度が高くなった組み合わせを示す。また、表 5 の説明変数の組み合わせを適用して推定した場合の、各クラスの推定精度を図 5 に示す。

図 5 より、最も良好な精度を示した説明変数の組み合わせは packet size + protocol の種類、もしくは、packet arrival interval + protocol の種類の 82.5% であり、最も精度が悪くなった組み合わせは、説明変数に受信バイト数を含む場合であった。このことから、説明変数の数は多ければ良いということではないこと、さらに、受信バイト数は説明変数として適切ではないことがわかった。さらに、packet size + protocol の種類、または packet arrival interval + protocol の種類の各クラスの精度を見ると、動画、Web、IoT は 80% 以上であり、比較的高い精度を得ることができていることがわかる。それに対し、音声のクラスは約 70% と他の 3 つに比べて若干精度が低くなっていた。この原因として、音声トラヒックである音楽は Web トラヒックの特性に似ていることが影響していると考えられる。

以上の結果から、通信開始時から 1 秒間のダウンリンク方向の packets のみを用い、説明変数として packet size, もしくは、packet arrival interval と protocol の種類を組み合わせたナイーブベイズ分類器の適用により、リッチコンテンツ、Web、IoT トラヒックのリアルタイムなトラヒック推定が可能であることを示した。一方で、音声トラヒック、特に音楽トラヒックについては、推定精度の向上が必要である。

表 5 説明変数の個数と組み合わせ

説明変数の個数	最も精度が高くなった説明変数の組み合わせ
1	パケットサイズ
2	パケットサイズ+プロトコルの種類
3	パケットサイズ+パケット到着時間間隔+プロトコルの種類
4	パケットサイズ+パケット到着時間間隔+プロトコルの種類+受信バイト数

