

BLEの時系列RSSIに基づく人流クラスタを使用した 移動方向と人数の推定

後藤 逸兵^{1,a)} 上田 健太郎^{1,b)} 松田 裕貴^{1,2,c)} 諏訪 博彦^{1,2,d)} 安本 慶一^{1,2,e)}

概要: 都市計画や商業施設の最適化に際し、人流解析は不可欠である。現在、カメラベースの人流解析手法が広く採用されているが、これに伴う高いコストやプライバシーの問題が浮き彫りになっている。これらの問題を解決する新たなアプローチとして、BLE (Bluetooth Low Energy) を活用した手法が多数提案されている。しかし、多くの先行研究は空間の混雑度に重点を置いており、移動方向の分析は十分に行われていない。本研究では、移動方向を捉えるために2台のBLEセンサを用いた移動方向(上向き、下向き)を考慮した通行量推定手法を提案する。提案手法では、2台のセンサから得られる時系列データを基に、データ間の差分を作成しクラスタリングを行い、各クラスタに所属するBLEアドレス数を特徴量として通行量を推定する。本手法の有効性を評価するため、大阪府の御堂筋で実験を行い、5分単位の通行量の評価を行なった。その結果、クラスタリングを用いた提案手法では、上向き・下向き・全体の通行量に対してそれぞれ平均絶対誤差 20.8, 16.3, 22.9 で推定できることを示した。

キーワード: Bluetooth Low Energy (BLE), 人流推定, IoT, スマートシティ, 機械学習

Estimation of movement direction and number of people using human flow clusters based on BLE time-series RSSI

1. はじめに

都市空間における人々の移動方向や人数に関する情報(論文中では、歩行者通行量と呼ぶ)を分析することは、交通施策、安全対策、商業戦略などの立案に重要である。交通施策としては、交通インフラの最適化や、新しい交通手段の策定に活用できる。安全対策としては、混雑や危険な状況を察知することで、適切な誘導や警備員の配置を実現できる。商業戦略としては、潜在的顧客を推定することに活用でき、店舗出店計画などに役立てることができる。しかし、人が目視で、人流を分析することは、多大なコストがかかるという問題がある。そこで、都市空間に設置したセンサを用いて自動的に人流を分析するための手法が多く開発されている。

リアルタイムに特定の範囲の人流を推定する手法としては、カメラを用いた手法が多く提案されている[1-4]。カメラベースの手法では、画像処理技術を用いて、人を認識し、その数を直接カウンティングする。しかし、全てのカメラベースの手法は、プライバシーの問題を持っているため、都市空間で設置するのは、不適切である。さらには、設置コストや設置場所、オクルージョンといった様々な問題も内包している。

プライバシーの問題を回避する手法として、BLE (Bluetooth Low Energy) や Wi-Fi などの無線信号を用いた混雑度・人流推定手法が提唱されている[5-12,12-18]。これらの手法ではユーザが所持するデバイスが発する無線信号情報を用いて、人々の密度や人流の推定を行っている。無線信号を用いた手法は、画像情報を用いないため、画像情報に含まれるプライバシーの問題を回避し、人流の分析を行う。しかし、ほとんどの無線信号を用いる既存研究で提案される分析フレームワークは、特定範囲に存在する群衆のカウンティングのみに焦点を当てている。このような研究は、群衆の移動方向とその人数という重要な情報を無視

¹ 奈良先端科学技術大学院大学, Ikoma, Nara 630-0192, Japan

² 理化学研究所

a) goto.ippei.gi4@is.naist.jp

b) ueda.kentaro.ug2@is.naist.jp

c) yukimat@is.naist.jp

d) h-suwa@is.naist.jp

e) yasumoto@is.naist.jp

しており、人流に関するより詳細な分析への道を閉ざしている。

そこで、我々は、プライバシーの問題を回避し、歩行者の移動方向とその人数（歩行者通行量）を把握するための新たな通行量推定フレームワークを提案する。我々の推定フレームワークは、センシング機構と推定機構の二つの機構で構成される。センシング機構では、街路設置した二つの BLE スキャナを用いて歩行者の所持するデバイスが発する BLE 信号を取得する。2つのスキャナは、同時刻帯に同一デバイスの発する信号をそれぞれ取得するため、より詳細な分析を可能とする。スキャナで取得された信号情報は、クラウドに送信され、推定機構で利用される。推定機構では、取得した BLE 情報から、歩行者通行量の推定を行う。センシング機構で取得された、同時刻帯に同一デバイスの発する信号は、信号の欠損や正規化などの前処理を受けた後、差分信号情報に変換される。差分信号情報は、クラスタリングされ、歩行者通行パターンの抽出に使用される。これは、人々の通行はいくつかのパターンに分類されるという直感に基づいている。抽出されたパターンは集計され、歩行者通行量推定を行うための機械学習モデルの学習と予測に使用される。

