

博士論文

配布型 BLE タグを用いた
屋内位置推定手法

481843013 浦野 健太

名古屋大学大学院 工学研究科
情報・通信工学専攻

概要

コンピュータの小型化・高性能化にともなって、情報システムが我々の生活を自然に援助してくれるユビキタスコンピューティング社会が身近になった。中でも位置情報の利用で道の混雑や人の移動度の分析が可能になり、より快適な移動や都市運営が試みられている。屋内では GPS 位置情報の利用が難しく、様々な環境で屋内位置推定が利用されてきた。中でも、期間を絞って開催される屋内イベントでは、来場者の行動分析がより重要である一方で、既存の人流推定や屋内位置推定手法の利用が難しかった。

本研究では来場者への負担や機材コスト、同一人物の追跡性などの面を考慮して、イベント環境で利用できる位置推定として、来場者に BLE タグを配布し、そのパケットを環境中の BLE スキャナで収集して位置推定を行う、配布型 BLE タグを用いた屋内位置推定を提案する。まず、データ収集用ハードウェアとシステムを構築し、実環境でのデータ収集を行った。BLE ではパケットロスが多く発生するため、タンデム BLE スキャナを構築し、実環境で得られるデータの実態の分析や、タンデム BLE スキャナが効果的かを検証した。次に推定アルゴリズムでは、学習用のデータ収集が難しい短期間、データ収集を行える長期間のイベントをそれぞれ考え、信号強度からの距離推定とパーティクルフィルタを用いる手法と、深層学習を用いる手法を提案し、前者では平均 3.62m を、後者では平均 1.92m の誤差となった。また、実環境でのトラブルを想定して精度の変化を検証し、信号強度とパーティクルフィルタを用いる手法は精度低下が小さく、深層学習を用いる手法では精度低下が大きいという結果を得た。そこで、どちらの手法も利用可能にしておき、データ収集状況や機材故障に合わせて切り替え、位置推定を行えない空白期間を減らす運用が必要だとわかった。

BLE 位置情報はこれまで部屋・エリア単位で、実用サービスでは滞在部屋の判定のため各部屋に BLE ビーコンを設置する運用だった、それに対し、本研究では配布型 BLE タグを用いて詳細に位置が得られる推定を提案し、屋内イベントの実環境での有効性を確認した。実環境におけるパケットロス問題の発見と、Bluetooth アダプタを複数使うタンデム BLE スキャナという安価で効果的な対策は、他の BLE 位置推定の精度を高めるために有用な知見である。さらに、BLE タグはモノへの貼付も容易であり、今後大量の設置が予想される IoT 機器にも簡単に組み込めるため、人だけに限らず幅広い利用が期待できる。本研究の提案である配布型 BLE タグによる屋内位置推定は、人・モノ・IoT デバイスの位置情報をより低価格に、容易に、詳細に取得できる世界の基盤として有用である。

目次

第 1 章	はじめに	1
1.1	背景	1
1.2	屋内空間での位置推定	3
1.3	大規模イベントにおける配布型 BLE タグを利用した位置推定	4
1.4	本研究のアプローチ・貢献	6
1.5	本論文の構成	10
第 2 章	関連分野の研究	11
2.1	位置情報を利用した情報分析に関する研究	11
2.2	加速度や画像を用いる位置推定	13
2.3	無線通信を利用した位置推定	14
2.4	大規模イベント環境での位置推定システムの要件	20
第 3 章	タンデム BLE スキャナの構築と実環境におけるデータ収集	23
3.1	BLE の概要	23
3.2	イベント向け BLE 位置推定システムの具体的な構成検討	27
3.3	G 空間 EXPO2015 での実験における実環境でのパケットロス状況の確認	29
3.4	タンデム BLE スキャナの構築	33
3.5	G 空間 EXPO2016 でのタンデム BLE を用いたデータ収集	38
3.6	G 空間 EXPO2016 での収集データの基礎分析	45
3.7	本章のまとめ	53
第 4 章	タンデムスキャナで得た信号強度を用いた位置推定	55
4.1	推定アルゴリズムの概要	55
4.2	信号強度をもとにした対象空間全体での推定	56

4.3	パーティクルフィルタによる過去の推定位置情報の利用	59
4.4	推定精度の評価	62
4.5	本章のまとめ	71
第 5 章	深層学習を利用した位置推定	73
5.1	深層学習を利用した位置推定の試み	73
5.2	オートエンコーダを用いた信号強度の補正の試み	74
5.3	時系列情報の利用を考慮した深層学習位置推定モデル	84
5.4	End-to-end 位置推定モデルの推定精度の評価	86
5.5	本章のまとめ	103
第 6 章	おわりに	105
6.1	本論文のまとめ	105
6.2	今後の展望	107
	謝辞	109
	参考文献	111
付録 A	Bluetooth Low Energy による通信の概要	127
A.1	Bluetooth 規格の概要・歴史	127

目次

1.1	総務省によるデータ利活用型スマートシティの構想 ([2] より引用)	2
1.2	イベントでの利用を考えた際の各手法の位置付け	5
1.3	提案する位置推定システムの概念図	6
1.4	一般的な BLE ビーコンの運用と, 本研究で提案する推定方式の違い	7
2.1	無線通信を用いる位置推定の, 対象空間と精度の概要 ([18] より引用)	15
2.2	推定アプローチの分類 ([39] より引用)	16
2.3	提案する位置推定システムの概念図: 三角測量・電波マップ方式の推定とその切替 の追加	21
3.1	BLE のチャンネル	24
3.2	<i>advDelay</i> を用いたアドバタイジングパケット送信の時間ランダム化	26
3.3	スキャン窓を用いたアドバタイジングチャンネルの監視	26
3.4	BLE スキャナ	27
3.5	BLE スキャナで用いる技術を追加したデータ収集システムの概念図	29
3.6	G 空間 EXPO2015 でのデータ収集システム	30
3.7	G 空間 EXPO2015 での BLE スキャナ配置図	31
3.8	G 空間 EXPO2015 の展示ブース設営前後の様子	31
3.9	G 空間 EXPO2015 での被験者	32
3.10	半時計回りに歩いた被験者についての, 実際に観測されたパケット信号強度と, 理 想の信号強度	33
3.11	7 個の Bluetooth アダプタを扱うタンデム BLE スキャナの例	34
3.12	送信機に対する受信アダプタの配置	35
3.13	各距離・各受信アダプタにおけるアドバタイジングパケットの受信回数	35

3.14	各距離・各受信アダプタにおけるアドバタイジングパケットの信号強度	37
3.15	特定のアドバタイジングチャンネルにパケットを送信した場合の信号強度	38
3.16	G 空間 EXPO2016 の場内の様子 ([101] より引用)	39
3.17	G 空間 EXPO 2016 における位置推定の対象エリア	39
3.18	G 空間 EXPO2016 での実験システム概要	40
3.19	iBeacon のパケットフォーマット	41
3.20	BLE タグ・UWB タグを装着した被験者	43
3.21	設置場所の例	44
3.22	会場内の BLE スキャナ配置とタンデム BLE スキャナのアダプタ方向	44
3.23	実験で使用したタンデム BLE スキャナ	44
3.24	被験者の実験時間の分布	46
3.25	UWB タグの正解位置から作成した滞在ヒートマップ	47
3.26	各被験者の実験時間と、その間の総移動距離	48
3.27	タンデム BLE スキャナが観測したパケットについての、各 Bluetooth アダプタでの受信数とユニークな受信数の比較	48
3.28	距離に対する信号強度の分布	50
3.29	タンデム BLE スキャナ 6 の信号強度分布	51
3.30	BLE スキャナごとの信号強度分布の違い (最大値)	52
3.31	精度検証用の経路	54
4.1	テスト用被験者の重みマップ	58
4.2	等間隔リサンプルの概念図	61
4.3	各経路において精度が最も良い軌跡	64
4.4	計算した信号強度と実際に観測された信号強度の比較	65
4.5	BLE タグの設定による平均誤差の変化	66
4.6	一部の BLE スキャナを利用しない設定	67
4.7	一部の BLE スキャナを利用しない場合の平均誤差の変化	68
5.1	デノイジングオートエンコーダ	76
5.2	オートエンコーダによる信号強度の補正の例 (入力・理想・再構築)	79
5.3	デノイジングオートエンコーダと前章の手法の組み合わせでの推定結果の例	81