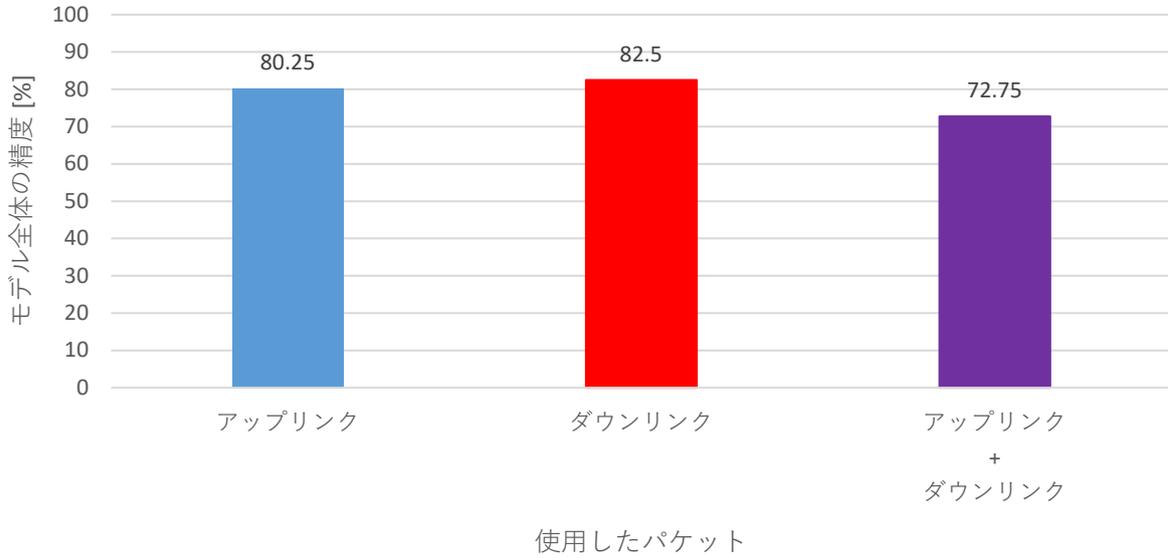


図 4 異なる通信方向のトラフィックを利用した場合のトラフィック推定精度

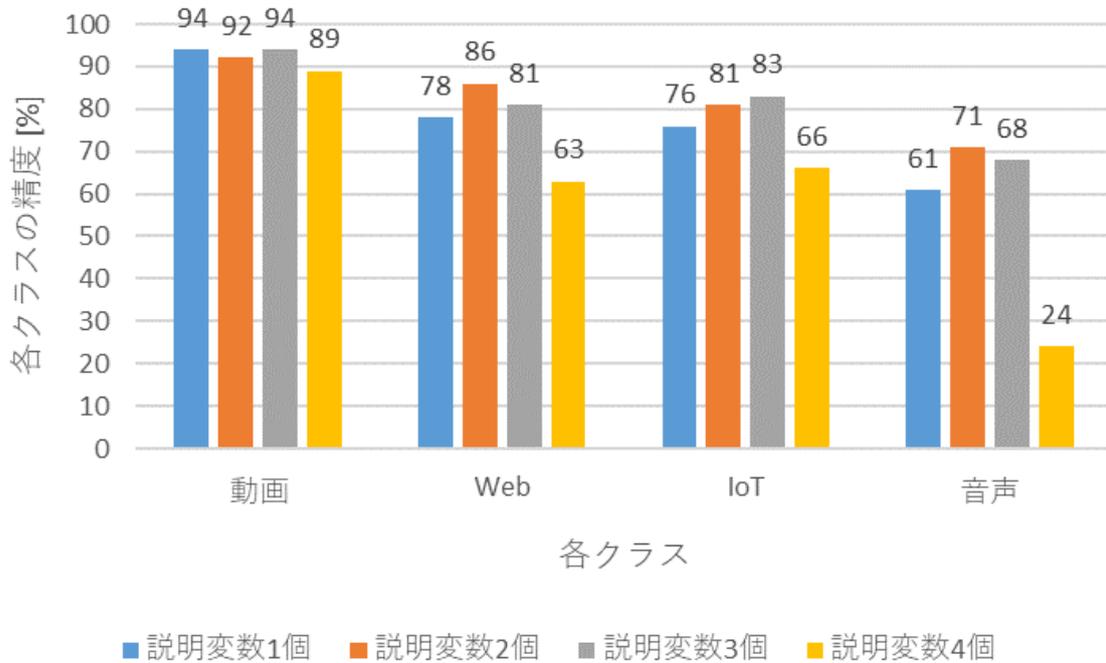


図 5 説明変数の数とモデル全体の推定精度 (ダウンリンク方向のパケットを用いた場合)

6 まとめ

本研究では、IoT デバイスの増加によって多様化する無線 LAN 上のトラフィック特性を調査するため、リッチコンテンツ、IoT、音声のトラフィック特性の違いについて、実機を使用した実験を通して調査した。さらに、無線 LAN AP 上でのトラフィック制御を目標としたリアルタイムなトラフィック推定が可能であるか明らかにするため、通信開始時の一部のパケットのみを用いた機械学習によるトラフィック推定を行った。

トラフィック特性の調査結果より、リッチコンテンツ、IoT トラフィック、音声（音楽と音声通話）トラフィックではパケットサイズ、パケット到着時間間隔、使用されるプロトコルに特徴があり、通信において発生する全パケットを用いる場合はルールベースでのトラフィック分類が可能である傾向にあることがわかった。

しかし、無線 LAN 上での帯域制御を考えた場合、一部のトラフィックからリアルタイムなトラフィック推定を行う必要があるため、実験で取得した一部のパケットのみを用いてガウシアンナイーブベイズ分類器による推定を行った。推定結果より、通信開始時から1秒間のダウンリンク通信のパケットのみを用いて、説明変数としてパケットサイズ+プロトコルの種類、もしくはパケット到着時間間隔+プロトコルの種類の組み合わせのとき、全体で約83%の精度を得ることができると示した。