本手法の有効性を確かめるために、日本の大阪市の御堂筋で実証実験を行った。収集されたデータから推定した上向きの通行量の MAE は 20.8, 下向きの通行量の MAE は 16.3, 全体の通行量の MAE は 22.9 であった。本稿の貢献は以下の 2 点である。

- (1) 我々は、BLE を用いて歩行者の移動方向とその人数を推定するための新たなフレームワークを開発した。2 台のセンサから同時刻に得られる 2 つの情報は歩行者のリッチなコンテキストを提供しており、差分信号情報とクラスタリングを通して、歩行者パターンを抽出するために使用される。
- (2) 一般の歩行者で構成される実環境下で提案フレームワークのパフォーマンスを評価した。評価の結果、提案フレームワークが歩行者通行量の把握のための強力な手法となることを示した。

本研究の構成は次のとおりである。2 章では関連研究について説明し、3 章ではデータ収集方法と、差分データの作成方法、クラスタリングの手法について説明を行う。4 章では結果と考察について説明を行い、5 章では本研究の結論を述べ、今後の課題をまとめる。

2. 関連研究

2.1 カメラベースの人流推定

歩行者の移動方向推定に関するカメラ利用の研究は、都市交通、スマートビル、小売業など多岐にわたる分野で行われている。Liu らは、異なる受容野サイズの特徴を融合し、その重要性を学習する新たな群衆密度推定のディープ

アーキテクチャを提案している [1]。ただし、カメラの位置によってはオクルージョンが発生するため、設置場所が限定される。

オクルージョンの問題を解決するため、Zhang らは、複数のカメラを配置することで、単一カメラでは捉えられない人々の動きを把握するアプローチを提案している [2]。Pandy らは、ドローンに取り付けたカメラで群衆の正投影を撮影し、オクルージョンやスケーリングの影響を軽減する手法の提案をしている [3]。しかしこれらの手法は、複数台のカメラやドローンを必要とするため、設置コストの問題が発生する。また、いずれの手法もプライバシー侵害の恐れがある。

プライバシーに配慮するために、Wang らは、トップビューの ToF カメラを利用した深度画像をもとに、迅速な人体検出および人流推定技術を提案している [4]。ToF カメラは、深度情報のみを取得するため、従来の RGB カメラと比較してプライバシーが守られる利点がある。ただし、ToF カメラは外部の光に影響されやすく、特定の位置に設置する必要があるという制約がある。

2.2 BLE, Wi-Fi を使用した混雑度・人流推定

カメラベースの人流推定手法は数多く提案されているが、プライバシーの侵害や設置コスト、設置場所の制約などの課題がある。この課題を解決する手法として、BLE (Bluetooth Low Energy) や Wi-Fi などのワイヤレス技術を用いた推定手法が提案されている [5-9, 16, 17]。BLE (Bluetooth Low Energy) や Wi-Fi などの無線技術を用いることで、プライバシーの侵害や設置場所の制約の問題を軽減できる。BLE や Wi-Fi の電波情報には、BLE アドレスや MAC アドレスなどのアドレス情報は含まれているが、これらの情報は直ちには個人情報には結びつかない。また、電波は反射、透過などの性質を持っているため、オクルージョンの問題を解決でき、設置場所の制約を軽減できる。

前川らは、Bluetooth を用いて車両レベルの列車の混雑度の推定を行っている [6] Weppner らは携帯電話を使って Bluetooth デバイスをスキャンすることで、群衆密度を推定する手法の提案を行なっている [5]。これらの研究では、混雑度を 2 段階または 7 段階に設定し、分類問題として混雑度推定を行っており、詳細な人数推定は行っていない。

松田らは、公共施設や飲食店といった異なる空間サイズを持つ場所で、BLE の電波受信状況を活用し、来客数を推定するモデルを構築している [7]。類似した手法で、金光らや Taya らは、バスや電車に BLE センサを設置し乗客人数の推定を行っている [8, 9]。これらの研究では、特定の場所に滞留している人数の推定を行っており、移動する人々は対象にしていない。