5.4	再構築した信号強度を用いた推定における重みマップの例 (時計回り)	83
5.5	再構築した信号強度を用いた推定における重みマップの例 (ジグザグ)	83
5.6	利用可能な信号強度の多寡による重みマップの面積の模式図	84
5.7	全結合層と LSTM からなるネットワーク構成の概要	85
5.8	ネットワーク構成ごとの累積誤差分布	89
5.10	実データ量を変更した際の誤差分布	97
5.12	「さらに低密度」の BLE スキャナ制限パターン	99
5.13	スキャナ脱落時の誤差分布	100
A.1	BLE のデータリンク層ステートマシン	129
A.2	LE 1M/LE 2M のパケットフォーマット	130

表目次

3.1	Raspberry Pi 各モデルの性能諸元	28
3.2	G 空間 EXPO2016 における実験で利用した機材	43
3.3	BLE タグの設定	43
4.1	図 4.3 の各経路における会場内左右での精度	65
4.2	タンデム BLE スキャナの利用 Bluetooth アダプタによる精度の変化	69
4.3	Bluetooth アダプタごとのタンデム BLE スキャナ 1 台あたりの平均パケット受信数	70
5.1	シミュレーションのパラメータ	77
5.2	デノイジングオートエンコーダの学習時のパラメータ	78
5.3	位置推定モデルのパラメータ	87
5.4	累積確率 0.5, 0.75, 0.9 の点での誤差	88
5.5	誤差平均と標準偏差	88
5.6	出力特徴数を変更した際の誤差の平均と標準偏差	93
5.7	LSTM の隠れ状態の次元を変更した際の誤差の平均と標準偏差	93
5.8	最適化手法をを変更した際の誤差の平均と標準偏差	94
5.9	損失関数の各項の重みをを変更した際の誤差の平均と標準偏差	95
5.10	実データ量を変更した時の累積確率 0.5, 0.75, 0.9 の点での誤差	96
5.11	実データ量を変更した時の誤差平均と標準偏差	96
5.12	スキャナ脱落時の累積確率 0.5, 0.75, 0.9 の点での誤差	99
5.13	スキャナ脱落時の誤差平均と標準偏差	100
A.1	クラシック Bluetooth の登場時期とデータレート	128
A.2	クラシック Bluetooth のパワークラス	129
A.3	BLE のデータレート	131

A.4	BLE のパワークラス (バージョン 5.2 時点)	131
A.5	PDU Type の一覧	132

第 1 章

はじめに

本章では、本研究の背景となる位置情報の利用と屋内位置推定について述べ、屋内イベント環境における位置推定で必要となる要素や問題を定義して、本研究の目的をまとめる。また、各章の内容を概観しつつ本論文の構成を示す。

1.1 背景

黎明期には真空管とリレーで稼働し、1台で部屋を埋めつくす大きさだったコンピュータは、その発展とともに小型で高性能になった。1970年代にはパーソナルコンピュータが登場するとともに、誰もが持つ小型低価格な持ち運び可能コンピュータが予言 [1] された。その後も情報技術の発展は続き、1990年代後半からはインターネットが一般家庭でも広く利用されるようになった。個人が携帯する端末も高性能化が進み、電話やメールの機能しか持たなかった携帯電話には写真撮影や音楽再生・テレビ視聴などの機能などが追加されていった。2000年代後半にはスマートフォンが登場して、従来型の携帯電話と置き換わる形で普及が進んだ。

2019年には日本でのスマートフォンの保有状況は世帯単位で83.4%、個人で67.6% [2] となっており、多くの人が高機能な携帯端末を利用している。また、機器同士をつなぐ無線ネットワークも高速化・大容量化が進んでおり、2020年3月には国内で商用の第5世代移動通信システム (5G) サービスが開始された。これらのコンピュータの性能向上とネットワーク技術の進歩により、我々は様々なサービスを好きなタイミングで利用できるようになった。たとえば、屋外で目的地の場所がわからなければ GPS (Global Positioning System) を用いた案内を利用できるし、店舗では SNS で配布されるチラシ情報の閲覧やクーポン券の利用が可能である。

小型・低価格でも高性能なコンピュータの普及により、我々の身の回りに多くのデバイスやセン



図 1.1: 総務省によるデータ利活用型スマートシティの構想 ([2] より引用).

サが設置されるようになり、空間のスマート化が進んでいる。コンピュータが日常に溶けこみスマート化した空間において、我々がその存在を意識することなく情報システムを自然に利用できるユビキタスコンピューティングの世界はかつて Weiser によって予言 [3] された。現在は、ウェアラブルデバイスや IoT (Internet of Things) デバイス、自動ロボットなどが市場に出回り、我々の身体から建物・都市に至るまで様々な広さの空間にデバイスが設置されるようになり、パーソナルコンピュータの前に座って情報システムを利用していた以前に比べ、ユビキタスコンピューティングは身近になりつつある。

様々な規模の空間にセンサやデバイスが導入された結果、ウェアラブルデバイスによる生体信号のセンシングや、スマートメータによる電力情報の収集など、様々なデータが取得できるようになった。都市や地域のサービスを効率化・高度化するスマートシティ [4] の取り組みにおいても、総務省がデータ利活用型スマートシティの構想を推進 [2] しており、図 1.1 でも様々なデバイスやセンサが取り上げられているように、実空間から得られるデータの利用が重要視されている。中でも、携帯電話の接続情報や GPS から得られる位置情報は、広域での人の行動や交通の状態を分析するために利用されている。たとえば、Twitter 上の GPS 位置情報付きの投稿を分析し、地域で起きているイベント情報を抽出する EvenTweet[5] や、交通情報を抽出する手法 [6] が提案されている。BusBeat[7] ではバスやゴミ収集車の GPS データを用いて、おもちゃの展示会や音楽コンサートのような大規模イベントの発生を予測する手法が提案されている。交通の情報を応用した例とし

て、災害時に自動車の通行実績を利用して通行可能な道を調べるサービス [8] もある。携帯電話の基地局の接続情報などを利用して、広域での移動・滞在情報を可視化するサービスも展開されており、モバイル空間統計 [9] や、KDDI Location Data[10] などが利用可能である。

1.2 屋内空間での位置推定

GPS を搭載したスマートフォンの登場と普及により、我々は自身の位置情報を容易に取得できるようになった。それに伴い、目的地までのナビゲーションが可能な地図アプリや、現在地に近く雨雲を確認できる天気アプリのように、日常生活に役立つサービスが多数展開されている。自身の位置情報のみならず他者の位置情報の利用も進んでおり、たとえばタクシー配車サービスにおける車両位置や出前サービスにおける配達者の位置を通知する機能などが挙げられる。

GPS による位置取得では、衛星から送られる電波を安定して受信できない場合は測位に誤差が生じる。密集した建物で電波が反射しやすい都市部では誤差が生じやすく、電波が遮蔽されやすい建物内・地下街などの屋内空間では測位が難しい。前者については GPS 信号を補完する準天頂衛星システムが展開されているが、後者の屋内空間では GPS に頼らずに位置を取得する必要がある。GPS を用いずに測位を行う屋内位置推定は、以前からさかんに研究が行われ、多数の手法が提案されてきた。

屋内位置推定に利用される情報は様々で、加速度や角加速度 [11, 12]、カメラ画像 [13, 14]、超音波 [15]、磁気 [16, 17]、無線通信用の電波 [18, 19] などが挙げられ、また複数の情報を利用して高精度を目指すハイブリッド推定も存在する。使う情報が異なれば必要となる機材も異なり、手法ごとに精度や機材価格などで利点・欠点が存在する。そのため屋内位置推定を利用する際には、対象となる環境に合わせて事前調査や手法の最適化が行われ、精度の向上が図られている。これらのような手法ごとの制約のため、どの環境でも利用できる手法は存在せず、求められる精度や想定する利用状況・構築したいサービスに合わせて適切な手法を選択する必要がある。

