

画像解析と Wi-Fi プローブ要求による人数予測を併用した 店舗内における人流解析

Store Traffic Analysis Using Image and Wi-Fi Data

長久保 伊吹* 堀川 三好* 山口 翼* 岡本 東* 片桐 聡志† 岩澤 俊弥† 山口 修平‡
Ibuki Nagakubo Mitsuyoshi Horikawa Tsubasa Yamaguchi Azuma Okamoto Satoshi Katagiri
Shun'ya Iwasawa Shuhei Yamaguchi

1. はじめに

近年、公共施設や店舗内における人流解析として、カメラによる年齢・性別推定や人流把握を用いたマーケティング分析が導入されている。しかしながら、店舗内全域における人流把握は、カメラ設置台数が増えることによるコスト増加や処理負荷の増大が課題となっている。

本研究では、カメラによる画像解析と Wi-Fi 基地局で収集する Wi-Fi プローブ要求（以降、プローブ要求）を特徴量とした機械学習による滞在人数予測（以降、Wi-Fi 人数予測）を併用することで、店舗の人流解析を実現することを目的としている。その手法として、人流解析をする上で重要な場所となる店舗の出入り口や会計エリアで画像解析を用い、その他の場所では Wi-Fi 人数予測を用いることを提案する。その際、画像解析を行う一部の場所でプローブ要求を同時に収集し、プローブ要求から得られる特徴量を入力値、画像解析結果から得られる滞在人数を正解ラベルとした訓練データを生成することで、容易に店舗の客層に適応した Wi-Fi 人数予測モデルを構築する手法を開発する。本稿では、提案する Wi-Fi 人数予測モデルの構築方法の有効性を実店舗において検証した結果を報告する。

2. 関連研究

公共施設や店舗内における画像解析やセンシング技術を用いた人流解析の社会実装は進んでおり、特に、マーケティングへの活用事例は増えている。小売店舗におけるカメラを用いた画像分析の事例では、来店人数カウント、顧客属性分析、滞留時間分析および動線分析が多くみられる[1][2]。一方、プローブ要求を用いた人流解析は、来店者数予測や混雑状況把握等、安価に導入が可能なものの精度が低いため大雑把な分析に利用されている。

プローブ要求を用いた人流解析は、従来は MAC (Media Access Control) アドレスをキーとした手法が提案され、多くの実証実験が行われた[3][4]。しかしながら、セキュリティ強化やプライバシー保護の観点から MAC アドレスのランダム化が適用されたことで、従来手法の適用が困難になっている。そのため、近年ではプローブ要求から得られる特徴量を用いた機械学習による研究が取り組まれている[5][6]。多くの場合、プローブ要求を用いた人数予測は、正解データを正確に把握できないことが多く、クラスタリング手法による教師なし学習が適用される。例えば、先行研究[7]において、著者らはトンネル避難者検出を目的としたモバイル端末台数推定を、プローブ要求から得られる特徴量にクラスタリング手法を適用して実現した。

* 岩手県立大学 Iwate Prefectural University

† グローリー株式会社 GLORY Ltd.

‡ 株式会社東急ストア Tokyu Store Co., Ltd.

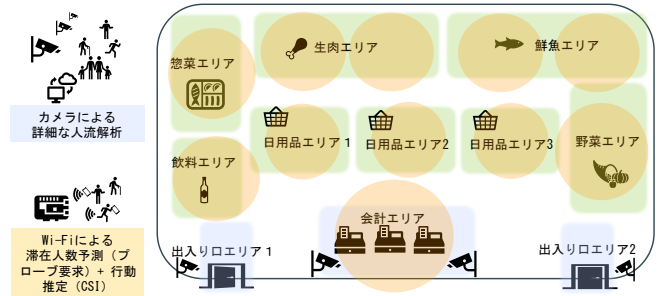


図 1 画像解析と Wi-Fi 人数予測による人流解析

3. 人流解析手法

3.1 提案手法の概要

提案手法では、カメラによる画像解析とプローブ要求による Wi-Fi 人数予測を併用することで、店舗の人流解析を行う（図 1）。Wi-Fi 人数予測は、プローブ要求から得られる特徴量と画像解析から得られる滞在人数を正解ラベルとした教師あり学習を適用することで、対象店舗の客層に適応した予測モデルを生成する。

