

清掃工場における気圧差・LPWA RSSIを用いたエリア推定

松永 拓也¹ 新 佑太郎² 新井 イスマイル¹ 川端 馨² 垣内 正年¹ 遠藤 新¹ 藤川 和利¹

概要: 清掃工場では人員削減が進んでおり, 作業員の不慮の事故の際に迅速に対応するため, 管理者が作業員の位置把握をする必要があり, 屋内測位システムに対する需要がある. 一般的な居住スペースでは無線インフラからの信号を利用した測位が広く用いられるが, 清掃工場では直接適用することが難しい. 我々は先行研究において磁気フィンガープリントを用いた測位精度について検証した. 結果として, 測位精度が課題であり, 測位対象面積のさらなる縮小によって, 測位精度向上が見込まれている. 本研究では, 測位対象面積を縮小するため, 清掃工場内をより細分化されたエリアとして定義し, エリア推定の可能性について検証を行った. 清掃工場では炉室とそれ以外の部屋で部屋の構造が異なるため, 気圧特性や電波伝搬特性に特徴が生じ, 同一階層を部屋によって細分化可能であると考えた. 本研究では, 気圧差と4台のLow Power Wide Area Network (LPWA) 基地局からの Received signal strength indication (RSSI) を用いて建物全体をどの程度の広さのエリアへ分割できるかを検証した結果, 平均面積 2035 m² のエリアへ分割できた. また, 実験により, 同一の高さであっても炉室とそれ以外の部屋で気圧の平均値が異なることを確認した.

Area Estimation Using Barometric Pressure Difference and LPWA RSSI in an Incineration Plant

TAKUYA MATSUNAGA¹ YUTARO ATARASHI² ISMAIL ARAI¹ KAORU KAWABATA²
MASATOSHI KAKIUCHI¹ ARATA ENDO¹ KAZUTOSHI FUJIKAWA¹

1. はじめに

人が労働する環境を構築する際, 労働者の安全を第一に考慮する必要がある. 例えば, オフィスのように一般的な居住スペースであれば, 人間が快適に過ごせるように室温が調整されており, 日本の真夏日であっても空調設備などを用いて調節することで, 安全に労働できる. 対して, 工場などでは生産設備の都合上, 人間にとって過酷な労働環境となる場合がある. 例として, 人間の排出したゴミを処理する清掃工場は, 施設内部の焼却炉でゴミを焼却するため, 焼却炉のある部屋(炉室)は非常に高温になる. そのような高温の部屋における長時間作業は熱中症などの症状を引き起こす可能性がある. このような人間にとって厳しい環境下で, 設備のメンテナンスを作業員が直接行う必要のある施設においては, 安全に施設を運営するために管理者が作業員の安全管理を徹底する必要がある.

清掃工場における安全管理のために, 管理者は作業員の位置をリアルタイムに把握する必要がある. 清掃工場では, 定期的なメンテナンスや清掃で作業員が炉室と呼ばれる空間へ直接出向き作業する. その際, 作業員の位置がリアルタイムに分かると, より安全・効率的に作業できる. 例えば, 安全管理として, 作業員が建物内で転落や熱中症などにより身動きが取れなくなった場合でも, リアルタイムに作業員の位置を把握できていれば, 搜索する時間を短縮し, より迅速に救出できる.

我々の研究では, 清掃工場の一つである石川北部 RDF センターを実験フィールドとし, 清掃工場において利用可能な屋内測位手法について研究を行っている. 石川北部 RDF センターは, 廃棄物から生成される Refused-derived Fuel (RDF) とよばれる燃料を焼却し発生する熱エネルギーで発電することにより, エネルギーの回収を行っている. 建物内部には, 炉室(図1)と呼ばれる, 燃料を焼却する設備が配置されている広大な部屋(水平方向 32 m × 40 m, 鉛直方向 25 m 以上)があり, その周辺には「誘引

¹ 奈良先端科学技術大学院大学

² 日立造船株式会社



図 1: 石川北部 RDF センターの炉室内部

通風機室」や「高圧電気室」等の炉室と比べて小さな部屋が複数あり、ゴミ処理や発電に必要な機材が設置されている。特に炉室に関しては、一般的なオフィスやアパートの部屋のような居住スペースとは構造が異なっている。一般的な居住スペースでは、部屋ごとに床面、壁面、天井面が存在するのに対して、炉室は最下位階層の床面から、建物の天井まで、巨大な一つの空間となっている。対して、炉室以外の部屋は、一般的な居住スペースのように1階層内で収まっている部屋や、高さのある構造物を格納するため、数階層にまたがって縦方向に空間を共有している部屋などが存在する。炉室内部では、周辺の部屋の階層に沿って、グレーチングと呼ばれる格子状の金属構造材で床面が構成され、炉などの機材が設置されている。グレーチングは階層全体にわたって床面として敷き詰められているのではなく、機材の設置位置、及びそれらの機材のメンテナンス用通路として、空間の一部に設置されている。以上のように、清掃工場は巨大な空間の中で構造物によって空中に階層が構築されているため、一般的な居住環境とは磁気特性、気圧特性や電波伝搬特性が異なる可能性がある。

我々の先行研究 [1] においては、清掃工場での磁気フィンガープリントを用いた地点推定について検証した。気圧差を用いて階層は分離可能と仮定し、1階層内での測位精度について評価した。しかし、測位精度は十分ではなく、測位精度向上のため、測位対象面積の縮小が必要である。本研究では、清掃工場において気圧差と LPWA RSSI を用いて、屋内測位の適用範囲を複数のエリアに細分化できるかを検討した。最下位層と計測地点間の気圧差と4台の LPWA 基地局からの RSSI を説明変数、エリアを目的変数とする分類器を構築した。階層を境にエリアを分割した場合、分類器が出力した上位2エリアを抽出することで、100%の推定精度を得た。また、階層に加えて炉室か炉室以外の部屋かを境にエリアを分割した場合、上位3エリアを抽出することで100%の推定精度を得た。

2. 関連研究

多くの屋内測位手法は、地点毎に取得できる計測値を用いて、未知の地点にて測位する。屋内測位手法は、その測位に用いる計測値として、特定の設備から得られる計測値を利用する場合と、自然現象から得られる計測値を利用する場合に分けられる。特定の設備から得られる計測値を利用する場合は、その設備が屋内測位専用となるのか、もしくは本来の目的に加え屋内測位でも二次利用可能か、で更に二分できる。

まず、測位に利用される設備としては、Wi-Fi や Bluetooth Low Energy (BLE) のアクセスポイントなどの無線設備が挙げられる。無線通信の特性として、無線通信する基地局と端末間の距離が離れるにつれ、受信信号強度が減衰する特性がある。この信号強度は端末側から取得可能であり、RSSI として取得できる。Local Area Network (LAN) を無線にて構築する際に利用される Wi-Fi は、現在広く使われている無線インフラの一つである。Wi-Fi アクセスポイントは固定設置されることが多いため、特定のアクセスポイントからの RSSI を計測することによって、地点毎の特徴を得ることができ、その特徴を元に測位する手法が多く利用されている [2][3][4]。近年では商業施設などにおいて公共の Wi-Fi アクセスポイントが設置されていることも多いため、通信の需要がある空間において屋内測位する場合に、Wi-Fi RSSI を用いた手法が用いられることが多い。