多様な屋内位置推定手法の中でも、電波を用いる手法は無線通信技術の発展にあわせて多数提案されてきた。無線通信は携帯電話が備える無線 LAN (Local Area Network) や Bluetooth などの広く利用されるものから、スマート家電の制御に使われる ZigBee や、物流の管理で利用される RFID (Radio Frequency Identification) など、様々な用途で利用されている。電波を用いて行う位置推定には、送信から受信までの時間を利用するものや、受信電波の角度を利用するものなどがある中で、通信時に得られる信号強度の情報を利用して行う位置推定は、壁や柵などの障害物によってデバイスと無線基地局の間に見通しを得られなくてもよく、屋内での利用に適している。

これらの屋内位置情報の利用も、屋外における位置情報と同様に注目されている。個人がスマートフォンのようなデバイスで自身の位置を推定する以外にも、屋内空間にいる人の位置を外部から取得・解析し、人流・滞在情報を取得できれば、マーケティングや安全管理、空間利用の効率化に利用できる。たとえばマーケティング面では、人の移動経路の調査や、買い物行動の分析などがあげられる。安全管理・空間利用の効率化では、動線の抽出による混雑しやすい通路の把握や、滞在者数を利用した空調の調整・避難誘導に必要な時間の見積もりなどが行える。また2019年末から、新型の感染症が世界的に流行しており、人どうしの接触の検出や同じ空間への滞在の把握など、感染の連鎖を起こさないための施策が求められており、その点でも屋内空間での位置情報は重要といえる。

先述のように、屋内では様々な位置推定手法から適切なものを選んで利用する必要がある。人流や滞在の情報を分析するには、個々人の位置情報を集約して分析するため、環境中の機器で外部から位置情報を取得することが多い。たとえば、複数の企業がカメラを用いた人流の可視化システムを提供 [20, 21] しており、スマートフォンなどの機器が発する無線 LAN の管理パケットを取得して人流を推定する研究 [22] も行われている。

1.3 大規模イベントにおける配布型 BLE タグを利用した位置推定

人流や滞在の情報の取得が重要な環境として、期間限定で開催される屋内イベントがある。イベントにはたとえば、イベントホールやドーム会場で行う展示会や即売会・学術会議、美術館や博物館における特別展示などが考えられる。イベント開催中は多くの人を訪れるため、来場者が快適に観覧できているかを知るには、混雑度の分析が必要となる。また、人気展示の調査・目玉展示の集客効果の検証や、滞在ブースの傾向の分析などの需要もある。このようにイベント環境における来場者の行動分析を行えると、来場者数だけにとどまらない分析が可能になる。特に大型の展示会イベントでは出展者ごとに展示内容が大きく異なり、様々な目的を持った来場者が訪れるため、これらの分析の価値はより高くなる。そのためには、イベント主催者側が来場者の位置を継続的に取得する必要がある。

期間限定のイベント環境で来場者の位置を取得する際の一般的な課題は、来場者の負担、用いる機材の価格、精度、同じ人物の追跡ができるかどうかなどである。来場者の目的はイベントの展示物の観覧であるため、位置推定に協力してもらう際に負担が少ない手法が望ましい。来場者の負担、機材価格、精度、同一人物の追跡の面からの各手法の位置付けを図 1.2 に示す。もっとも負担が少ないのは、来場者が機材を持たなくてよいデバイスフリー、もしくは誰もが持っているデバイ

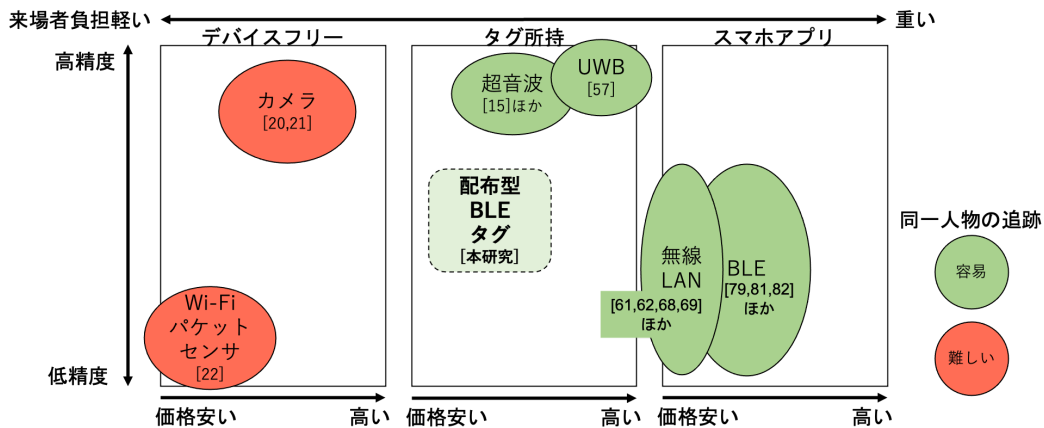


図 1.2: イベントでの利用を考えた際の各手法の位置付け

スを用いる方法である。この場合は来場者は特別なことをする必要がなく、会場内のデバイスで来場者の位置を取得する。カメラを用いたシステム [20, 21] では、カメラが見ている地点の人の位置を推定しやすい一方で、障害物の奥に人がいる場合や複数の人が重なった場合の検出や、個人を識別して追跡することが難しい。無線 LAN の管理パケットをパケットセンサで収集する手法では、来場者のスマートフォンに対して追跡を行うが、近年はプライバシー保護のために MAC アドレスのランダム化 [23, 24] が行われており、今後の利用が難しい。またこれらの手法では、カメラの視野に人が入らないと検出されない、パケットセンサ間の詳細な移動経路がわからないなど、得られる情報に制限がある。最も負担が重いのは、スマートフォンのアプリケーションを用いる場合である。スマートフォンは多くの人が持っており、屋内位置推定手法が多数提案されている。中でも、無線 LAN を利用した推定は多くの環境で利用しやすく、近年では BLE (Bluetooth Low Energy) ビーコンを環境に設置し、その信号をスキャンして行う推定手法も提案されている。一方で、イベント来場者に位置推定用のアプリケーションをインストールしてもらい、さらに会場内にいる間アプリケーションを動かし続けてもらうことは難しい。

これらの中間に位置するのが、来場者に位置推定用のタグを所持してもらう手法である。この場合、入り口や受付で主催者が超音波や電波で情報を送信する小型のタグを配布し、来場者はそれを携帯して会場を見て回る。来場者はタグを携帯する必要があるため負担はあるものの、スマートフォンアプリケーションをインストールし稼働させるような手間は生じない。また、タグの ID 情報を用いて同一人物を追跡できる。位置推定は、タグから発信された情報を会場に設置したスキャナで収集し、それをもとに行う。超音波を用いる位置推定や、UWB (Ultra Wide-Band) の電波を用いる手法があるが、これらは送受信の時刻差から送受信間の距離を推定する。そのため見通しが