図 1 の例では、POS レジが複数設置される会計エリアでカメラによる画像解析を行い、並行してプローブ要求の収集を行う。すなわち、会計エリアで収集されたデータから対象店舗の Wi-Fi 人数予測モデルを容易に生成し、他のエリアに同モデルを適用した Wi-Fi パケットキャプチャを設置することで、エリアごとの滞在人数予測を行う。エリア範囲については、プローブ要求の受信信号強度 (RSSI: Received Signal Strength Indicator) に閾値を設定することで管理する。また、各エリアでは、Wi-Fi 人数予測のみでなく CSI (Channel State Information) を用いた商品棚周辺の顧客の行動推定についても開発を進めているが、本稿では詳細を省略する。

3.2 カメラによる画像解析

設置カメラによる画像解析では、物体検出や物体追跡技術を用いて来店人数カウント、年齢・性別等の顧客属性分析および滞留時間の分析を行う。

来店人数カウントや滞留時間の算出には、店舗出入り口にカメラを設置する必要がある。来店人数カウントのみでなく、顧客の外観の特徴を取得することで入店時刻と出店時刻を把握し、滞留時間の算出が可能となる。顧客の属性分析は、会計エリアを対象に行うことが効果的と思われる。POS レジにおける購買データと紐付けることで、顧客属性と購買履歴を紐づけることが可能である。会計エリア

は、店舗において比較的滞留時間が長い傾向にあるため、プローブ要求の収集に適している。会計エリアに限定した滞在時間は、物体検出と物体追跡から得られる顧客ごとのエリア到着から離脱までの時間を用いて算出することができる。併せて、これを用いて一定期間の滞在人数が算出可能となる。

店舗における画像解析として、他にも動線分析や商品棚前の顧客行動を分析する事例がある。顧客属性を含めた動線分析を行うためには店舗に多くのカメラを設置する必要があるが、滞在人数の推移の把握だけであれば Wi-Fi 人数予測での代用が可能である。また、姿勢推定技術から骨格データを取得して顧客行動を推定する事例があるが、本研究ではより低コストで導入可能な Wi-Fi CSI を用いた行動推定を検討しているため取り上げない。

3.3 Wi-Fi 人数予測

店舗におけるプローブ要求は、顧客がモバイル端末を保持していた場合に、接続可能な Wi-Fi アクセスポイントを探すために送信する信号となる。その送信間隔は、端末仕様（Android/iPhone）や端末状態（アクティブ状態/スリープ状態）により大きく異なる。例えば、先行研究[7]の予備調査では、アクティブ状態において Android 端末の場合に5秒から15秒、iPhone の場合に10秒から30秒間隔で送信されていた。また、スリープ状態の場合は、数十秒から数分間隔で送信される。そのため、ある一定の期間で収集されるプローブ要求の特徴量から各エリアの滞在人数予測を行う必要がある。この一定期間を時間枠と呼び、Wi-Fi 人数予測の対象期間とする。本来、プローブ要求から予測可能なのはモバイル端末台数であるが、モバイル端末の保持比率、仕様構成および状態比率を含めて店舗特性として学習することで、時間枠ごとの滞在人数を予測する。以下に時間枠ごとに収集されたプローブ要求の特徴量算出方法と Wi-Fi 人数予測モデルの生成方法について述べる。

3.3.1 プローブ要求から取得する情報

プローブ要求には、プライバシー情報である MAC アドレスの他に多くの情報が含まれる。本稿では、表1に示す6つの情報を収集して、Wi-Fi 人数推定の特徴量として用いる。パケット長や HT Capability は、モバイル端末の製造仕様の仕様により一定の値を取る。一方、RSSI は時間経過とともに変化する。周波数はプローブ要求を観測する周波数帯に依存する。また、MAC アドレスは、ランダム化によ