群衆の移動に関する研究としては、空港やバスターミナル、イベント会場、大学のキャンパスを対象に、複数ス

表 1: この研究の位置付け

手法	プライバシー リスク	設置 コスト	設置位置の 制限	歩行者計測の 解像度	移動 方向	エリアの 解像度	
カメラベース [1-4]	高い	高い	厳格	精密	考慮	精密	
ワイヤレス ベース	混雑推定 [5,6]	低い	低い	緩い	粗い	考慮せず	精密
	人数推定 [7-9]	低い	低い	緩い	精密	考慮せず	精密
	群衆の移動 [10-14]	低い	低い	緩い	粗い	考慮	粗い
	提案手法	低い	低い	緩い	精密	考慮	精密

ポットに Wi-Fi と Bluetooth センサを設置し、各スポットでセンサから得られるデバイスの MAC アドレスなどから、人々の移動の向きやスピードを推定する研究がなされている [10-14]。これらの研究では、複数のスポット間の移動に着目しており、各地点における歩行者の移動方向を考慮しているわけではない。

北里らは、BLE スキャナを持っている歩行者が、すれ違う歩行者の BLE 信号を取得することで、その相対速度を推定する手法を提案している。室内における実験結果は、すれ違う歩行者の速度を推定できることを明らかにしている。しかしこの手法では、BLE スキャナ自体が移動していることが前提であり、特定のスポットの通行量とその方向を推定する手法としては適していない。

2.3 既存研究の課題と本研究のアプローチ

表 1 に既存研究と本研究の特徴を整理する。カメラベースの手法は、特定の場所における移動方向を考慮した通行量推定が可能であり、現実社会でも活用されている一方で、プライバシーの侵害や設置コスト、設置場所の制約などの課題がある。BLE や Wi-Fi を使用した既存手法は、これらの課題を解決できるものの、それぞれ課題がある。

前川らや Weppner らの混雑度推定手法は、特定の場所の混雑度は推定できるものの、詳細な人数推定や移動方向は考慮できていない [5,6]。松田、金光、田谷らの BLE アドレスを数える手法は、特定のエリアに滞留している人の詳細な数値を推定できるものの、移動については考慮できていない [7-9]。Kurkcü らなどの群衆の移動に関する手法は、スポット間の移動などのある程度広範囲における移動方向や人数を考慮しているものの、特定の場所における移動方向を考慮した通行量推定は実現できていない [10-14]。

本研究では、これらのすべての課題を解決するために、特定のエリアにおける移動方向を考慮した通行量推定手法を提案する。具体的には、2 台の BLE センサを数十メートルの距離で設置し、センサ間の差分データをクラスタリングすることで歩行者の移動パターンを抽出する。抽出された歩行者の移動パターンを特徴量として用いることで、移動方向を考慮した通行量推定を試みる。次章で提案手法について詳細を述べる。

3. 提案手法

3.1 システムの概要

図 1 では、提案手法の全体的な概要を示している。このシステムは主に「センシング機構」と「推定機構」の二つの部分で構成される。「センシング機構」において、BLE センサを 2 台使用することにより、移動方向を考慮するための時差付き BLE データを収集する。2 台のセンサがキャッチした BLE データは、定期的にクラウド環境へ送信し保存する。「推定機構」では、収集した BLE データから各アドレス毎の差分を計算し、それをもとに BD アドレスのクラスタリングを実施する。このクラスタリングは特定の時間単位で実施し、その結果を集計して移動方向の特徴として使用する。各機構の詳細を次に述べる。

3.2 センシング機構

センシング機構では BLE センサを用いて BLE データを取得する。BLE センサを使用する際に取得できる主要な情報は、BD アドレスと RSSI の 2 つである。BD アドレスは Bluetooth 対応デバイスを一意に識別するためのアドレスで、全 48 ビットの情報から成る。このアドレスは、デバイス同士が通信を行う際、それぞれのデバイスを特定する役割を果たす。しかしスマートフォンなどの個人が利用するデバイスにおいては、ユーザーのプライバシーを保護する目的で、一定の時間経過後に自動的にアドレスが変化する設計となっている。RSSI (Received Signal Strength Indicator) は受信した電波の強度を示す指標である。具体的には、デバイスとセンサの間で交換される電波の強度を数値で示す。この数値は、デバイスとセンサとの物理的な距離に関連し、2 つが近づくと数値は大きくなる傾向がある。逆に距離が離れると数値は小さくなる。これを利用して、デバイスの位置や距離をおおまかに推定することが可能である。