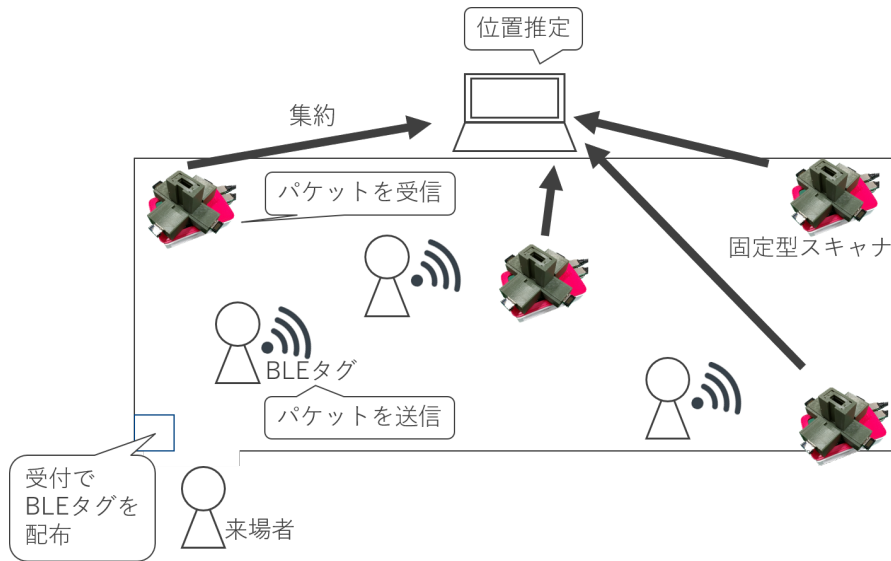


図 1.3: 提案する位置推定システムの概念図

悪いと推定が難しく，スキャナを高所に設置するなど機材の配置に注意が必要になる．UWB を用いるものは商用のシステムがあり，誤差が数十センチメートルと高精度であるが，機材が高額である．イベント会場でタグを配布して位置推定を行うには，会場の広さや来場者の数を考慮してスキャナもタグも多数用意する必要があり，高価な機材の導入は難しい．

以上より，タグを配布して行う位置推定では来場者の負担を抑えつつ，同一人物を追跡して位置推定を行えるため，イベント会場での利用に適している．一方で，見通しの確保のために機材の設置場所に注意が必要である，機材が高額であるなどの点により，イベント会場での利用が難しい．そこで，本研究では設置場所の制限が少ない安価な機材として BLE タグに注目し，図 1.3 に示すような，配布型 BLE タグを用い，信号強度をもとに行う位置推定を提案する．まず，イベントの来場者には受付で BLE タグを配布し，来場者は BLE タグを携帯して会場内を自由に移動する．その間，BLE タグは定期的に決まった形式のパケットを周囲に送信し，会場内に設置した複数の固定型 BLE スキャナでそのパケットを受信する．受信したパケットの情報は別のコンピュータに集約し，位置を推定する．

1.4 本研究のアプローチ・貢献

配布型 BLE タグを用いた位置推定では，来場者が携帯する配布型 BLE タグからの信号を会場内の BLE スキャナで収集するため，スマートフォンをスキャナとして用い会場内の BLE ビーコンからの信号を受信する方式と送信・受信側を入れ替えたものとなる．BLE は Bluetooth Low Energy

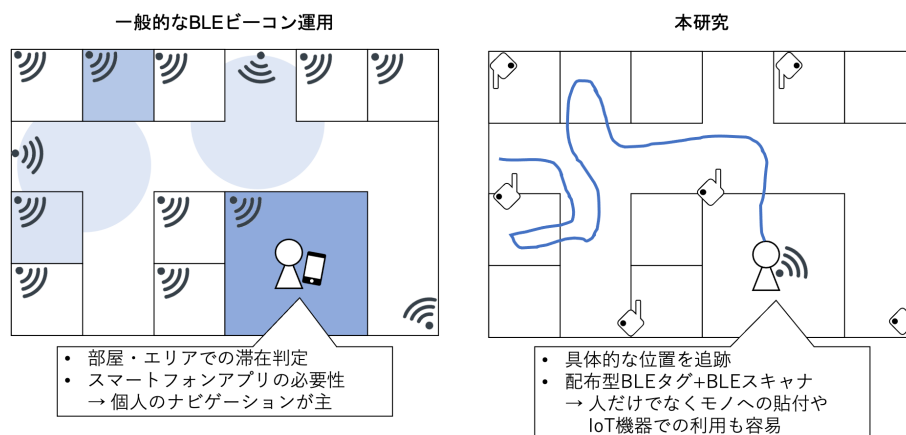


図 1.4: 一般的な BLE ビーコンの運用と、本研究で提案する推定方式の違い

の略で、Bluetooth バージョン 4 で規格に追加された通信方式である。既存の Bluetooth (クラシック Bluetooth) と同様に 2.4GHz 帯の電波を利用して通信を行うが、クラシック Bluetooth とは直接の互換性がない。一方で、名前のおと低消費電力での動作に焦点が当てられており、ボタン電池やさらに小型の電池で長期間動作可能なデバイスを構築できる。

BLE デバイスは特定の内容のパケットを定期的に周囲に送信するビーコン動作が可能であるため、あるデバイス周辺に他デバイスへの情報通知や、位置推定分野での利用が期待されている。しかし、受信される BLE の信号強度は用いるチャンネルや、信号の反射・干渉の影響を受けて不安定である。Apple 社が展開する BLE ビーコン規格である iBeacon[25] では、距離が Immediate(iBeacon デバイスと触れられる程度の至近距離), Near(およそ 1 から 3 メートル), Far(iBeacon デバイスを検出できるが距離がわからない) の 3 段階で検知されるようになっており、送受信間の具体的な距離の推定は行われていない。そのため、実際に運用されている BLE ビーコンを用いた位置情報サービスは、建物の各部屋に BLE ビーコンを設置し、どの部屋にいるかを取得するものとなっている。一方で、本研究で提案する配布型 BLE タグによる位置推定では、部屋単位の滞在判定ではなく、より広い空間における詳細な位置の取得を目指す。図 1.4 に一般的な BLE ビーコンの運用と、本研究で提案する方式についての概念図を示す。一般的な運用では、検知した BLE ビーコンの系列で移動が表現されるため、どこをどう移動したかという詳細な情報が得られない。本研究では「より広い空間」として、開けたブース展示により部屋のような閉所がなく、不特定多数の人が移動する屋内イベントに焦点をあて、実環境における BLE 位置推定に、広い空間における詳細な位置の取得という新たな視点を導入する。また、配布型 BLE タグはモノへの貼付も容易であるため、人だけでなくモノの位置推定にも利用できる。さらに、BLE タグとしての機能は性能や電力の面で

厳しい制限がある IoT 機器にも簡単に組み込めるため、位置推定で使われる他の通信方式やセンサと比べ、IoT 機器の位置を取得する基盤技術としても最適である。

BLE を用いた位置推定は、個人向けのナビゲーションなどを対象に、固定型の BLE ビーコンからのパケットをスマートフォンで受信する方式が多く研究されている。スマートフォンを用いた BLE 位置推定の研究でも信号強度の不安定さは問題として挙げられており、BLE ビーコンのパケット送信を高頻度に行う、フィルタリングを行って安定した値を得るなどの工夫が施されている。信号の不安定さは、配布型 BLE タグを用いて行う場合でも問題になるが、BLE タグ・BLE スキャナの仕様を自由に決められるため、受信機である BLE スキャナに工夫を施して安定した受信を狙える余地がある。一方で実際に配布型 BLE タグと固定型 BLE スキャナを用いた実環境でのデータ収集や位置推定は行われておらず、イベント環境でデータを収集するにはどのようなシステムを構築して運用すればよいか、どのようなデータが得られるか、またどのような精度で位置推定できるかが未知である。さらに、イベント環境の準備期間の短さを考えると、信号強度を用いる位置推定でよく行われる電波マップの構築は、事前データ収集が難しいため、イベント開始時に利用可能にすることが難しい。そこで本研究では、イベントでのデータ収集と位置推定について、以下の3つの項目を主たる技術的な貢献とする。

- (貢献 1) より安定してデータを取得できるハードウェアであるタンデム BLE スキャナの構築と実環境でのデータ収集
- (貢献 2) 短期のイベントを想定し、事前データ収集なしの位置推定と、ハードウェア設定を変更した際の精度の確認
- (貢献 3) より長いイベントを想定し、収集したデータから学習を行う、深層学習を用いた位置推定