表1 プローブ要求から得る情報

プローブ要求の情報	特徴	特徴量（統計量）
時間	プローブ要求を取得した時間を表す情報。	平均受信時間のばらつき
パケット長	プローブ要求のパケットの大きさを表す情報。 iOSとAndroidではパケット長の個数が異なり、iOSでは2~3種類、Androidでは3種類以上のパケット長が取得される。	パケット長の種類数
MACアドレス	Wi-Fi端末が利用可能なネットワークを検出するために送信する信号。 プライバシー保護のためMACアドレスをランダム化されている。	MACアドレスの種類数
RSSI	プローブ要求の受信信号強度を表す情報。 0~-128の範囲で取得可能であり、-30~-100の範囲が信頼できる値となっている。	RSSIの最大値 RSSIの最小値 RSSIの平均値
HT Capability	IEEE 802.11n規格で導入された高速伝送技術を表す情報。 最大帯域幅や最大スループット、最大変調方式などの情報を含んでおり、モバイル端末ごとに値が異なる。	HT Capabilityの種類数
周波数	プローブ要求が送信される周波数帯。	周波数の種類数

て一定間隔ごとにアドレスが切り替わる。端末仕様に依存するが、多くの端末では数秒間隔でアドレスが切り替わる。また、プライバシーに配慮するため、MAC アドレスはハッシュ化したものを収集する。

3.3.2 プローブ要求の特徴量変換

プローブ要求から得られる情報を、時間枠ごとに統計量として変換したものを、Wi-Fi 人数推定モデルの特徴量とする。表1・3列目に特徴量として用いる統計量を示す。本稿では、プローブ要求の総数、平均受信間隔のばらつき、RSSIの平均・最大・最小及びMACアドレス、パケット長、周波数、HT Capability に対するデータの種類の数を算出して特徴量とする。

3.3.3 Wi-Fi 人数予測モデル

各時間枠において、プローブ要求から得られる特徴量を入力値、カメラによる画像解析から得られる会計エリアの滞在人数を正解ラベルとした訓練データを生成する。正解ラベルについては、POS レジから得られる顧客数や他のセンサを用いた人数カウントを利用することが考えられるが、動線分析に必要な一定期間ごとの滞在人数を予測するために、画像解析から得られる滞在人数を用いる。本稿では、1次元の時系列データを扱う。そのため、学習モデルとして、以下の2つを比較する。

① CNN (Convolutional Neural Network)

このモデルは特徴量ごとの入力層、畳み込み層 (Conv 層) を2層、全結合層を3層で構成されている。活性化関数は、Conv 層では ReLU、全結合層では線形 (Linear) 関数を用いる。

② CNN-LSTM

CNN-LSTM は、各特徴量の特徴を抽出する CNN と時系列データの処理を行う LSTM を組み合わせたモデルである。このモデルは、Conv 層を2層、LSTM 層を1層、全結合層を2層で構成されている。活性化関数は Conv 層では ReLU、LSTM 層・全結合層は Linear を用いる。

4. 店舗における検証実験

4.1 実験概要

提案する人流解析手法における Wi-Fi 人数予測について検証実験を行った。検証実験は、グローリー株式会社と株式会社東急ストアで実施したリテールメディアの実証実験[8]の一部期間を利用して、東急ストア中目黒本店（以降、対象店舗）で実施した。検証実験では、対象店舗の会計エリアに Wi-Fi パケットキャプチャを1台設置し、2024年2月20日から2024年3月1日の11日間の営業時間である午前9時から午後12時のデータを収集した。