本研究では、BLE センサを利用して移動方向の推定を試みる。具体的には、2 台の BLE センサを直線上に設置し、それらのセンサ間で BD アドレス毎に RSSI の時間変化を観察する。図 2 に BLE センサを 2 台設置した際の RSSI の時間変化が示す。例えば、もし歩行者が図 1 の左から右

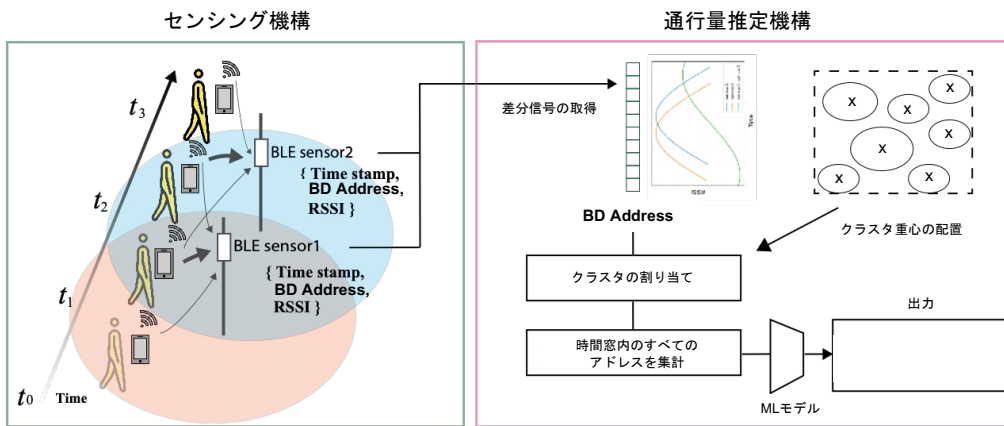
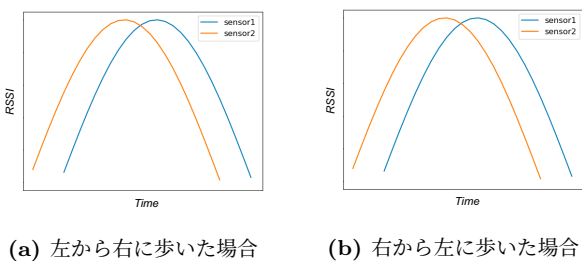
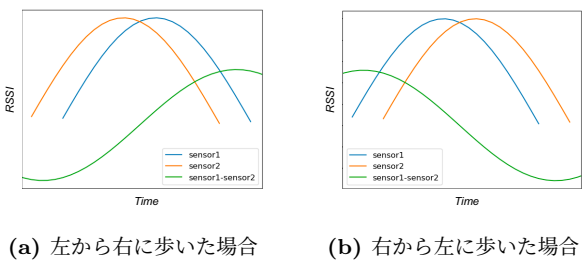


図 1: システムの概要図



(a) 左から右に歩いた場合 (b) 右から左に歩いた場合

図 2: 各センサごとの RSSI の時間経過のイメージ



(a) 左から右に歩いた場合 (b) 右から左に歩いた場合

図 3: 差分信号のイメージ

に向かって歩行する場合、物理的な位置関係から考えると、RSSI はデバイスとセンサとの距離が近づくとその数値が大きくなる特性があるのでセンサ 2 で先に BLE 信号が検出されるはずである。したがって、時系列的な RSSI の変化を観察すると、図 2 (a) に示されるように、センサ 2 で先に信号が大きくなり、その後センサ 1 の信号が大きくなることが確認できる。逆に、被験者が図 1 の右から左に向かって歩行する場合、センサ 1 での信号が先に検出される。図 2 (b) に示すように、センサ 1 での信号の変化がセンサ 2 よりも先行していることが確認できる。

本研究では 2 台のセンサ間での RSSI の差分を計算し、その差分から移動方向の特徴を捉える手法を提案する。具体的には、図 3 に示されているように、歩行の方向に応じて 2 台のセンサでの RSSI の変動が逆転することを利用している。もし歩行の方向が逆であれば、図中の緑色で表される差分信号が逆方向になることが期待され、その変動をもとに歩行方向の特定が可能となると考えられる。