BLE も屋内測位に利用される [5][6][7]。BLE も Wi-Fi と同様に RSSI を測位へ利用できる。BLE の利点として、Wi-Fi に比べて低消費電力で測位システムを実現でき、かつ Wi-Fi と同様にスマートフォンなどで通信できるため、ユーザーが簡単に利用できる。欠点として、BLE ビーコンを屋内にて整備することは一般的では無いため、二次利用ではなく測位システムのために整備する必要がある。

LPWA は、Wi-Fi、BLE よりも長距離通信する目的で利用される無線規格である。Wi-Fi、BLE の使用周波数が 5GHz 帯や 2.4 GHz 帯であるのに対して、LPWA は 920 MHz と、より低い周波数帯を利用する。無線の特性として、周波数が低いほど障害物を回り込んで到達できるようになる。よって、LPWA は 2.4GHz 帯を利用する無線規格と比較し、より長距離の通信できる。LPWA はその特性から、主に屋外測位での利用が検討されている [8][9][10]。また、近年ではアパートを対象とした LPWA を用いた屋内測位も研究されている [11]。しかし、清掃工場のように、隣接するフロア同士で一つの広大な屋内空間を共有し、多数の機器が配置されている環境ではまだ検証されていない。

次に、自然現象から得られる信号を用いて屋内測位する手法について述べる。屋内にて建物に付随する設備無しに

利用できる特徴量としては、気圧と磁気を用いた手法が挙げられる。まず気圧は高さに応じて変動する特性から、屋内測位においては階層の推定に利用される [12][13][14][15]。これらの研究はオフィスビルや駅、空港を対象としている。対して、清掃工場では十分に検証されていない。

屋内において、磁気は任意の地点において安定していることが知られており、その特性から測位に利用できる [1][16][17][18][19]。建物の鉄製の構造物に残留磁気が保持されることにより、地点毎に磁気の特徴が生まれ、地点を推定できる。我々の先行研究では、石川北部 RDF センターにおける磁気を用いた測位精度について検証した [1]。この検証では、計測地点毎に計測した磁気から、その地点の磁気フィンガープリントのデータセットを作成し、未知地点にて計測した磁気と磁気フィンガープリントデータセットと照合することで地点推定した。その結果、1階層内における測位誤差の中央値が 9.16 m と大きく、測位精度の向上が必要であると分かった。測位誤差が大きくなる理由としては、Ouyang ら [17] も示すように、磁気フィンガープリントによる地点推定では、特徴量が磁気 3 軸と少ないため、推定対象エリアが広がるほど磁気フィンガープリントが複数箇所で一致してしまう可能性が高くなるためである。石川北部 RDF センターにおける測位精度向上のため、移動経路を考慮した先行研究 [16] では測位誤差が 0.05 m へ減少した。しかし、移動経路情報を考慮するため、一度正解とは異なる経路として判定すると以後の測位精度に大きく影響するという欠点がある。

また、地磁気によるフィンガープリントの測位対象面積を縮小するため、先行研究 [20] ではフィールドに存在する Wi-Fi の各アクセスポイントの観測状況に応じて測位対象面積を減少させる手法について検討した。

3. LPWA と気圧差によるエリア推定の提案

本研究では、我々の先行研究 [1] と同じフィールドを対象として、地点推定の対象エリアを狭める手法を提案する。対象エリアを狭めることができれば、類似した特徴を持つ磁気フィンガープリントが複数地点において出現する可能性が減るため、測位精度の向上に繋がると考える。本研究では、未知の地点において計測されたセンサデータを元に、計測された地点のエリアを推定することをエリア推定と定義する。

提案手法では、清掃工場で計測したセンサデータセットを用いて、気圧差と LPWA RSSI を説明変数、エリアを目的変数とした分類器を作成し、分類器が出力する上位 n エリアの合計をエリア推定結果とする。提案手法のデータフローを図 2 に示す。一般的に、機械学習における分類器は 1 インスタンスに対して推論を行い、目的変数の各クラスへ属する確率を算出し、そのうち確率が最大のクラス 1 つを推論結果として抽出する手法が広く用いられる。対して

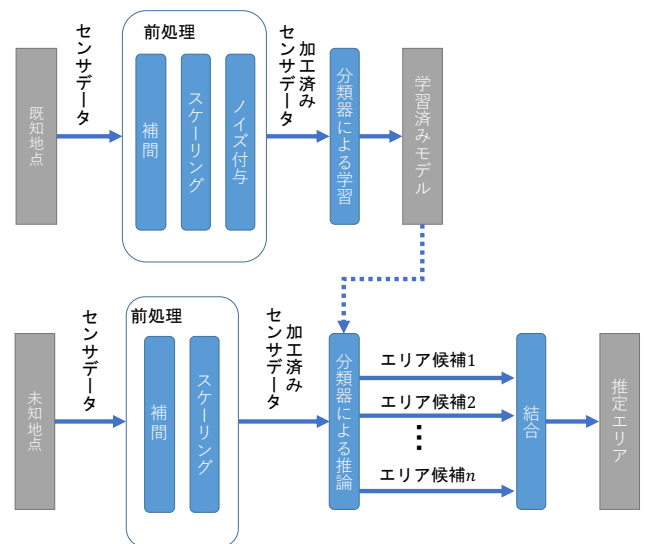


図 2: 提案手法のデータフロー

提案手法では確率が最大の 1 クラスだけではなく、所属確率が高い順に n クラスを抽出し、エリア候補として出力する。エリア推定によって縮小されたエリア内に、正解地点が含まれていなければ地点推定の精度が低下するため、エリア推定の出力には必ず正解エリアが含まれている必要がある。先行研究 [1] において、気圧を説明変数、階層を目的変数として線形回帰モデルを学習し、1 クラスを出力した場合の正解率は 0.895 だった。よって、エリア分割条件を階層とした場合に正解率が 1.0 となる分類は難しいと考えたため、分類器の推論結果の上位 n クラスを許容することで、目的変数のエリア粒度よりも大きな粒度でのエリア出力を可能にした。

まず、説明変数の一つに LPWA RSSI を選択した理由は、LPWA が清掃工場における需要を低コストで満たすことのできる通信インフラとして導入が検討されているためである。作業員の異常を炉室から管理者へ通知するためには、炉室全体をカバーした通信インフラの整備が必要である。石川北部 RDF センターの通信インフラの整備状況としては、Wi-Fi が整備されているが、炉室全体はカバーできていない。Wi-Fi によって清掃工場の建物全体をカバーするためには基地局を追加で多数設置する必要があり、コスト面から導入が難しい。また、現状では Wi-Fi によって実現されるような高速なネットワークが必要とされていない。対して LPWA は Wi-Fi や BLE よりも低速ではあるが、長距離通信が可能であるため、より低コストでの炉室全体のカバーが可能であることから、導入が検討されている。先行研究 [20] によって、無線基地局を用いて測位対象エリアを絞り込み、磁気フィンガープリントによる測位精度を向上できることが示されており、また Kim らによる先行研究 [11] においても、900 MHz 帯の無線通信規格を用いた屋内測位可能性を示しているため、本研究では測位に利用する特徴量の 1 つとして LPWA RSSI を採用する。