本稿では、プローブ要求とカメラから得られる情報を用いて Wi-Fi 人数予測が可能か検証することを目的に分析した結果について報告する。

4.2 データ収集方法および前処理

対象店舗の会計エリアでは、複数台の POS レジが並んでおり、レジ混雑解消を目的として複数の AI カメラを用いた会計エリア周辺の来店客の購買行動や混雑状況の分析を実施している[8]。本稿では、グローリー株式会社から AI カメラ分析による滞在人数データを提供いただき、正解ラベルとする。

また、Wi-Fi パケットキャプチャは、Raspberry Pi 4 に USB Wi-Fi 無線 LAN を装着したものを設置し、パケットキャプチャしたデータを Microsoft Azure IoT Hub を用いて 5 分間隔でクラウド上に送信することで取得する。

データの前処理として、収集したプローブ要求は、実験とは関係のない周辺のモバイル端末や機材のデータと識別するため、営業時間外に観測された同一の MAC アドレスを持つデータを除外した。

4.3 分析手順

時間枠については、プローブ要求の送信間隔を考慮して、0.5, 1, および 5 分の 3 水準を設定する。また、各学習モデルのハイパーパラメーターは、予備実験により決定する。例として、CNN-LSTM の場合は、バッチサイズを 128, エポック数を 300, Conv 層および LSTM 層のユニット数と隠れ層をそれぞれ 128 とした。CNN-LSTM における窓長は、3, 5 および 7 の 3 水準を用いる。

分析は、以下の手順で進める。

- ①プローブ要求数とカメラによる滞在人数の関係
- ②プローブ要求の日による影響
- ③学習モデルが Wi-Fi 人数推定に与える影響
- ④時間枠が Wi-Fi 人数推定に与える影響
- ⑤窓長が Wi-Fi 人数推定に与える影響

4.4 実験結果

4.4.1 プローブ要求数とカメラによる滞在人数の関係

図 2 に 2024/02/21 における 5 分間隔のプローブ要求数と滞在人数を示す。プローブ要求および滞在人数は、最小および最大値で正規化をして、0 から 1 で表示している。滞在人数が多い時に、プローブ要求数が多くなるのがわかる。

人流解析を行うにあたり、プローブ要求数がモバイル端末台数と相関が強いことは知られている[3][4]。一方で、モバイル端末の保持比率、仕様構成および状態比率を含めた滞在人数との相関については、明確な報告は見当たらない。そのため、プローブ要求数とカメラによる滞在人数の相関分析を行う。相関分析の際、エリア判定に用いるプローブ要求の RSSI 閾値による影響を調査する。RSSI の閾値は、-128, -90 から -30 までの +10 ずつ 8 水準を使用する[9]。2024/02/20 から 2024/02/26 までの 1 週間のデータに対して、時系列相関分析手法である相互相関分析を適用した結果を図 3 に示す。時間枠が 1 分の場合は相関係数が低くなるものの、時間枠が 5 分以上の場合は相関係数が高い傾向が見られた。また、今回の実験においてカメラを設置した会計エリアにおいては、RSSI が -70dBm 以上になると相関係数が減少した。設置時の予備実験では、POS レジの中央付近にパケットキャプチャを設置しており、最も離れた POS レ




図 2 プローブ要求数と滞在人数の関係

ジ付近のモバイル端末の RSSI は約 -80dBm であった。そのため、会計エリアの RSSI 閾値は -80dBm が妥当であると考察される。

4.4.2 プローブ要求数の日による影響

Wi-Fi 人数予測を実施するにあたり、学習モデルを曜日ごとに生成、平日と休日を分けて生成、日に関わらず 1 つのモデルとして生成等を検討する必要がある。そのため、日ごとのプローブ要求数同士の相関分析を行う。RSSI の閾値を -80dBm に設定した結果を表 2 に示す。窓長が 1 分の場合は相関係数が低いことがわかるが、窓長が 5 分以上の場合は相関係数が高い傾向が見られた。その際、土・日曜日は、若干相関係数が低くなるものの、対象期間のデータを用いて 1 つの Wi-Fi 人数予測モデルを構築することとした。