3.3 推定機構

人々の動きは複雑で、その予測は難しい。歩行速度の違い、突然の停止、方向転換などの日常的な動きの変動がその主な理由である。さらに、センサが収集するデータには、人の動きと関係のないノイズや外部干渉も混入する。この問題への対策として、本研究は k -means クラスタリングを用いて、歩行のパターンを明確にする方法を導入する。 k -means クラスタリングの通常の距離指標は Euclid 距離である。しかし、Euclid 距離はデータ間の直線的な距離を計算するので、一定の速度やタイミングでの動きを前提としており、実際の人々の動きのような変動や非線形性を十分に捉えることが難しい。このため、時系列データの特性をより活かすために、 k -means のメトリックに Dynamic Time Warping (DTW) を手法として採用する。DTW は、時系列データ間の非線形な時間ずれも考慮した距離計算方法であり、伸縮性を持つため異なる速度やタイミングでの動作も類似として捉えることが可能である。この手法の利点は、一定の時間枠でセンシングされた信号をグループ化することで、正確ではないものの、人の歩行パターンをおおまかに反映したクラスタを生成できる点にある。

生成された各クラスタの人数を使用することで、移動方向を考慮した通行量推定を行う。通行量推定には、機械学習を用いる。BLE デバイスを持つ人は限られており、また、一人当たりのデバイス数も一定ではない。このバリエーションを補完するために、機械学習を導入している。特徴量としては、センサから取得したアドレスのユニーク数と、先ほど作成した各クラスタの割合を使用している。

4. 実験

4.1 実験概要

提案手法の有効性を検証するために、大阪府にある御堂筋でデータ収集・通行量推定実験を実施した。データ収集は 2022 年 10 月 18 日から 24 日までの一週間にわたり行われた。図 4 に示されているように、BLE センサとカメラ



図 4: 設置図



図 5: 映像の一部

を組み合わせた装置を、歩道に対して直線上に配置されている街路灯に取り付けてデータ収集を行った。センサ間の距離は約 30 m である。10 月 18 日から 23 日の 6 日間にわたり、さまざまな時間帯で 1 時間ごとに 5 分毎の通行量のラベリングを合計 24 時間分行った。

これにより、BLE センサが収集したデータと実際の通行量の動きを照らし合わせ、比較・分析することを可能としている。計測に使用したデバイスは、Bluetooth 5.0 をサポートする Bluetooth モジュールを内蔵している。このモジュールは、周辺の BLE データをキャッチし、そのデータをモバイル回線を通じて定期的にクラウドに送信・保存する。なお、データのスキューンは 15 秒ごとに自動的に行われるよう設定しており、デバイスの制約上、一回のスキューンで取得できるデータの上限は 100 件となっている。

4.2 通行量の測定

本研究における通行量の測定について説明する。図 5 には、実際にカメラで取得した映像の一部を示している。こ

の画像内に特定の位置に設定された赤線が確認できる。本研究では、この赤線を基準にして人々の移動方向を判定する。具体的には、5 分間の観察期間中に赤線を映像の下側から上側へと越えた人数を“上向きの通行量”として定義している。一方で、赤線を映像の上側から下側へと越えた人数は、“下向きの通行量”としてカウントされる。そして、これら二つの方向の通行量を合計を“全体の通行量”とする。本研究のデータ収集手法において、1 時間を 1 セッションとして定義し、この 1 セッションをさらに 5 分間の区切りで分割してデータ収集を行っている。その結果、1 セッションには合計 12 サンプルの通行量データが得られることとなる。

すべての時間に対してビデオを確認してアノテーションするには、人的コストが大きすぎるため、1 日 4 時間ずつランダムに選択して、アノテーションを行っている。これを 6 日間のデータに対して行い、24 セッション（合計 24 時間分）のデータを作成している。

1 サンプル（5 分間）における通行量の最大、最小、平均はそれぞれ、上向きの通行量は、256 人、1 人、75.5 人、下向きの通行量は 286 人、3 人、81.8 人、全体の通行量は、491 人、10 人、157.2 人となっている。

4.3 データ処理

データの処理方法について説明する。収集した BLE データ（時間、BD アドレス、RSSI）を、様々な行動パターンに分類するために、 k -means アルゴリズムを用いてクラスタリングを行う。クラスタリングのためのメトリックとしては DTW を提案しているが、比較対象として Euclid 距離を用いた場合の結果も示す。本実験では、クラスタリングを用いない場合、クラスタリングのメトリックとして Euclid 距離を用いる場合、クラスタリングのメトリックとして DTW を用いる場合の 3 種類について結果を示す。