以上のように、機械学習によるトラフィックの推定精度に加えて、教師データとして適切なパケットの通信方向と説明変数を明らかにすることができた。

【参考文献】

- [1] IoT 検定ユーザー教育推進ワーキンググループ, 「図解即戦力 IoT の仕組みと技術がこれ 1 冊でしっかりわかる教科書」, 技術評論社, 2020 年 3 月 7 日
- [2] 総務省 | 令和 4 年版 情報通信白書 | データ集 (第 3 章 関連データ), <https://www.soumu.go.jp/johotsusintokei/whitepaper/ja/r04/html/nf3r1000.html>, (参照 2024-1-8).
- [3] IEEE Standard for Information Technology--Telecommunications and Information Exchange between Systems Local and Metropolitan Area Networks--Specific Requirements Part 11: Wireless LAN Medium Access Control (MAC) and Physical Layer (PHY) Specifications Amendment 1: Enhancements for High-Efficiency WLAN,” in IEEE Std 802.11ax-2021 (Amendment to IEEE Std 802.11-2020), pp.1-767, May 2021, doi: 10.1109/IEEESTD.2021.9442429.
- [4] Tatsuya Oogami, Chiharu Nakashima, Hitomi Tamura, Daiki Nobayashi, Kazuya Tsukamoto, “Experimental Evaluation of Downlink OFDMA in IEEE 802.11ax Wireless LAN,” SAES2022, B-31, Dec.2022. “無線 LAN—CSMA/CA とは”, <https://www.infraexpert.com/study/wireless6.html>.
- [5] Jayavardhana Gubbi, Rajkumar Buyya, Slaven Marusic, Marimuthu Palaniswami, “Internet of Things (IoT): A vision, architectural elements, and future directions,” Future Generation Computer Systems, Volume 29, Issue 7, 2013, Pages 1645-1660, ISSN 0167-739X, <https://doi.org/10.1016/j.future.2013.01.010>.
- [6] Rajesh Palit, Kshirasagar Naik, Ajit Singh, “Anatomy of WiFi Access Traffic of Smartphones and Implications for Energy Saving Techniques,” International Journal of Energy, Information and Communications Vol. 3, Issue 1, Feb., 2012

〈発表資料〉

題名	掲載誌・学会名等	発表年月
IEEE 802.11ax 無線 LAN AP の通信手順と通信性能に関する性能評価	電子情報通信学会 2022 年 ソサイエティ大会, B-6-31	2022 年 9 月
IEEE 802.11ax 準拠の無線 LAN におけるダウンリンク OFDMA の評価実験	電子情報通信学会技術研究報告, vol. 122, no. 198, NS2022-88, pp. 33-38	2022 年 10 月
IEEE 802.11ax 準拠の無線 LAN におけるダウンリンク OFDMA の評価実験	電子情報通信学会 電子情報通信学会 超知性ネットワーキングに関する横断型研究会 (RISING 2022)	2022 年 10 月
未使用 AP によるビーコンが無線 LAN 通信性能に与える影響	電子情報通信学会 技術研究報告, IA2022-37, pp.1-7	2022 年 11 月
Experimental Evaluation of Downlink OFDMA in IEEE 802.11ax Wireless LAN	International Symposium on Applied Engineering and Science (SAES2022), B-31	2022 年 12 月
IoT 化が与える無線アクセストラフィック特性の調査	情報処理学会 火の国シンポジウム 2023	2023 年 3 月
Bluetooth 接続を行う IoT デバイスのトラフィック特性の調査	2023 年度電子情報通信学会九州支部学生会講演会	2023 年 9 月
Experimental Evaluation of Uplink Communication Performance in IEEE 802.11ax Wireless Local Area Network: OFDM vs. OFDMA	Advances in Intelligent Networking and Collaborative Systems. INCoS 2023. Lecture Notes on Data Engineering and Communications Technologies, vol 182. Springer	2023 年 9 月
Experimental Evaluation of Application Traffic Characteristics on WLANs in the IoT Era	Advances in Intelligent Networking and Collaborative Systems. INCoS 2023. Lecture Notes on Data Engineering and Communications Technologies, vol 182. Springer	2023 年 9 月
IEEE 802.11ax 無線 LAN におけるダウンリンク/アップリンク OFDMA 向けトラフィック制御手法の検討	電子情報通信学会 電子情報通信学会 超知性ネットワーキングに関する横断型研究会 (RISING2023)	2023 年 10 月