4.4.3 学習モデルが Wi-Fi 人数推定に与える影響

これまでの検証から、時間枠を 5 分、RSSI 閾値を -80dBm と設定し、学習モデルによる予測誤差を検証する。すなわち、時間枠ごとに取得されるプローブ要求の 9 つの特徴量を入力値、予測人数を出力値とする時系列回帰モデルを構築した。また、構築したモデルの損失関数には平均二乗誤差 (MSE)、予測性能の評価に平均絶対誤差 (MAE) を平均滞在人数で除した相対平均絶対誤差 (RMAE) を用いる。2024/02/20 から 2024/02/28 までのデータを学習データ、2024/02/29 のデータを検証データ、2024/03/01 のデータをテストデータに分割して Wi-Fi 人数予測モデルの精度検証を行った。カメラによる滞在人数予測と Wi-Fi 人数予測モデル (CNN および CNN-LSTM) の予測結果の比較を図 4、CNN-LSTM の学習曲線を図 5 に示す。カメラを用いて推定された滞在人数の増減に追従はしているものの、予測誤差が大きいことがわかる。

4.4.4 時間枠が Wi-Fi 人数予測に与える影響

表 3 に時間枠が Wi-Fi 人数予測に与える影響を示す。CNN と CNN-LSTM (窓長 5) において比較をしている。いずれの時間枠の場合も CNN および CNN-LSTM に大きな精度差は生じておらず、時間枠が大きい場合に RMAE が小さ




図 3 プローブ要求数と滞在人数の相関関係

表 2 プローブ要求数の日毎の相関関係

1分ごとのバケット数の相関						
	2024/2/20	2024/2/21	2024/2/22	2024/2/23	2024/2/24	2024/2/25
2024/2/20	1.00	0.67	0.68	0.75	0.70	0.74
2024/2/21	0.67	1.00	0.65	0.71	0.66	0.71
2024/2/22	0.68	0.65	1.00	0.71	0.67	0.71
2024/2/23	0.75	0.71	0.71	1.00	0.73	0.78
2024/2/24	0.70	0.66	0.67	0.73	1.00	0.75
2024/2/25	0.74	0.71	0.71	0.78	0.75	1.00
2024/2/26	0.70	0.70	0.69	0.72	0.68	0.72

5分ごとのバケット数の相関						
	2024/2/20	2024/2/21	2024/2/22	2024/2/23	2024/2/24	2024/2/25
2024/2/20	1.00	0.87	0.88	0.91	0.88	0.89
2024/2/21	0.87	1.00	0.87	0.89	0.88	0.87
2024/2/22	0.89	0.87	1.00	0.89	0.88	0.87
2024/2/23	0.91	0.89	0.89	1.00	0.90	0.92
2024/2/24	0.88	0.88	0.88	0.90	1.00	0.90
2024/2/25	0.89	0.87	0.87	0.92	0.90	1.00
2024/2/26	0.89	0.87	0.87	0.88	0.87	0.87




図4 滞在人数の予測結果




図5 CNN-LSTMモデルの学習曲線

表3 Wi-Fi 人数予測の時間枠による影響

時間枠	CNN (相対平均絶対誤差)	CNN-LSTM (相対平均絶対誤差)
0.5分	0.4630	0.4611
1分	0.3969	0.3963
5分	0.3376	0.3445

表4 Wi-Fi 人数予測の窓長による影響

窓長	CNN-LSTM (相対平均絶対誤差)
3	0.4003
5	0.3932
7	0.3934

くなる。また、時間枠が大きい場合に比して、小さい場合にCNN-LSTMのRMAEがCNNより小さくなる。会計エリアの平均滞在時間とプローブ要求の送信間隔を考慮すると、時間枠が長い場合には、時系列を考慮する必要がないものの、時間枠が短い、すなわち、即時性高くWi-Fi人数予測を実施する必要がある場合は、時系列を考慮したモデルが必要となる。しかしながら、プローブ要求の平均受信間隔やカメラ滞在人数との相関関係から、短い時間枠で即時性高く滞在人数を推定するには、カメラとWi-Fi人数推定の精度を更に高めていく必要があると考察される。