クラスタの数、すなわち k -means における k の値は 7 に設定している。この値はエルボー法により決定している。クラスタリングするためのデータセットとして、ラベリングされていない 10 月 24 日のデータを用いている。

機械学習モデルは、その汎用性と高い予測性能から、ランダムフォレストを採用している。ランダムフォレストは、多数の決定木を組み合わせることで、高い精度と安定性を持つモデルとして知られている。このモデルを用いて、回帰分類を行っている。

4.4 評価

評価は、上向きの通行量、下向きの通行量、通行量の全体を対象に、5 分ごとのデータを取得・分析する。この短い時間単位での分析により、詳細な動向や変動を効果的に捉えることができる。本研究では、提案手法の有効性を確認するため、特定のクラスタの特徴量を使用する場合と使

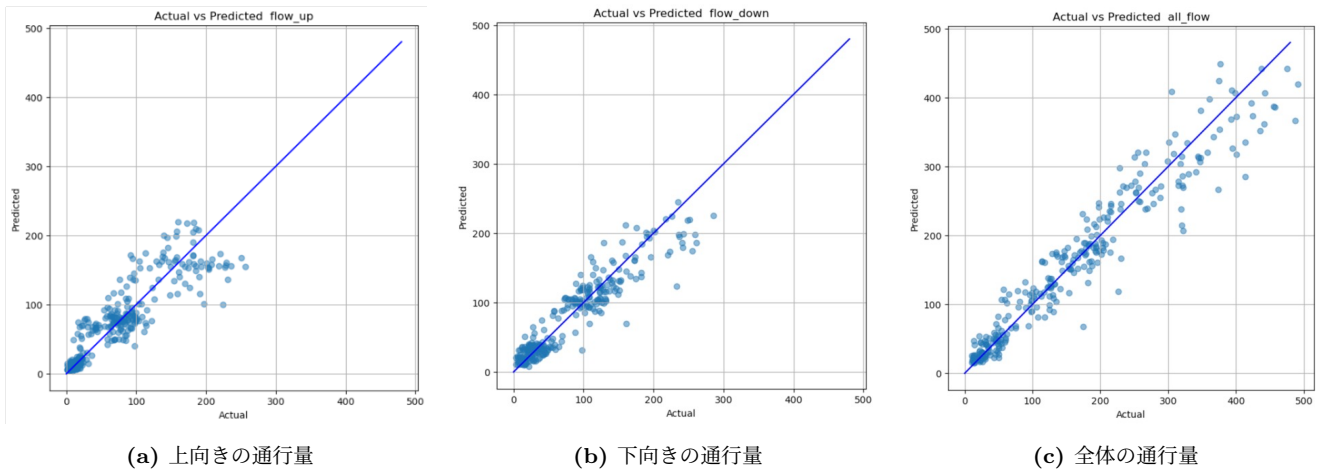


図 6: メトリックに DTW を用いた場合の結果

用しない場合で比較を行う。この比較により、特徴量の利用が結果にどれほど影響するかを明確にする。データセットに関しては、1 時間ごとのデータを一つのグループとして扱い、それを基に「Leave One Session Out 交差検証」を用いて評価する。この手法を利用することで、各時間帯の特性を網羅的に考慮しながら、全体の傾向を正確に分析することができる。最終的な評価指標として、MAE (平均絶対誤差)、RMSE (平方根平均二乗誤差)、MAPE (平均絶対パーセンテージ誤差)、CORR (相関係数) の 4 つを選択した。MAE (平均絶対誤差) は、実際の値と予測値の差の絶対値の平均を示す指標であり、小さいほど予測の正確さが高いと評価される。具体的に、MAE が 1 減少すると、それは平均で 1 人の予測誤差が改善されることを意味する。RMSE は予測誤差の平均を示す指標であり、予測値と実際の値の差を二乗した後に平均を取り、さらに平方根をとったものである。小さいほどモデルの予測精度が高いと評価される。MAPE は実際の値に対する予測誤差のパーセンテージを示すもので、予測が実際の値からどれだけかのパーセンテージでズレているかを示す指標である。CORR は予測値と実際の値の相関を示すもので、+1 は完全な正の相関、0 は相関なし、-1 は完全な負の相関を意味する。