表 1: エリア分割の条件とデータセットの内容

エリア分割 ID	分割条件
エリア条件 1	階層
エリア条件 2	階層 + 炉室か炉室以外か

加えて、説明変数として気圧を選択した理由は、清掃工場内の 1 階層の中には、高さの異なる床面が多数存在していることから、階層以上に細分化できる可能性があるためである。また、Kaji らが示すように [21]、数 10 cm の高さの変化であっても、スマートフォンの気圧センサにより気圧変動として検出可能であることが期待できるため、1 階層内で高さが異なる床面を気圧差から識別できることが期待できる。そして、清掃工場は炉室と呼ばれる吹き抜けの広大な空間と、それ以外の小さな部屋によって構成されている。密閉された部屋では、同一の高さであっても部屋ごとに気圧特性が異なることから、気圧による部屋の識別が期待できる。気圧と高さには線形関係があるため、階層推定は回帰問題として解くことも可能だが、本研究では前述したように、同一の高さであっても部屋ごとの異なる気圧特性を持つことを考慮し、階層推定も分類問題として解決する。

エリア分割の条件を表 1 に示す。エリア条件 1 においては、1 つの階層を 1 つのエリアとして定義した。気圧を用いた先行研究において、気圧による階層推定は一般的な課題であるため、当フィールドにおいても検証する。対して、エリア条件 2 では、「階層」に加えて「炉室か炉室以外の部屋か」という条件を付与した。これにより、1 階層内に 2 種類の空間（炉室、炉室以外の部屋）が存在する場合、1 種類の空間（炉室のみ）が存在する場合がある。炉室かそれ以外の部屋かという条件づけの根拠として、以下の仮説を設定した。

- 気圧差の観点において、広大な空間である炉室とそれ以外の個々の部屋間で、異なる気圧特性を持っている。よって、フロアが同一であっても、炉室かそれ以外かは判別可能である。
- LPWA RSSI の観点において、炉室は開けた空間であるため、壁面や床面、天井に囲われた個々の部屋に比べて電波が長距離まで届く。炉室内外での異なる電波減衰によって計測地点での RSSI に特徴が生まれ、炉室の判別に影響を与える。

以上の仮説より、気圧差と LPWA RSSI によって、測定地点は炉室かそれ以外の部屋かを識別可能であると考えた。

エリア推定に用いる分類器は複数の機械学習手法にて比較する。先行研究 [1] では、線形回帰を用いて気圧差と高さの関係を算出し、階層推定を行った。本研究では、前述したように、階層内での線形関係にない特徴を元にしたエリア分類が期待できるため、線形回帰より複雑な特徴を学習できる決定木やニューラルネットワークを用いた手法

を採用する。決定木ベースの手法として Random Forest、ニューラルネットワークを用いた手法として Multi Layer Perceptron、回帰ベースの手法として Logistic Regression を選択し、それぞれのモデルによる分類結果を比較することによって、エリア推定に適している機械学習手法について検討する。

4. 実地実験

本章では、実験に用いたデータセット、実験方法、および実験結果について示す。実験は 1 章にて示した石川北部 RDF センターにて行った。本研究においては、「階層」と「フロア」の 2 つの高さを示す単語を定義する。石川北部 RDF センターは高さ毎に図面が存在する。本研究における「階層」は、建物の図面 1 枚に記載されている高さとする。そして、実際の 1 階層の中には、多数の高さの異なる床面が存在する。それらの床面を「フロア」と定義する。よって、1 つの階層の中に複数のフロアが存在しており、階層とフロアの高さが一致するフロア、及び一致しないフロアがある。データセットに含まれる階層及びフロアの高さを表 2 に示す。

4.1 データセット

石川北部 RDF センターにて計測された 2 種類のデータセット（同一フロア歩行データセット、地点データセット）について説明する。

同一フロア歩行データセットは、同一フロアを歩行した場合の気圧変化を検証する目的で、2021 年 8 月 23 日に収集した。収集したデータは、歩行ルート及び定点観測地点の気圧である。気圧計測に用いたスマートフォンを表 4 (a) に示す。計測者は Android スマートフォンを胸のあたりで保持し、フロア内を一定速度で歩き回り、フロア内の気圧を計測した。1 回の計測時の移動範囲を 1 フロアへ制約するため、計測者は階段や段差などを超えず、同一の高さのフロアを可能な範囲で満遍なく歩行した。計測者は手元に地図を所持しており、歩行ルートを地図へ記録した。以後この計測者が同一フロアを歩行した一回の計測を計測回と呼ぶ。計測回に対する正解ラベル（フロアの高さ）は、計測者の記録した歩行ルートと、建物の図面を参照することにより取得した。計測者が利用したアプリケーションは、先行研究 [1] にて我々が開発した Android アプリケーションである。対して定点観測地点のスマートフォンでは、Google Play ストアにて一般公開されているセンサロガーアプリケーション（パッケージ名: AndroSensor）を利用した。

計測回によっては、歩行ルートの高さが図面に記載されていない場合があり、その計測回はデータセットから除外した。また、計測者 B と計測者 C の 2 名の計測者にて、フィールド内の各階層を分担して計測したが、計測者 B のデータは一部データの欠損があったため除外した。データ

表 2: 各データセットを計測した高さ

データセット名	高さ [m]
同一フロア歩行データセット	-8.5, -1.3, 0.735, 1.475, 2.475, 2.7, 4.3, 4.7, 5.2, 5.64, 5.7, 6.575, 8.55
地点データセット	0.2, 2.7, 5.2, 6.6, 9.2, 12.0, 14.8, 18.2, 20.6, 23.65

表 3: 各データセットに含まれる特徴量

データセット名	センサ名・収集項目
同一フロア歩行データセット	気圧 (定点観測地点), 気圧 (歩行ルート内), 加速度 (3 軸), 磁気 (3 軸), ジャイロ (3 軸)
地点データセット	気圧 (定点観測地点), 気圧 (計測地点), 4 台の LPWA 基地局からの RSSI, 加速度 (3 軸), 磁気 (3 軸), ジャイロ (3 軸)




図 3: 地点データセット計測時に利用したスマートフォンと LPWA モジュール

セットに含まれる特徴量を表 3 に示す。地点データセットと共通で収集しているセンサデータとして、定点観測地点における気圧、加速度、磁気、ジャイロがある。加速度、磁気、ジャイロについては、本研究では利用していないが、両データセット中に含まれる。

地点データセットは、地点による各センサデータの特徴を調査する目的で、2021 年 8 月 24 日および 8 月 25 日に収集した。建物内の座標が既知の 583 地点にて、地点の正解ラベルと共に気圧と各 LPWA 基地局からの RSSI を 5 秒間計測した。実験前に各地点の計測順を定義し、8 月 24 日の計測順を地点の正解ラベルとした。8 月 24 日は全 583 計測値点を計測し、8 月 25 日は計測時間の都合から、半数の地点のみを計測した。8 月 25 日は奇数の地点ラベルが付けられている地点のみで計測することで、8 月 24 日の計測と同等の範囲を計測しつつ、計測密度を下げた。8 月 25 日に計測した地点のうち、欠損値を含む地点を除外した 282 地点を、8 月 25 日計測分として採用した。各計測地点を 3 人の測定者によって分担して計測し、各測定者は、両日とも同じ地点の計測を担当した。各計測者は Android スマートフォン 1 台 (Google Pixel 4 もしくは Google Pixel 4a) と、LPWA 無線モジュール 1 台 (interplan 社製 920MHz