4.4.5 窓長がWi-Fi人数予測に与える影響

表4にCNN-LSTMにおいて窓長がWi-Fi人数予測に与える影響を示す。時間枠が1分の場合における窓長3, 5, 7

の場合の比較をしている。今回の実験では、窓長においても大きな差は生じていない。特に、窓長5および7についてはRMAEにほとんど差がないことがわかる。これは、対象店舗にて11日間収集したデータにおける人の滞在時間は平均24秒、最大279秒のため、時間枠1分の場合、窓長5以上は予測精度に影響しないためだと考察される。すなわち、窓長は、時間枠との関係の他に、対象場所における滞在時間を考慮する必要がある。

5. おわりに

本研究では、カメラによる画像解析とプローブ要求によるWi-Fi人数予測を併用することで、店舗の人流解析を行う手法を提案した。Wi-Fi人数予測は、プローブ要求から得られる特徴量と画像解析から得られる滞在人数を正解ラベルとした教師あり学習を適用することで、対象店舗の客層に適応した予測モデルが構築可能であることを示した。しかしながら、現状における予測精度は十分なものとは言えないため、プローブ要求の他情報の利用や統計量変換の方法の検討、予測モデルの再構築、カメラによる滞在人数推定精度の向上を行う必要がある。また、主要エリアで構築したWi-Fi人数予測システムを他のエリアで利用可能かを検証する必要がある。これらの課題解決のための技術開発を行いながら、実証実験を行い、カメラによる画像解析とWi-Fi人数予測を併用した導入の容易な店舗の人流解析を実現していく予定である。

謝辞

実験のためのフィールドをご提供いただいた東急ストア様およびカメラによる人数推定データという貴重なデータをご提供いただいたグローリー様に感謝いたします。

参考文献

- [1] ABEJA, "ABEJA INSIGHT for Retail", 株式会社 ABEJA, <https://www.abejainc.com/insight-retail-main>, (最終閲覧日 2024/05/16)
- [2] PLATEAU by MLIT, "異なるモニタリング技術の併用による人流解析", 日本電気株式会社, <https://www.mlit.go.jp/plateau/use-case/uc20-006/> (最終閲覧日 2024/05/16).
- [3] 玉田 拓, 豊木 博泰, 渡辺喜道, "Wi-Fi プローブパケットと目視データを用いた公園内の訪問者流動推定手法と効果的なセンサ配置の検討", FIT2020, O-014 (2020).
- [4] 中田 恵史, 岡本 東, 堀川 三好, "無線LANにおけるプローブ要求を用いた混雑度推定", IPSJ SIG Technical Report, Vol.2018-MBL-87, No.1 (2018).
- [5] 金子 俊之, 松下 雅典, 森谷 武浩, 齋藤 育門, "Wi-Fiパケットセンサーデータを活用した公共空間の面的な人流解析", 第57回土木計画学研究発表会・講演集, 02-08, 2018 (2018).
- [6] Cai, Yuyi, *et al.* "MAC address randomization tolerant crowd monitoring system using Wi-Fi packets." Proceedings of the 16th Asian Internet Engineering Conference. 2021 (2021).
- [7] 長久保 伊吹, 堀川 三好, 岡本 東, 堀川 真伸, 松浦 弘治, "濃煙トンネル空間における避難誘導を目的としたモバイル端末台数推定手法の提案", FIT2023, CM-005 (2023).
- [8] グローリー株式会社ニュースリリース, "グローリーと東急ストアがリテールメディア事業の実証実験を開始", 2023/12/25, <https://www.glory.co.jp/company/news/detail/id=2285> (最終閲覧日 2024/5/29)
- [9] Bravenec, Tomáš, *et al.* "UJI probes: Dataset of Wi-Fi probe requests." 2023 13th International Conference on Indoor Positioning and Indoor Navigation (IPIN). IEEE, 2023.