貢献 1: 会場内に BLE スキャナを設置してデータを収集するためには、BLE スキャナの製作と、データ収集を行うシステムの構築が必要である。BLE スキャナには、広い会場でも機材価格を抑えるため、低価格な小型コンピュータを利用する。また、実際のイベント環境での実験において、BLE タグが送信したパケットが BLE スキャナに届かないパケットロスが頻発することがわかった。そこで、複数の Bluetooth アダプタを持つタンデム BLE スキャナを構築し、パケットロスをデータを集められるようにし、再び実際のイベント環境で実験を行い、タンデム BLE スキャナの有効性の確認と、得られたデータからイベント会場における信号強度の分布を確認する。以上、イベント環境でデータ収集を行うための BLE スキャナとデータ収集システムの構築、パケットロスを抑えられるタンデム BLE スキャナの構築を**貢献 1**とする。

貢献 2：展示ブースの骨組み工事や展示物の搬入などを経て会場の設営が行われるため、イベント準備期間中には会場内の電波的特徴が変化する。またイベント環境の準備期間は短く、電波マップを用いる手法で必要になるデータ収集を準備期間中に行うことは難しい。そこで事前のデータ収集を行えない、ごく短期間(数時間から数日)のイベント・長期のイベントの開始直後でデータ収集が十分でない状況でも利用できる位置推定手法を考える。この手法では信号強度を用いた送受信間の距離推定を利用し、パーティクルフィルタを組み合わせ位置を推定する。この推定手法の精度の確認には、実際にイベント環境で収集したデータを用い、BLE タグの設定を変更した場合や、会場内の BLE スキャナの設置数を減らした場合、タンデム BLE スキャナの利用 Bluetooth アダプタ数を変えた場合の精度の変化も確認する。以上、信号強度とパーティクルフィルタを用いた推定手法による事前データ収集なしでの位置推定と、実環境データを用いた精度検証を**貢献 2**とする。

貢献 3：イベントが1週間以上などある程度長い期間開催されれば、環境の電波的特徴を学習するためのデータ収集を行える。長期のイベントにおいては、イベントの途中から手法を切り替えて、より高精度な位置推定を利用することを考える。ここでは、深層学習を用いて、信号強度の時系列を入力に、推定位置を直接出力する Ent-to-end の推定手法を提案する。また、学習に用いるデータ量や利用可能なスキャナの数を変化させ、実際のイベントで発生するトラブルを想定して精度検証を行う。以上、信号強度の時系列を入力に、直接推定位置を出力する End-to-end の推定手法の提案と、実環境トラブルを想定した精度検証を**貢献 3**とする。

以上より、本研究の主たる貢献は、これまで詳細な位置の取得が難しく、部屋単位のような推定を行っていた BLE 位置推定に、より広い空間で詳細な位置を取得できるような発展を、人だけでなくモノや IoT 機器での利用も容易な形で与えたことである。それに対する技術的な貢献として、**貢献 1** から **貢献 3** までがあり、イベント環境で配布型 BLE タグを用いて位置推定を行うためのデータ収集用ハードウェアの構成から、実際の位置推定までを行った。さらに、実際の屋内イベントで、提案である配布型 BLE タグを用いた位置推定が実際に詳細な位置の取得に有効であることを確認したことも、実験環境ではなく実環境での運用を行う際の重要な知見である。また、「この場所でこれからしばらく人の位置を取得したい」という位置推定の需要は大規模イベント環境だけにとどまらず、店舗が新たな広告キャンペーンの集客効果を検証する場合や、ショッピングモールや駅で大型連休の混雑度を取得したい場合のような、ある期間で人の行動が変化する状況での応用も期待できる。また、期間限定でない環境でも提案する位置推定は利用可能であるため、博物館・水族館などでの常設運用も可能である。上記に挙げたように、BLE タグは人だけでなくモノでも可能であり、また IoT 機器との相性も良いことから、モノの位置推定や、IoT 機器の位置情報基盤

としての利用も可能で、これからの世界で人・モノが協調してよりよい生活を実現するための要素技術としての利用が可能になるため、本提案手法の応用の幅は広い。

1.5 本論文の構成

本論文の以降の構成は次のとおりである。本章ではユビキタスコンピューティング分野の一般的な背景と位置情報の利用・屋内位置推定について紹介した。さらに大規模イベントでの利用という観点から、配布型 BLE タグを用いた位置推定を提案し、本研究のアプローチをまとめた。

2章では、関連する分野の研究や事例を紹介する。またイベント環境で利用する観点から、どのようなアプローチが必要かをまとめ、位置推定システムの設計を考える。

3章では、**貢献1**に対応する、イベント環境向け BLE データ収集システムの構築、タンデム BLE スキャナの構築について説明する。さらに、実際の大規模展示会である G 空間 EXPO2016 で行った実験を紹介し、実験で収集したデータの分析から、タンデム BLE スキャナの有効性の確認・位置推定を行うための検討も行う。

4章では、**貢献2**に対応する、データ収集を行わない推定手法について述べる。この推定手法では信号強度と距離の関係を用いた会場全域での推定と、以前の推定位置を利用して現在位置を推定するパーティクルフィルタを用いる。

5章では、**貢献3**に対応する、学習用のデータを用いた、より高精度な推定手法について述べる。ここでは深層学習を用い、信号強度を補正して4章の手法と組み合わせる手法、信号強度の時系列を入力に使うモデルで位置を推定する手法の2つを考える。

最後に6章では、全体の内容をまとめて、イベント環境で行う位置推定について本研究で得た知見を総括する。

第 2 章

関連分野の研究

ここでは、位置情報を利用した情報の分析についての研究や位置情報を利用している事例について紹介し、屋内位置推定に利用される手法についてまとめる。まず位置情報の分析に関する研究や事例を紹介し、位置情報の利用がもたらすより快適・安全な生活の可能性を示す。次に、位置推定で用いられる手法を紹介し、本研究と関連が強い無線通信を用いる手法について詳しくまとめる。また、イベント環境で位置推定を利用する際に求められる要件についてまとめる。

2.1 位置情報を利用した情報分析に関する研究

GPS を利用した屋外での位置情報の分析や、無線通信を利用した位置情報分析について紹介する。

2.1.1 GNSS を利用した屋外位置情報分析

GPS をはじめとする GNSS (Global Navigation Satellite System) を用いて位置を取得できるデバイスが利用しやすくなり、屋外での位置情報の収集が容易になった。それにもなって、スマートフォンの地図アプリケーションや、位置情報を利用したゲームなどのような個人向けサービスだけでなく、屋外や都市において人や車両の位置を利用して様々な分析を行えるようになった。

実用の交通情報サービスとして、カーナビゲーションシステムの情報を集約し、災害時に自動車の通行実績を利用して通行可能な道を調べるもの [8] がある。都市のタクシー位置情報をもとにした利用曜日・時間帯や発着地点などの分析が、ポルトガルのリスボン [26] やアメリカ合衆国のニューヨーク [27] で行われている。BusBeat[7] では車両の GPS データから、広域の自動車移動に影響を及ぼす大規模イベントの発生を予測する手法が提案されている。

携帯電話やスマートフォン用のアプリケーションを稼働させている一般の人からデータを収集して、GPS の位置情報と他のセンサ情報を用いて分析を行う参加型センシングも提案されている。Blanke ら [28] は、スイスの屋外大規模イベントにおいて、イベント用の公式アプリケーションに GPS 位置情報を収集する機能を組み込み、混雑している時間帯・場所の分析や、歩行速度や進行方向の変化を分析している。位置情報と他のセンサの情報を紐つけた分析として、携帯電話のマイクを利用した騒音計測で都市の騒音公害マップを作成する NoiseTube[29] や、スマートフォンとガスセンサを用いて大気汚染の情報を収集する GasMobile[30] などが行われている。参加型センシングの仕組みを用いることで、多数のセンサを設置することが難しい都市圏でも、一般の人の協力を得て大規模な分析が可能になる。また、自転車に注目した手法として、YKOB[31] が提案されている。YKOB では、自転車走行者のスマートフォンの GPS 位置情報と加速度信号を利用して道路の状態を調査している。自動車でも同様に、スマートフォンの加速度データを利用して舗装の剥がれを検出する手法 [32] が提案されている。