無線モジュール IM920s) を利用した。計測に利用したスマートフォンを表 4 (b) に示す。2つのデータセット間で、計測者 B と定点観測地点にて利用したスマートフォンが異なる理由は、8 月 24 日にスマートフォン D において計測アプリケーションが正常に動作しなくなり、定点観測地点にて利用していたスマートフォンと計測者 B の利用するスマートフォンを計測開始前に交換したためである。8 月 24 日のスマートフォン D においても、AndroSensor の動作に影響はなかったため、定点観測地点に影響はなかった。LPWA ネットワークは計測者が利用する子機 3 台の他に、炉室内の離れた地点に設置された親機 4 台にて構成する。各 LPWA モジュールは、子機親機共に Raspberry Pi 3 model B に搭載し、データ収集した。定点観測地点における気圧計測は、0.2m の階層にて Google Pixel 5 を用いて行った。同一フロア歩行データセットと異なる点として、同一フロア歩行データセットでは歩行状態での計測だったが、地点データセットにおいてはスマートフォンと LPWA モジュールを三脚に固定し、計測した。計測の様子を図 3 に示す。スマートフォンは三脚の上部に固定し、LPWA モジュールは三脚の脚部に固定した。

4.2 各データセットに対する前処理

各計測地点でのセンサデータ群に対して、分類器へ入力するために前処理した。以下より、各データセットにて行った前処理について示す。

4.2.1 両データセットへ共通で適用した前処理

気圧値に対する前処理として、定点観測地点と計測地点の気圧差を算出した。気圧は時刻変化するため、分類器へ入力する特徴量として利用する際には、時間変化分を取り除く必要がある。本研究では、計測者によって計測された気圧値から、建物の最下位層 (階層 0.2m) において定点観測された気圧値を引くことで、最下位層と計測地点の気圧差を算出し、特徴量として利用した。また、各スマートフォンに搭載されている気圧センサ BMP380 の相対誤差が ± 0.06 hPa であり、小数点 2 桁目に影響しているため、気圧差は小数点第 3 桁で四捨五入により桁丸めした。

表 4: 各データセット収集時に利用したスマートフォン

(a) 同一フロア歩行データセット

利用箇所	利用したスマートフォン ID	実験における利用
定点観測地点	スマートフォン A	利用
計測者 B	スマートフォン D	利用せず
計測者 C	スマートフォン C	利用

(b) 地点データセット

利用箇所	利用したスマートフォン ID
定点観測地点	スマートフォン D
計測者 A	スマートフォン B
計測者 B	スマートフォン A
計測者 C	スマートフォン C

表 5: 実験に利用したスマートフォン

ID	型番	気圧オフセット [hPa]
スマートフォン A	Google Pixel 4	-0.6046
スマートフォン B	Google Pixel 4a	0.0000
スマートフォン C	Google Pixel 4a	-0.0656
スマートフォン D	Google Pixel 5	未計測

4.2.2 地点データセットへ適用した前処理

スマートフォンで計測した各センサ値、及び LPWA モジュールにて計測した LPWA の RSSI は、互いにサンプリング周波数が異なる。特定センサの値が更新されるタイミングを基準とすると、計測されたセンサ値以外は欠損値となる。対して、分類器での学習及び推論時は、1 インスタンスに各センサの値を含む必要があるため、欠損値を補完する必要がある。欠損値補完の手順として、まず各センサがそれぞれ更新されたタイミングで 1 インスタンス生成する。そして該当センサで取得された値以外は一時的に欠損値としてデータセットに登録する。欠損値となった更新されていないセンサからの値は、そのセンサで直近で取得された値をコピーすることで補完する。

LPWA RSSI に対する前処理として、計測値を元に生成したガウスノイズによるデータ拡張を行っている。LPWA RSSI は他センサと比べてサンプリング周波数が低い。そのため、分類器を学習させる際に、データの普遍性が不足する可能性がある。提案手法では、先行研究 [2] を参考に、データセットのトレーニングデータについて、各 LPWA 基地局からの RSSI を人工的に生成したノイズデータへ置き換えた。各計測地点において計測された LPWA RSSI の平均値及び標準偏差を元にガウスノイズを生成し、データセットのトレーニングデータとした。また計測地点によっては、特定の LPWA 基地局からの電波を全く受信できない地点も存在している。計測時間内に RSSI を計測できなかった場合、その基地局からの RSSI は -100 dBm としている。欠損値補完処理の都合上、LPWA RSSI はそれぞれの地点の気圧計測開始時刻より 100 ms 遅らせてデータセットに追加している。

また、計測にて利用した気圧センサは、個体ごとに一定の絶対誤差が存在している。地点データセットでは、3 台のスマートフォンにて計測したため、計測値から絶対誤差を差し引く必要がある。この気圧絶対誤差値は、同フィー

ルドにおいて 8 月 25 日に 3 人の測定者が同一ルートを同時に 27 秒間歩行しながら計測した気圧値から算出した。測定者は地点データセットの計測者と同じである。各スマートフォンにおいて、計測された気圧値の中央値を算出し、計測者 A のスマートフォンを基準とした場合の、算出された絶対誤差を表 5 に示す。以後本文にてスマートフォンを識別する際には、表 5 に示す ID を用いて識別する。

加えて、Logistic Regression, Multi Layer Perceptron の各モデルへ入力する特徴量は正規化するため、気圧差と各 LPWA 基地局からの RSSI へは最小最大スケールリングを適用した。

4.3 同一フロア歩行実験

高さ気圧差の関係を検証するため、同一高さ歩行データセットを用いて、各高さにおける気圧差を評価した。高さが同一なフロア内での気圧差の分布を把握するため、データセットに含まれる高さのうち、同一フロア内で 2 回以上計測した高さのみを抽出し、計測回毎の気圧差の平均値、標準偏差、及び気圧差の 95 % 信頼区間幅を表 6 に示す。また、各計測回の計測値を高さ毎に合わせ、気圧差に対して表 6 と同じ統計量を算出した結果を表 7 に示す。各計測回の気圧差は正規分布であると仮定し、95 % 信頼区間を算出した。また、各高さにおける気圧差の分布を図 4 に示す。図 4 は各高さにおける気圧差の分布を示しており、縦軸が気圧差、横軸が度数を示している。計測回 1 つに対してヒストグラム 1 つを示している。図 4 (a) の様に、同一高さ及び同一部屋内で複数ルート計測した場合は、それぞれの分布が何ルート目か示している。

4.4 エリア推定実験

次に、エリア分割の精度を評価するエリア推定実験について説明する。3 章で示した各エリアについて、図面を元にエリア面積を算出した。エリア条件 2 におけるエリア面積は、炉室はグレーチングの面積、その他の部屋は床全体の面積とした。ただし、階層 0.2m は床が空中に構築されたグレーチングではなく、フロア全体をカバーしたコンクリートの床であるため、階層 0.2m 炉室のエリア面積は床全体の面積とした。エリア条件 1 は、エリア条件 2 において算出した各部屋の面積を合計し、階層の面積としている。