5. 結果と考察

5.1 クラスタリングの効果

表 2 に通行量推定の結果を示す。表中の太字は最も優れた手法を示すものである。クラスタリングを使用した結果、MAE, RMSE, MAPE の値が改善される傾向が見られる。具体的には、全体の方向での MAE は 23.9 (クラスタリングなし) から 22.9 (DTW 使用) に、上向きの方角での MAE は 23.8 から 20.8 に、下向きの方角での MAE は 17.7 から 16.3 にそれぞれ減少している。これは、作成した歩行クラスタが歩行パターンを表現することで予測の精度が向上することを示唆している。

表 2: 通行量の推定の結果

方向	評価指標	クラスタリング		
		なし	Euclid	DTW
上向き	MAE	23.8	21.3	20.8
	RMSE	27.5	24.4	24.0
	MAPE	0.59	0.59	0.55
	CORR	0.85	0.89	0.89
下向き	MAE	17.7	16.7	16.3
	RMSE	21.3	20.2	19.5
	MAPE	0.38	0.36	0.37
	CORR	0.93	0.93	0.94
全体	MAE	23.9	23.8	22.9
	RMSE	29.4	28.7	28.0
	MAPE	0.22	0.23	0.22
	CORR	0.96	0.96	0.96

5.2 DTW の効果

DTW を使用すると、ほとんどのケースで Euclid よりも優れた結果が得られる。全体の方向での MAE は Euclid の 23.8 に対し、DTW では 22.9 となっており、上向きの方角では 21.3 から 20.8、下向きの方角では 16.7 から 16.3 へと改善している。このことから、時系列データに適した DTW は Euclid よりも通行量の推定において適したメトリックであるといえる。図 6 に DTW (Dynamic Time Warping) を使用した際の結果を詳しく示している。横軸に正解値、縦軸に予測値を配置しプロットしているの、点が対角線近くに分布していれば、予測が正解に近いことを意味する。全体、上向き、下向きの通行量ともに人数の傾向を捉えられていることがわかる。

6. おわりに

本研究では、移動方向を考慮した通行量推定を可能するために BLE センサを 2 台使用し、センサデータの差分から歩行クラスタの作成を行い、クラスタをもとに機械学習で通行量の推定を行う手法を提案した。その有効性を検証す

るため、大阪府の御堂筋での実験を実施した結果、クラスタリングのメトリックにDTWを採用した方法が最も高い精度で通行量を推定できることが確認された。具体的には、上向きの通行量で20.8, 下向きの通行量で16.3, 全体の通行量で22.9のMAEで推定可能であった。この結果は、都市部の混雑度を判断し、警備員の配置や歩行者ナビゲーションに十分適用できると考えられる。

将来的な展望として、提案された手法を4つのセンサへの適用を考察中であり、これにより上下左右の4方向における通行量の高精度な計測が実現可能となることを目指している。さらに、ドメイン適応技術の採用を通じて、多様な環境や空間での適用を柔軟に行うことが期待される。また、教師なし自己学習(SSL)を利用することで、未ラベルのセンサデータの効果的な活用法についても研究を進めている。リミテーションとして、本手法が極端な混雑、例えば災害発生時などの異常事態において超大人数の通行量に対応できるかは不明である。こういった異常事態をシミュレートすることも今後の課題である。