ソーシャルメディア上の位置情報付き投稿を利用して、様々な場所で起きている出来事を抽出する手法も提案されている。EvenTweet[5] では地域のイベントが、D'Andrea らの手法 [6] では交通渋滞などの情報がそれぞれ抽出の対象になっている。

2.1.2 無線通信を利用した位置情報分析

GPS 位置情報の収集を行うには、スマートフォン上でアプリケーションを常に実行する必要があるが、バッテリー寿命への影響や、プライバシー面での問題があるため、無線通信を利用した位置情報分析も行われている。一般の人からのデータを集めるために、スマートフォン等の無線 LAN や Bluetooth の信号を観測する例が多い。無線 LAN や Bluetooth が有効になっているデバイスは周辺の基地局やデバイスを探索するため、探索用のパケットを傍受するデバイスを用いて、そのデバイス周辺にいる人を検出できる。これらの無線通信による人の検出は、監視カメラやレーザセンサを用いる人の検出と異なり、複数のデバイスの間で同じ人を追跡できる。

森本ら [22] は Wi-Fi パケットセンサを用い、商業施設のグランフロント大阪における人流の可視化や、高速道路の交通流の可視化を行った。Wi-Fi パケットセンサは、無線 LAN を備えたデバイスが周辺の基地局を探索するときに発する管理パケットを記録できるもので、複数を設置して同じ ID を持つデバイスを追跡すれば、これらの間の人々の移動を検出できる。浅尾ら [33] は、屋外に Wi-Fi パケットセンサを設置し、観光マーケティングや交通観測に向けた人の流動パターンの分析を行っている。Khaimook ら [34] も同様に Wi-Fi パケットセンサを用いて、岐阜県の商店街におけ

るイベントでの人の回遊行動を分析した。

Bluetooth を用いたものでは、Weppner ら [35] が Bluetooth のデバイス探索に応答したデバイスの数を元に空間の混雑度を推定する手法を提案している。周辺の Bluetooth デバイスを探索するスマートフォンアプリを用いた、屋外の音楽フェスティバルでの混雑度センシング [36] も行われている。Oosterlinck ら [37] は、ショッピングモールに複数の Bluetooth スキャナを設置し、各スキャナ間の人の移動を分析した。

これらの分析では、同じ人の追跡が可能である一方で、Wi-Fi パケットセンサや Bluetooth スキャナ間の移動について、詳細な情報を得られない。2つの Wi-Fi パケットセンサが時差をともなってそれぞれ同じ ID を検出した場合、その間を移動したことはわかっても、どの通路や道路を具体的にどう移動したかがわからない。また、近年ではプライバシー保護の観点から無線 LAN や Bluetooth のデバイス固有アドレスがランダム化されるようになりつつあり、同じ人の追跡も困難となっている。そこで、同じ人を確実に追跡でき、具体的な位置を推定できれば、これまでの密度や2点間の流動の分析に、さらに詳細な移動情報の分析を追加できる。

これには、屋内位置推定技術の導入が有効である。屋内位置推定では様々な方法が提案 [38, 39, 40] されている。推定で使われる情報は慣性センサで得る加速度信号、カメラで得る画像、無線通信の信号など多岐にわたっており、それぞれ精度や想定する利用状況が異なっている。機材の費用や計算コストなど、精度と空間の広さだけでは決まらない一長一短も存在するため、それらも考慮した手法の選択が必要となる。以降では、加速度を用いる手法・画像を用いる手法の紹介と、無線通信を用いる手法を別々に紹介する。

2.2 加速度や画像を用いる位置推定

加速度や画像を用いる手法では、推定対象が持っているセンサを用いて推定を行うため、環境に追加の機材を設置しなくてもよい点が魅力的である。これらの手法ではしばしばスマートフォン向けの実装が行われており、屋外で GPS を用いる場合と同じような屋内でのナビゲーションを実現するために研究されている。

2.2.1 加速度を用いる PDR

デバイスが持つ加速度センサ・角速度センサなどを用いて物理的な動きを検出し、それを元に以前の場所からどの方向にどれだけ移動したかを算出する手法のうち、人に対する手法を歩行者自律航法 (Pedestrian Dead Reckoning; PDR) と呼ぶ。1997 年には Judd[41] が専用のモジュールを

作成して加速度と地磁気を利用した推定を行っている。Beauregard ら [12] はヘルメットにとりつけたセンサの加速度信号から歩行を検知し、GPS の精度が低下する地点の精度保証に利用した。Kamisaka ら [42] は携帯電話を用いた PDR について議論し、スマートフォンを用いた PDR の可能性を示した。Chen らが提案した IONet[43] では、LSTM を用いた機械学習モデルを使って PDR を行っている。

PDR の特徴は、推定対象がセンサを装着して移動している必要があること・歩行開始からの相対位置が推定されることである。現代のスマートフォンは加速度センサ・角速度センサを内蔵しており、PDR を実行可能である。しかし、以前の位置からの移動を推定する相対測位であるため、誤差が少しずつ蓄積して長時間の利用では精度が低下しやすい。そのため、特定地点で絶対位置情報が得られるという条件を用いた補正も行われている [44]。

2.2.2 画像を用いる SLAM

カメラを用いて得られる RGB 画像や深度画像を用いて、周囲の環境地図 (特徴マップ) の作成と自身の位置推定を行う手法は Visual SLAM (Simultaneous Localization And Mapping) や Visual Odometry[14] と呼ばれる。これらの手法では、画像内の特徴点や画素の値をもとに、カメラの姿勢計算 (位置推定) と特徴マップの生成・更新を行う。コンピュータビジョン分野で研究が盛ん [45] な手法で、単眼カメラによる手法 [13] や、カメラ姿勢の計算と特徴マップの計算を同時に行う PTAM[46]、画素の値を直接使って環境の三次元的な構造を蜜に推定する DTAM[47] などを経て、いまではスマートフォンの AR (Augmented Reality) 技術などでも利用されている。

これらの手法は、空間中の絶対位置を高精度に取得できることである。かわりに、特徴点の抽出や特徴マップの作成などの処理が高負荷になりやすく、カメラを常時動作させる必要があるため端末のバッテリー寿命に影響しやすい。また、移動する障害物が画像内の大半を占める環境では、特徴マップ中でカメラ姿勢を推定できなくなることがある。

2.3 無線通信を利用した位置推定

無線通信は通信距離や周波数や変調方式によって様々なものが利用されており、環境中の無線基地局とあわせて位置推定を行う。また、位置推定のアプローチ自体もいくつかに別れており、近接度・三点測位・電波マップなどが用いられている。Liu ら [18] は、様々な通信方式・推定アプローチについて、その対象空間と精度を図 2.1 のようにまとめている。図より、通信方式によって対応する空間の広さや、精度が異なることがわかる。ここではまず、推定アプローチについて紹介して