表 6: 各計測回における気圧差の統計量

高さ [m]	部屋名	計測回	気圧差		
			μ [hPa]	σ [hPa]	信頼区間幅
0.735	部屋 A	1	0.126	0.030	0.118
0.735	部屋 A	2	0.138	0.026	0.103
1.475	炉室	1	0.170	0.023	0.091
1.475	炉室	2	0.145	0.023	0.090
2.475	炉室	1	0.287	0.024	0.093
2.475	炉室	2	0.264	0.021	0.080
4.3	炉室	1	0.541	0.022	0.085
4.3	炉室	2	0.526	0.027	0.105
4.7	部屋 B	1	0.564	0.030	0.116
4.7	部屋 C	1	0.565	0.032	0.126
4.7	炉室	1	0.616	0.028	0.108
5.2	部屋 D	1	0.695	0.025	0.099
5.2	炉室	1	0.648	0.021	0.082
5.2	炉室	2	0.629	0.028	0.110

表 7: 各高さにおける気圧差の統計量

高さ [m]	気圧差		
	μ [hPa]	σ [hPa]	信頼区間幅
0.735	0.131	0.029	0.114
1.475	0.158	0.026	0.103
2.475	0.271	0.024	0.095
4.3	0.535	0.025	0.098
4.7	0.574	0.036	0.142
5.2	0.666	0.035	0.137

エリア推定の手順について説明する。まず、データセットのトレーニングデータから、気圧差と LPWA RSSI を説明変数、エリアを目的変数としてモデルの学習する。次に、学習済みモデルに対して、テストデータを用いて推論する。この際、入力 1 インスタンスに対する推定結果として、最も属している可能性が高い 1 クラスのみではなく、全クラスに対して、インスタンスが属している可能性を出力する。この推論結果を用い、以下の出力を得る。

- 最も属している可能性が高いクラスのみを用いて、正解ラベルと推論ラベルの混同行列を作成する。この混同行列を用いて、各ラベルのテストデータが分類されたクラスを分析する。
- テストデータに対する推論結果から、インスタンスが属している可能性が高い順に n クラスのみを抽出し、その中に正解クラスが含まれているかを検証する。また、各インスタンスを入力した際の推論結果から n クラス抽出した際の、エリア面積を算出し、テストデータの全インスタンスにおける平均面積を算出する。

分類器として、Random Forest を利用し、scikit-learn を用いて実装した。Random Forest のハイパーパラメータはランダムシード値のみ任意の値で固定し、それ以外のパラメータは scikit-learn バージョン 1.0.2 のデフォルト値を利用した。また、トレーニングデータである 8 月 24 日のデータに対しては、各エリア条件毎のインスタンス数が同数になるように、エリア条件のうち最もインスタンス数の少ないエリアのインスタンス数に合わせ、ランダムに選択した。

エリア条件 1 の場合の分類結果の混同行列を図 5 に示す。縦軸は正解ラベル、横軸は分類器が出力した推論ラベルであり、特定のインスタンスを入力した際に、どのラベルへ分類されたかを示している。エリア条件 1 における F1 スコアは、説明変数として気圧差を入力した場合は 0.906、

気圧差と LPWA RSSI を入力した場合は 0.964 であった。


エリア条件 2 の場合の分類結果の混同行列を図 6 に示す。図 6 の正解ラベル及び推論ラベルにおいては、炉室である場合は FR、炉室以外の部屋では Not FR と記載している。エリア条件 2 における F1 スコアは、説明変数として気圧差を入力した場合は 0.649、気圧差と LPWA RSSI を入力した場合は 0.906 であった。また、分類器から出力されたエリアの中に、正解エリアが含まれている確率について実験した。分類器として、Random Forest, Logistic Regression, Multi Layer Perceptron を利用した。各モデルのハイパーパラメータにおけるデフォルト値からの変更点として、Logistic Regression と Multi Layer Perceptron では最大反復回数を 1000 回に設定し、ランダムシード値を固定した。それ以外のパラメータはデフォルト値を利用した。分類器から出力されたエリア内に正解エリアが含まれる確率について、エリア条件 1 の場合を表 8 (a)、エリア条件 2 の場合を表 8 (b) に示す。

5. 考察


5.1 同一フロア歩行実験

表 6 より、各計測回の気圧差の 95 %信頼区間幅は、0.080 hPa から 0.118 hPa の範囲である。計測に利用した Google Pixel 4, 4a に搭載されている気圧センサ BMP380 の相対誤差が ± 0.06 hPa であること、及び歩行中の計測であることから、同一の高さを歩行時の計測された気圧差として妥当であるといえる。


表 7 より、1 つの部屋のみが存在しているフロアでは、気圧差の 95 %信頼区間幅は 0.735 m のフロアにおいて最大であり、0.114 hPa である。対して、フロアに複数の部屋が存在する高さでは、95 %信頼区間幅が 4.7 m のフロアにおいて最大であり、0.142 hPa であった。つまり、単一




(a) 0.735 m (単一の部屋のみ)



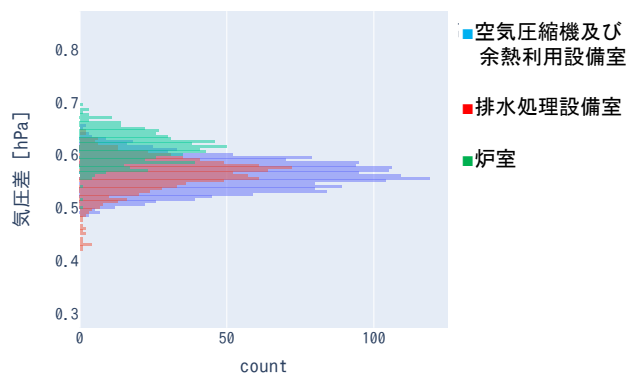
(b) 1.475 m (炉室のみ)




(c) 2.475 m (炉室のみ)



(d) 4.3 m (炉室のみ)



(e) 4.7 m (2部屋 + 炉室)



(f) 5.2 m (1部屋 + 炉室)

図 4: 各高さの気圧差分布

の部屋のみが存在するフロアよりも複数の部屋が存在するフロアにおいて、気圧差の95%信頼区間幅は大きな値を示す。ここで、表6の各計測回における気圧差に着目すると、高さが4.7mのフロアは炉室と2部屋が存在しているが、それぞれの部屋における気圧差の95%信頼区間幅は

最大でも0.126 hPaである。つまり、各計測回における気圧差のばらつきはほぼ一定であることを示している。これらの結果は、図4に示すヒストグラムからも確認できる。単一のフロアのみが存在する0.735m, 1.475m, 2.475mでは、各計測回毎に計測された気圧分布がほぼ重なって