参考文献

- [1] Weizhe Liu, Mathieu Salzmann, and Pascal Fua. Context-Aware Crowd Counting. In *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, CVPR'19, pp. 5094–5103, 2019.
- [2] Qi Zhang, Wei Lin, and Antoni B. Chan. Cross-View Cross-Scene Multi-View Crowd Counting. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, CVPR'21, pp. 557–567, 2021.
- [3] Navjot Singh Anurag Pandey, Mayank Pandey and Abha Trivedi. KUMBH MELA: a case study for dense crowd counting and modeling. *Multimedia Tools and Applications*, Vol. 79, pp. 17837–17858, 2020.
- [4] Weihang Wang, Peilin Liu, Rendong Ying, Jun Wang, Jiuchao Qian, Jialu Jia, and Jiefeng Gao. A High-Computational Efficiency Human Detection and Flow Estimation Method Based on TOF Measurements. *Sensors*, Vol. 19, No. 3, 2019.
- [5] Jens Weppner and Paul Lukowicz. Bluetooth based collaborative crowd density estimation with mobile phones. In *2013 IEEE International Conference on Pervasive Computing and Communications (PerCom)*, pp. 193–200, 2013.
- [6] Yuki Maekawa, Akira Uchiyama, Hirozumi Yamaguchi, and Teruo Higashino. Car-level congestion and position estimation for railway trips using mobile phones. In *Proceedings of the 2014 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, UbiComp '14, p. 939–950, New York, NY, USA, 2014. Association for Computing Machinery.
- [7] Yuki Matsuda, Kentaro Ueda, Eigo Taya, Hirohiko Suwa, and Keiichi Yasumoto. BLECE: BLE-Based Crowdedness Estimation Method for Restaurants and Public Facilities. In *The 14th International Conference on Mobile Computing and Ubiquitous Networking*, ICMU'23, pp. 1–6, 2023.
- [8] Yuji Kanamitsu, Eigo Taya, Koki Tachibana, Yugo Nakamura, Yuki Matsuda, Hirohiko Suwa, and Keiichi Yasumoto. Estimating Congestion in a Fixed-Route Bus by Using BLE Signals. *Sensors*, Vol. 22, No. 3, 2022.
- [9] Eigo Taya, Yuji Kanamitsu, Koki Tachibana, Yugo Nakamura, Yuki Matsuda, Hirohiko Suwa, and Keiichi Yasumoto. Estimating congestion in train cars by using ble signals. In *2022 2nd Workshop on Data-Driven and Intelligent Cyber-Physical Systems for Smart Cities Workshop (DI-CPS)*, pp. 1–7, May 2022.
- [10] Abdullah Kurkcu and Kaan Ozbay. Estimating Pedestrian Densities, Wait Times and Flows using Wi-Fi and Bluetooth Sensors. *Transportation Research Record Journal of the Transportation Research Board*, Vol. 2644, pp. 72–82, 2017.
- [11] Lorenz Schauer, Martin Werner, and Philipp Marcus. Estimating Crowd Densities and Pedestrian Flows Using Wi-Fi and Bluetooth. In *11th International Conference on Mobile and Ubiquitous Systems: Computing, Networking and Services*, MOBIQUITOUS'14, 2014.
- [12] Asad Lesani and Luis Miranda-Moreno. Development and testing of a real-time wifi-bluetooth system for pedestrian network monitoring, classification, and data extrapolation. *IEEE Transactions on Intelligent Transportation Systems*, Vol. 20, No. 4, pp. 1484–1496, 2019.
- [13] Yuren Zhou, Billy Pik Lik Lau, Zann Koh, Chau Yuen, and Benny Kai Kiat Ng. Understanding Crowd Behaviors in a Social Event by Passive WiFi Sensing and Data Mining. *IEEE Internet of Things Journal*, Vol. 7, No. 5, pp. 4442–4454, 2020.
- [14] Xi Yang, Suining He, Bing Wang, and Mahan Tabatabaie. Spatio-temporal graph attention embedding for joint crowd flow and transition predictions: A wi-fi-based mobility case study. *Proc. ACM Interact. Mob. Wearable Ubiquitous Technol.*, Vol. 5, No. 4, dec 2022.
- [15] Tomoya Kitazato, Masaki Ito, and Kaoru Sezaki. A Study of the Detection of Pedestrian Flow Using Bluetooth Low Energy. In *2018 IEEE International Conference on Pervasive Computing and Communications Workshops*, PerCom'18 Workshops, pp. 716–721, 2018.
- [16] Utkarsh Singh, Jean-François Determe, François Horlin, and Philippe De Doncker. Crowd forecasting based on wifi sensors and lstm neural networks. *IEEE Transactions on Instrumentation and Measurement*, Vol. 69, No. 9, pp. 6121–6131, 2020.
- [17] Hyuckjin Choi, Manato Fujimoto, Tomokazu Matsui, Shinya Misaki, and Keiichi Yasumoto. Wi-CaL: WiFi Sensing and Machine Learning Based Device-Free Crowd Counting and Localization. *IEEE Access*, Vol. 10, pp. 24395–24410, 2022.
- [18] Akira Tokuda, Yutaka Arakawa, Shigeru Takano, and Shigemi Ishida. Automatic Parameter Adjustment for Hybrid WiFi and BLE-based Congestion Measurement. In *2021 Thirteenth International Conference on Mobile Computing and Ubiquitous Network*, ICMU'21, pp. 1–6, 2021.