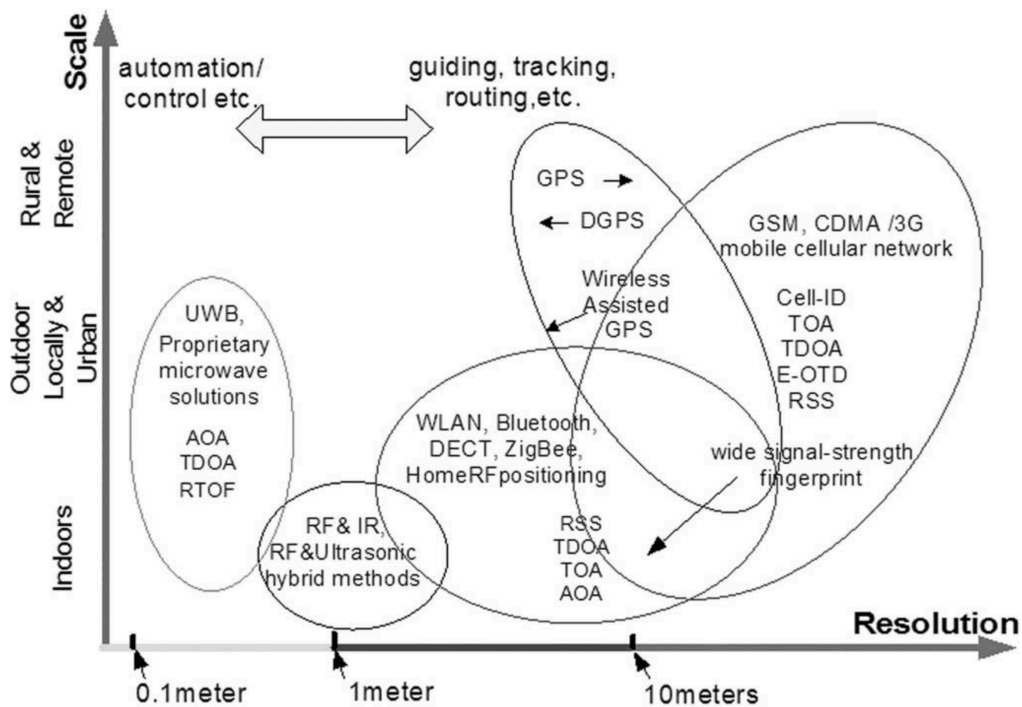


図 2.1: 無線通信を用いる位置推定の、対象空間と精度の概要 ([18] より引用)

から、個別の手法について述べる。

2.3.1 推定アプローチの概要

実際に無線信号を用いて位置推定を行うには、いくつかのアプローチがある。Yassin ら [39] は図 2.2 のような各アプローチの分類を紹介している。以降では近接度 (proximity)、三角測量 (triangulation)、電波マップ (scene analysis) の順で各アプローチを概観する。

近接度

近接度を用いた位置推定では、位置推定の対象となる空間に設置した位置が既知の複数の基地局のうち、どれに近いかを検出し、その位置を推定位置とする。複数の基地局が観測できる場合、最も強い信号強度のものが最近接の基地局として扱われる。そのため、ある基地局が最も強い信号強度となる範囲内では、その設置位置が推定位置として扱われるため、絶対的な位置が推定されるわけではない。

この手法は得られた信号強度から最も強いものを選ぶというシンプルな推定を行うため、実装が容易である。また、ある範囲内にいるかどうかという判定にも利用できるため、たとえば学校の各

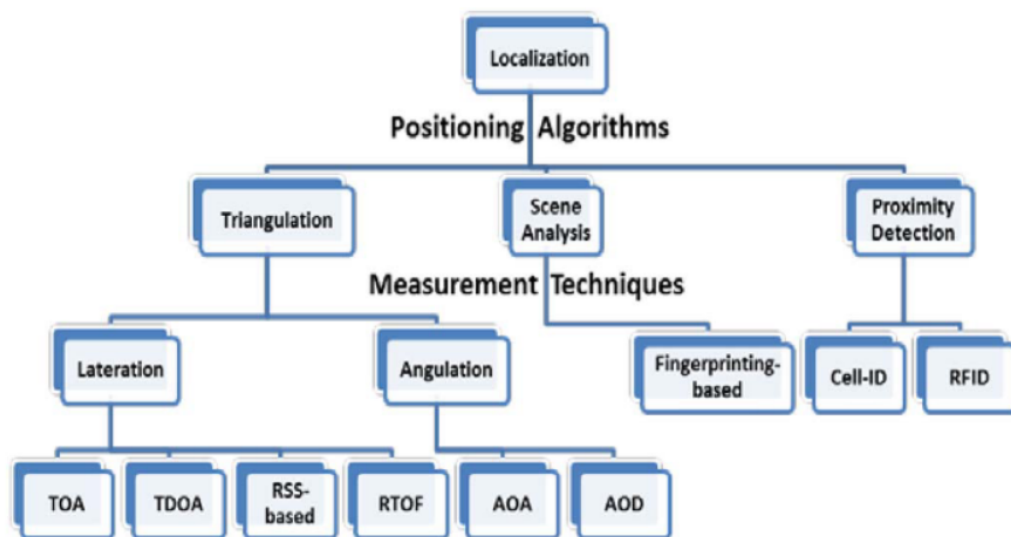


図 2.2: 推定アプローチの分類 ([39] より引用)

教室に 1 つずつ基地局を置き、どの教室にいるかを推定する用途では使いやすい。一方で、高精度に推定を行うためには多数の基地局を密に設置する必要が生じる、基地局が故障した場合は対応する位置での推定が行えなくなるなどの課題がある。

三角測量

三角測量を用いた位置推定では、推定対象と基地局との距離の推定、信号の到来方向の推定などを行って位置を推定する。

距離を用いた推定では、最低 3 つの基地局と推定対象との距離を用い、各基地局の位置を中心に円を描いてその交点を推定位置として利用する。距離の推定が正確に行えていれば描いた円が一点で交わるが、実際は推定には誤差が含まれるため、最も確率の高い位置を探す必要がある。距離の推定では、信号強度や信号の到来時間 (Time-of-Arrival; ToA)、到来時間の差 (Time-Difference-of-Arrival; TDoA) などが利用される。

信号の到来方向の推定では、複数のアンテナ (アンテナアレイ) で信号の到達時間差や信号の位相差などを検出し、信号がアンテナに対してどの角度から来たか (Angle-of-Arrival; AoA) を用いる。この場合は 2 つの基地局に対する AoA がわかれば、その交点を推定位置として利用できる。

三角測量では近接度と比較して絶対位置の推定が可能で、少ない基地局の数でも推定を行える。高精度な推定には正確な距離推定や角度推定が必要になる。ToA や TDoA の利用には高精度な時刻同期が必要だったり、AoA の利用にはアンテナアレイが必要になるなど、専用の機材が要求さ

れる。また、信号の干渉や反射が多い環境ではこれらの推定が難しい。信号強度は市販のデバイスでも取得しやすいが、干渉や反射の影響を受けて安定しない傾向にある。

電波マップ

電波マップを用いた位置推定では、推定がオフラインフェーズとオンラインフェーズの2段階に分かれる。オフラインフェーズでは、対象の空間内で電波的な特徴を収集し、電波マップを構築する。位置推定はオンラインフェーズで行われ、推定対象のデバイスで得た信号をオフラインフェーズで構築した電波マップとマッチングし、推定位置を探す。

このアプローチでは、対象の空間の各所における信号の干渉や反射などが電波マップに組み込まれる。そのため、三角測量を用いる場合よりも良い精度を達成しやすく、電波マップの形式や、マッチングの方法などが異なる多数の手法が提案されている。また、基地局の位置が既知でなくても利用できる点も特徴である。一方で、電波マップの構築には大きな労力が必要になるほか、基地局の移動や交換に伴って電波マップを更新する [48] 必要が生じる。

2.3.2 無線位置推定の各手法

ここでは、無線の方式ごとに分けて、無線通信を用いる位置推定を紹介する。

超音波

電波ではなく、超音波を用いた位置推定も行われている。多くの場合は天井に基地局として送(受)信機を設置し、推定対象が対になるデバイスを持って推定を行う。Bat[49]ではToF (Time-of-Flight; 信号の飛行時間)による距離推定が行われ、三点測位で三次元的な位置が推定された。Cricket[50]では複数の超音波受信機を使い、位置に加えて方向も含めた推定が行われている。DOLPHIN[51]では、送受信機が一体になったデバイスを用い、位置が未知のデバイスについて、推定できるものから順次推定する手法が提案された。また、Hazasら [15]は、直接スペクトラム拡散による符号分割多元接続 (DS/CDMA) を用いて、複数の推定対象を識別する方法を提案した。

超音波を用いた手法は数センチメートルの高精度が特徴となっている。一方で三角測量の項で述べたように、送受信機の間に見通しがない場合は推定が難しく、障害物の影響を受けやすい。また、音波を使うため送受信機間の距離が離れると減衰が大きくなるため、数十平方メートルの空間での利用に向いている、