表 8: クラスへ属している確率が大きい順に n 個のクラスを候補として抽出した場合、正解クラス（エリア）が含まれる確率

(a) エリア条件 1

n	Random Forest		Logistic Regression		Multi Layer Perceptron	
	正解ラベルが含まれている確率	平均面積 [m ²]	正解ラベルが含まれている確率	平均面積 [m ²]	正解ラベルが含まれている確率	平均面積 [m ²]
1	0.965	1250.281	0.956	1220.502	0.939	1248.272
2	0.996	1917.193	0.999	1997.335	1.000	2071.748
3	0.997	2351.887	1.000	2962.678	1.000	2959.436
4	0.997	2578.124	1.000	3874.396	1.000	3870.385
5	0.997	2646.103	1.000	4875.388	1.000	4737.645

(b) エリア条件 2

n	Random Forest		Logistic Regression		Multi Layer Perceptron	
	正解ラベルが含まれている確率	平均面積 [m ²]	正解ラベルが含まれている確率	平均面積 [m ²]	正解ラベルが含まれている確率	平均面積 [m ²]
1	0.908	786.949	0.858	764.798	0.866	781.837
2	0.977	1273.128	0.981	1276.615	0.972	1341.146
3	0.987	1631.434	0.991	1880.956	1.000	2035.391
4	0.991	1879.371	0.992	2524.982	1.000	2731.599
5	0.991	1998.305	0.995	3136.505	1.000	3373.389

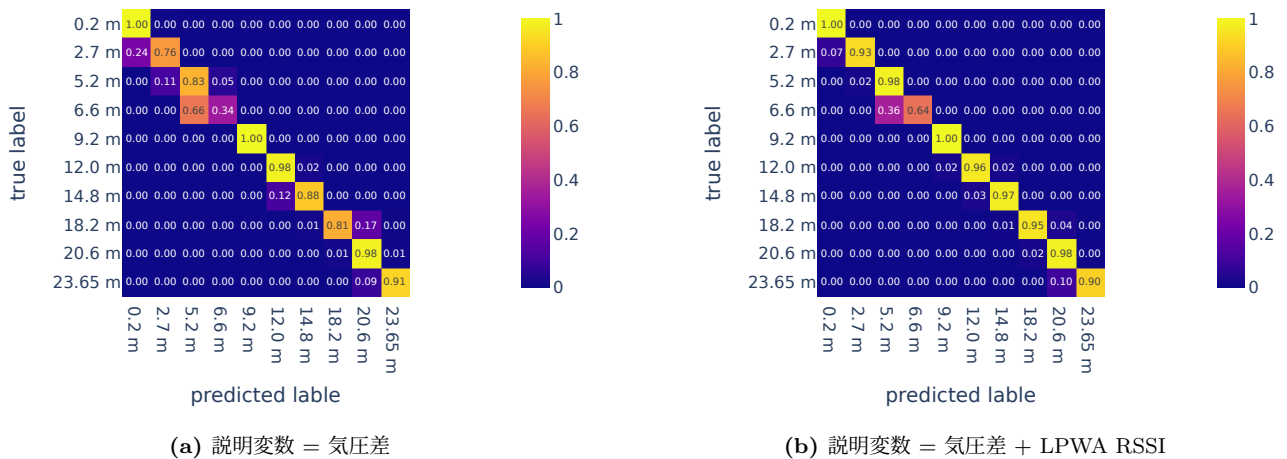


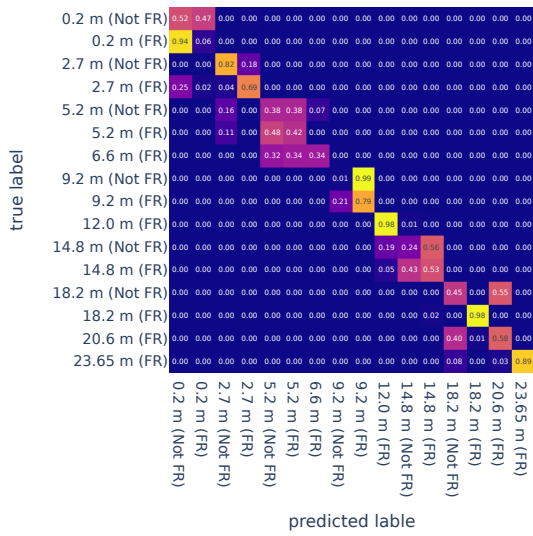
図 5: エリア条件 1 におけるエリア推定結果

る。対して、フロア内に複数の部屋が存在している 4.7m, 5.2m のフロアにおいては、気圧分布同士の重なりがずれが発生している。これらから、単一の部屋のみが存在するフロアよりも複数の部屋が存在するフロアの方が、気圧差の 95%信頼区間幅が大きい理由は、それぞれの部屋における気圧差の平均値が、フロアの高さ以外の要因から影響を受けているためであると考えられる。これは、フロア内に複数の部屋が存在している場合でも、気圧差によって識別できる可能性があることを示している。

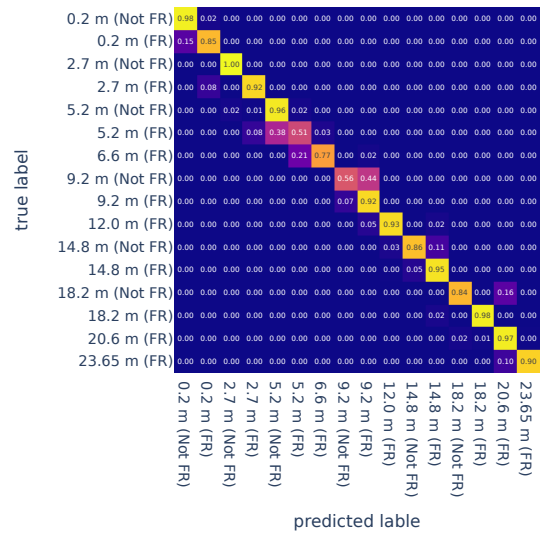
5.2 エリア推定

まず、エリア推定において、分類器が出力したエリア候補のうち、上位 1 クラスを抽出した場合 ($n = 1$) につい

て考察する。エリア条件 1 においては、説明変数を気圧差単体とした場合の F1 スコアは 0.906 であり、LPWA RSSI を加えた場合の F1 スコアは 0.964 だった。図 5 から、エリア条件 1 においては説明変数へ LPWA RSSI を加えることによって、分類精度が向上していることが分かる。同様に、図 6 より、LPWA RSSI の追加によってエリア条件 2 においても分類精度が向上していることが分かる。特に、エリア条件 2 では、気圧差単体を説明変数とした場合は F1 スコアが 0.649 と低いが、LPWA RSSI を加えることで 0.906 へ改善した。つまり、気圧差単体では区別が付かないエリアに対しても、LPWA RSSI を加えることで判別可能になることを示している。LPWA RSSI によって炉室か炉室以外かの判別精度が向上する理由として、炉室内

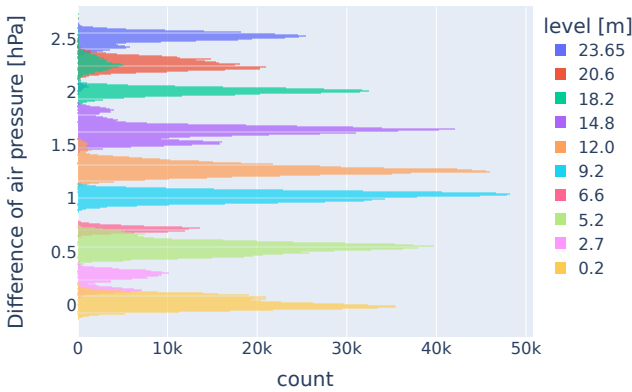


(a) 説明変数 = 気圧差

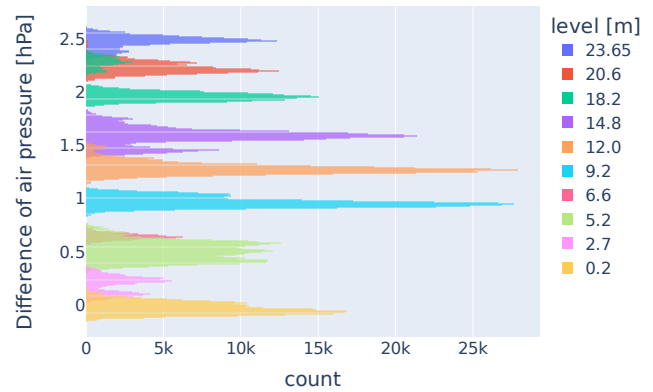


(b) 説明変数 = 気圧差 + LPWA RSSI

図 6: エリア条件 2 におけるエリア推定結果



(a) 8月24日



(b) 8月25日

図 7: 地点データセットにおける各計測日の気圧差の分布

に対して、炉室以外の部屋は電波強度が下がるためだと考えられる。炉室内は壁が無いので、電波が遮蔽されないが、部屋においては壁によって電波が遮られることで、電波強度の低下などが発生していると考えられる。

図 5 (b), 6 (b) より、エリア条件 1, 2 共に、インスタンスが属している確率が最大であると推論されたクラスのみを抽出しても、ある程度分類が可能であることが分かる。しかし、正解とは異なるクラスへ分類される場合がある。これは、エリア推定として、最も属している可能性の高い 1 クラスのみを抽出すると、入力されたインスタンスに対して異なるエリアを提示する可能性があることを示している。エリア推定によって異なるエリアが示されると、後続の磁気マッチングによる地点推定の際に、正解地点が含まれない可能性がある。よって、エリア候補から、最もイン

スタンスが属している確率が高いとされた 1 クラスのみを抽出することは、エリア推定として不十分である。

次に、必ず正解を含む最大クラス数について考察する。表 8 より、エリア条件 1 の場合、分類器として Multi Layer Perceptron を用い、インスタンスに対する推論結果のうちトップ 2 クラスを抽出すれば、推論結果の中へ必ず正解クラスが含まれることが分かる。エリア条件 1 の場合の 2 クラス分は、建物の図面上での 2 階層分に当たる。対して、エリア条件 2 においては、Multi Layer Perceptron を用いた場合は、3 クラスを抽出することで必ず正解クラスが含まれている。エリアの面積としては、2035.391 m² と、エリア条件 1 において最も面積が小さかった場合よりも小さなエリア面積となった。エリア面積を縮小できた理由として、気圧差と LPWA RSSI によって、1 階層内で炉室か、

炉室以外の部屋かを区別できることから、1候補あたりの面積が削減されたためであると考えられる。

次に、エリア推定に失敗する場合の原因について考察する。まず、階層を超えて間違ったエリアを出力している場合について述べる、図5(b)より、正解が階層6.6mのインスタンスを入力した際に、階層5.2mと誤判定するパターンが多いことが分かる。これは、まず階層5.2mと階層6.6mの階層差が1.4mと小さいことが原因だと考えられる。その他の階層差は最低でも階層18.2mと階層20.6m間において2.4mであるため、階層5.2mと階層6.6mの階層間距離は他階層間よりも1m小さい。地点データセットの各階層における気圧差の分布を、図7に示す。階層5.2mと階層6.6mに着目すると、8月24日は分布の半分ほどが重なっているが、8月25日は分布のほぼ全てが重なっていることが分かる。また、図6(b)より以下が分かる。

- 階層5.2mの炉室以外の部屋を示すインスタンスを入力した場合は、ほぼ正解している。
- 階層5.2mの炉室を示すインスタンスを入力した場合、階層5.2mの炉室以外の部屋と誤判定している。
- 階層6.6mの炉室を示すインスタンスを入力した場合、階層5.2mの炉室と誤判定している

つまり、階層5.2mと階層6.6mで誤判定する条件としては、それぞれの階層の炉室にて計測した場合であり、誤判定する理由としては時間経過によって気圧差が変動する地点があると考えられる。気圧差が変動する原因として、ゴミ焼却機器の稼働やドアの開閉状況などが考えられる。これらの変動条件は、階層5.2mや階層6.6mに限らず存在していると考えられるが、その他の階層は階層間の距離が離れているため、影響を受けていない、もしくはLPWA RSSIによって補正される。つまり、隣接する階層同士が近く、かつ炉室内部のように空間を共有している場合、LPWA RSSIによって補正しきれず、高さ以外の条件によって変動した気圧差の影響を受ける可能性を考慮する必要がある。

次に、同一階層内でエリア推定に失敗しているエリアについて述べる。階層5.2mの炉室を示すインスタンスを入力した場合、同階層の炉室以外の部屋と誤判定している。また、階層9.2mの炉室以外の部屋を示すインスタンスを入力した場合、同階層の炉室と誤判定している場合がある。図6(a)より、説明変数が気圧差のみでは、正解ラベルが階層9.2mの炉室以外の部屋のインスタンスに対して、ほぼ全てを9.2mの炉室だと誤判定している。これはLPWA RSSIを加えることで改善しているものの、半数近くのインスタンスが誤判定されている。対して、階層0.2mと階層14.8mでは、説明変数が気圧差だけでは炉室内外の判定に失敗しているが、LPWA RSSIを加えることで炉室内外の判定が改善している。つまり、炉室内外の判定はLPWA RSSIによって補正可能な場合と、補正が不十分な場合があ

る。その原因として、炉室内外に関わらず、LPWA RSSIの傾向が類似している可能性があると考えられる。

6. おわりに

本研究では、同一フロアにおける気圧差について調査を行い、またLPWA RSSIがエリア推定に与える影響について検証し、気圧差とLPWA RSSIによって縮小可能なエリア面積について考察した。気圧差とLPWA RSSIを用いて、清掃工場内部を複数のエリアへ分離できた。施設を階層に基づいてエリアに分離した場合、全10階層を2階層へ絞り込めた。施設を階層と部屋が炉室かどうかに基づいてエリアに分離した場合、全16エリアを3エリアへ絞り込めた。同一フロアであっても、炉室かそれ以外の部屋かを識別できる理由として、各部屋の気圧差は異なるためだと考える。また、気圧差だけでは分離が困難なエリアであってもLPWA RSSIによって補正が可能であることが分かった。

しかし、階層が隣接し空間を共有する場合、気圧差とLPWA RSSIを用いても区別できないエリアが存在した。これらの分離不能なエリアでは、2日間で気圧差が変動していたことが影響していると考えられる。また、同一階層内でも、炉室と炉室以外の部屋を識別できない階層があった。今後の課題として、エリア面積縮小のため、気圧差が時間変動する要因について調査を行い、気圧差のみでは分類精度が不十分なエリアに対してより適切に補正が行えるLPWA基地局の設置数や設置箇所について検討する。

謝辞 データ収集にご協力いただいた石川北部RDFセンターの関係者の方々に感謝いたします。

参考文献

- [1] 奥村嶺, 新佑太郎, 新井イスマイル, 川端馨, 藤川和利: 清掃工場における磁気と気圧を用いた屋内測位可能性の現地調査, 情報処理学会研究報告モバイルコンピューティングと新社会システム (MBL), Vol. 2021-MBL-99, No. 27, pp. 1-8 (2021).
- [2] Abbas, M., Elhamshary, M., Rizk, H., Torki, M. and Youssef, M.: WiDeep: WiFi-based Accurate and Robust Indoor Localization System using Deep Learning, *Proceedings of the 2019 IEEE International Conference on Pervasive Computing and Communications (PerCom)*, pp. 1-10 (online), DOI: 10.1109/PERCOM.2019.8767421 (2019).
- [3] Kotaru, M., Joshi, K., Bharadia, D. and Katti, S.: SpotFi: Decimeter Level Localization Using WiFi, *Proceedings of the 2015 ACM Conference on Special Interest Group on Data Communication, SIGCOMM '15*, New York, NY, USA, Association for Computing Machinery, pp. 269-282 (online), DOI: 10.1145/2785956.2787487 (2015).
- [4] Ghourchian, N., Allegue-Martinez, M. and Precup, D.: Real-time Indoor Localization in Smart Homes Using Semi-Supervised Learning, *Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence, AAAI'17*, San Francisco, California, USA, AAAI

- Press, pp. 4670–4677 (2017).
- [5] Sun, D., Wei, E., Ma, Z., Wu, C. and Xu, S.: Optimized CNNs to Indoor Localization through BLE Sensors Using Improved PSO, *Sensors*, Vol. 21, No. 6, p. 1995 (online), DOI: 10.3390/s21061995 (2021).
- [6] Faragher, R. and Harle, R.: Location Fingerprinting With Bluetooth Low Energy Beacons, *IEEE Journal on Selected Areas in Communications*, Vol. 33, No. 11, pp. 2418–2428 (online), DOI: 10.1109/JSAC.2015.2430281 (2015).
- [7] Cantón Paterna, V., Calveras Augé, A., Paradells Aspas, J. and Pérez Bullones, M. A.: A Bluetooth Low Energy Indoor Positioning System with Channel Diversity, Weighted Trilateration and Kalman Filtering, *Sensors*, Vol. 17, p. 2927 (online), DOI: 10.3390/s17122927 (2017).
- [8] Chen, Y.-S., Hsu, C.-S. and Huang, C.-Y.: A Semi-Supervised Transfer Learning with Grid Segmentation for Outdoor Localization over LoRaWans, *Sensors*, Vol. 21, No. 8, p. 2640 (online), DOI: 10.3390/s21082640 (2021).
- [9] Anjum, M., Khan, M. A., Hassan, S. A., Mahmood, A., Qureshi, H. K. and Gidlund, M.: RSSI Fingerprinting-Based Localization Using Machine Learning in LoRa Networks, *IEEE Internet of Things Magazine*, Vol. 3, No. 4, pp. 53–59 (online), DOI: 10.1109/IOTM.0001.2000019 (2020).
- [10] Sallouha, H., Chiumento, A. and Pollin, S.: Localization in Long-Range Ultra Narrow Band IoT Networks Using RSSI, *Proceedings of the 2017 IEEE International Conference on Communications (ICC)*, pp. 1–6 (online), DOI: 10.1109/ICC.2017.7997195 (2017).
- [11] Kim, K., Li, S., Heydariaan, M., Smaoui, N., Gnawali, O., Suh, W., Suh, M. J. and Kim, J. I.: Feasibility of LoRa for Smart Home Indoor Localization, *Applied Sciences*, Vol. 11, No. 1, p. 415 (online), DOI: 10.3390/app11010415 (2021).
- [12] Xia, H., Wang, X., Qiao, Y., Jian, J. and Chang, Y.: Using Multiple Barometers to Detect the Floor Location of Smart Phones with Built-in Barometric Sensors for Indoor Positioning, *Sensors*, Vol. 15, No. 4, pp. 7857–7877 (online), DOI: 10.3390/s150407857 (2015).
- [13] Cock, C. D., Joseph, W., Martens, L. and Plets, D.: Floor Number Detection for Smartphone-based Pedestrian Dead Reckoning Applications, *Proceedings of the 2021 International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, pp. 1–6 (online), DOI: 10.1109/IPIN51156.2021.9662470 (2021).
- [14] Muralidharan, K., Khan, A. J., Misra, A., Balan, R. K. and Agarwal, S.: Barometric Phone Sensors: More Hype Than Hope!, *Proceedings of the 15th Workshop on Mobile Computing Systems and Applications, HotMobile '14*, New York, NY, USA, Association for Computing Machinery, pp. 1–6 (online), DOI: 10.1145/2565585.2565596 (2014).
- [15] Xu, Z., Wei, J., Zhu, J. and Yang, W.: A Robust Floor Localization Method Using Inertial and Barometer Measurements, *Proceedings of the 2017 International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, pp. 1–8 (online), DOI: 10.1109/IPIN.2017.8115952 (2017).
- [16] Okumura, R., Arai, I., Yutaro, A., Kaoru, K. and Fujikawa, K.: Feasibility Study of Magnetism-based Indoor Positioning Methods in an Incineration Plant, *2022 IEEE International Conference on Pervasive Computing and Communications Workshops and other Affiliated Events (PerCom Workshops)*, pp. 563–568 (online), DOI: 10.1109/PerCom-Workshops53856.2022.9767331 (2022).
- [17] Ouyang, G. and Abed-Meraim, K.: Analysis of Magnetic Field Measurements for Mobile Localisation, *Proceedings of the 2021 International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, pp. 1–8 (online), DOI: 10.1109/IPIN51156.2021.9662551 (2021).
- [18] Wang, X., Yu, Z. and Mao, S.: DeepML: Deep LSTM for Indoor Localization with Smartphone Magnetic and Light Sensors, *Proceedings of the 2018 IEEE International Conference on Communications (ICC)*, pp. 1–6 (online), DOI: 10.1109/ICC.2018.8422562 (2018).
- [19] Shu, Y., Bo, C., Shen, G., Zhao, C., Li, L. and Zhao, F.: Magicol: Indoor Localization Using Pervasive Magnetic Field and Opportunistic WiFi Sensing, *IEEE Journal on Selected Areas in Communications*, Vol. 33, No. 7, pp. 1443–1457 (online), DOI: 10.1109/JSAC.2015.2430274 (2015).
- [20] 東和樹, 新井イスマイル: 相互補完型 Wi-Fi・地磁気フィンガープリンティング手法の評価, *情報処理学会論文誌*, Vol. 58, No. 2, pp. 384–395 (2017).
- [21] Kaji, K., Isomura, K. and Takai, T.: Step Recognition Method Using Air Pressure Sensor, *Proceedings of the 2019 International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, pp. 1–8 (online), DOI: 10.1109/IPIN.2019.8911762 (2019).