RFID・UWB・ZigBee

RFID (Radio Frequency IDentification) は無線通信を用いたデータ交換する技術を指している。RFID タグと RFID リーダがセットで利用され、物品への電子的なタグ付けや、非接触の IC カードによる認証などで利用されている。交通系の IC カードや、万引防止のタグも一種の RFID とみなすことができ、近年では洋服店における会計の自動化で利用されること [52] もある。RFID を用いた通信は基本的に短距離を想定しており、また専用のリーダーが必要となるため、入退室の管理などでの利用が一般的である。LANDMARK[53] では自らが情報を発信するアクティブ RFID タグを利用して、RFID リーダ・参照用の RFID タグとの併用で位置推定を行った。Joho ら [54] は、RFID タグの検出情報と信号強度を利用し、空間中に設置された RFID タグの位置の特定と、自己位置推定を行っている。

UWB (Ultra-Wide Band) では、ごく短い時間の信号を広い周波数帯に送信して通信を行う。信号の時間的な短さにより、電波の反射によって信号の経路が複数生じるマルチパスの識別が容易であるとされている。位置推定は UWB の利用 [55] のひとつの形態として以前から議論 [56] されてきた。商用利用されているシステムとして Ubisense[57] があり、このシステムは 15cm 程度の精度をうたっている。機材の価格が高い・障害物が存在すると誤差が出やすいなどの理由で、一般の空間では広く利用されていないが、工場などで高精度な位置推定を提供している。

ZigBee は基礎的な仕様が IEEE802.15.4 で規定されている規格で、低価格・低データレートで電力効率に優れるネットワークを提供する。センサネットワークやスマートホーム家電などの制御でしばしば利用される通信方式である。たとえばスマート LED 電球には ZigBee で制御を行うもの [58] がある。利用する周波数帯が 2.4GHz 帯のほか、868MHz 帯、900MHz となっていることも特徴である。位置推定への利用は Fingerprint を利用したもの [59, 60] が提案されている。

無線 LAN

無線 LAN は 2020 年現在、ゲーム機やスマートフォン・ノート PC などが標準で備えている通信機能となっている。喫茶店や駅、飛行機内などに基地局が設置されており、広く一般で利用される通信である。そのため屋内位置推定の研究も特に盛んで、様々な手法が提案されている。

無線 LAN の信号強度を利用した位置推定では電波マップを用いる RADAR[61] が特に有名で、信号強度の空間における近傍を探索して位置推定を行う手法である。Youssef ら [62] は計算コスト削減のためにクラスタリングを用いる手法を提案した。無線 LAN を用いた手法では、電波マップがよく利用 [63] されている。藤田ら [64] は電波マップを正規分布の線形結合モデル (Gaussian

Mixture Model) で表現し、電波マップのデータ量を抑えて推定を行う手法を提案した。Ferris ら [65] は無線 LAN を用いた SLAM を提案し、電波マップの作成と推定を同時に行っている。電波マップに用いるデータは信号強度だけでなく、一部の IEEE 802.11n デバイスで取得可能な、無線 LAN のチャンネルごとの信号伝搬に関する情報である CSI (Channel State Information)[66] も利用されている。

近年では深層学習を用いた手法が開発されており、DeepFi[67] では CSI を入力にとる手法が提案された。また CiFi[68] では CSI から作成した AoA を示す画像を信号の畳み込みで特徴を認識する CNN (Convolutional Neural Network) に入力する推定手法を提案した。WiDeep[69] では信号強度を利用した深層学習による位置推定を行っている。信号強度の時系列を用い、時系列の特徴を認識する RNN (Recurrent Neural Network) で位置を推定する手法 [70] も提案されている。さらに、複数の建物・複数フロアでの使用を考慮した深層学習を用いる手法 [71] や、建物・フロアの識別・位置推定を同時に行う手法 [72] も提案されており、より柔軟な位置推定に向けた研究が行われている。

また、Dynamic-MUSIC[73] では CSI を用いて、推定対象が無線 LAN デバイスを所持していなくても推定できるデバイスフリー位置推定が提案されている。CSI の利用は位置推定だけにとどまらず、人の睡眠状態を認識する Wi-Sleep[74] でも利用されている。

BLE

BLE は Bluetooth 4.0 で追加された規格で、低消費電力が特徴である。周囲に情報を広告するのみのデバイス (BLE ビーコン) が位置推定にしばしば利用されており、位置推定専用のデバイス設置が行いやすい。Bluetooth を用いた位置推定の試みは以前から行われている [75, 76] が、BLE の登場により研究が活性化し、様々な手法が提案 [77, 78] されている。

BLE を用いた位置推定では、電波マップを用いた推定 [79] や三点測位による推定 [80] などが提案されている。Campana ら [81] は事前に収集した信号強度を用いてランダムフォレスト分類器を作成し、どの部屋に滞在しているかを推定した。Zafari ら [82] は複数のフィルタを利用して高精度化を狙った手法を提案している。また人の移動できる場所が柵によって制限される大型スーパーマーケットにおいて、移動できる場所をグラフ構造で表現し、そのどこにいるかを推定する手法 [83] も提案されている。BLoc[84] では BLE 版の CSI が提案され、高精度な推定が試みられた。深層学習を用いた手法も提案されており、Xiao ら [85] は入力した信号強度からノイズを除去するデノイジングオートエンコーダを用いて、入出力の類似度から 3 次元の位置推定を行った。また、信号強度が利用チャンネルごとに変化することに注目し、電波マップへの影響の調査 [86] が行われ

る、PDR との組み合わせが行われる [87] など、高精度な推定を目指して研究が進められている。これらは人がスマートフォンを持っており、固定型の BLE ビーコンから送信される信号を受信して行う方式の位置推定である。一方で、近接度を用いた老人ホームの入居者モニタリング [88] では、スマートフォンを持たない老人の滞在場所 (リビングのソファ周辺、キッチン周辺など) を推定するために、配布型 BLE タグと固定型 BLE スキャナを利用している。

一方、実用サービスとしては Apple 社が iBeacon[25] の名称で BLE ビーコン規格を展開している。信号強度をもとにした 3 段階の近接度が定義されており、同社の iOS で利用可能なため広く利用されている。空港スタッフの所在を管理する実証実験 [89] や、観光地のスタンプラリー [90] などで利用されている。観光向けの別の例として、BLE ビーコンとスマートフォンを用いたナビゲーションの実験 [91] が栃木県日光市で行われている。また、国土交通省の高精度測位社会プロジェクトによって、成田空港では BLE ビーコンを用いたナビゲーションが利用可能 [92] となっている。広い空間だけでなく、アートギャラリーの展示パネルにビーコンを設置して、スマートフォンに自動的に情報表示を行い、ギャラリーに訪れた人の没入感を高める Notify-and-Touch[93] もあり、ナビゲーションだけではなくサービスも提案されている。独自の拡張を施したビーコンを用いた高精度測位を謳う Quuppa[94] が商用サービスを展開するなど、研究と実用が非常に近い領域である。

2.4 大規模イベント環境での位置推定システムの要件

大規模イベント環境で人の位置情報を取得し、会場内の混雑度や来場者の移動経路を分析するには、来場者が会場に来てから帰るまでの間、継続的に位置推定を行う必要がある。来場者に位置推定への協力をしてもらいつつ、来場者を識別して継続的に追跡でき、会場内での移動経路を具体的に取得できる手法が必要となる。本研究では来場者への負担配布型 BLE タグを用いて位置推定を行うことにしたが、イベント環境特有の要素を考慮して近接度・三角測量・電波マップから利用できる推定アプローチを考える。

イベントは開催期間が限られた一時的なもので、会場設営時や撤収時に使える時間が限られており、会場が広い。精度を向上させるために多数の BLE スキャナを必要とする近接度方式は、基地局の設置や回収に困難が生じる。たとえば、展示ブースや通路の大きさの基準となる 3 メートルごとに 1 つの基地局を設置し、9 平方メートルに 1 つの密度にしようとする、30 メートル四方の会場でも 100 個の基地局が必要になる。この設置や回収はかなり大変な作業となり、また個数のぶんだけ必要な金額も大きくなるため、近接度方式は適さない。

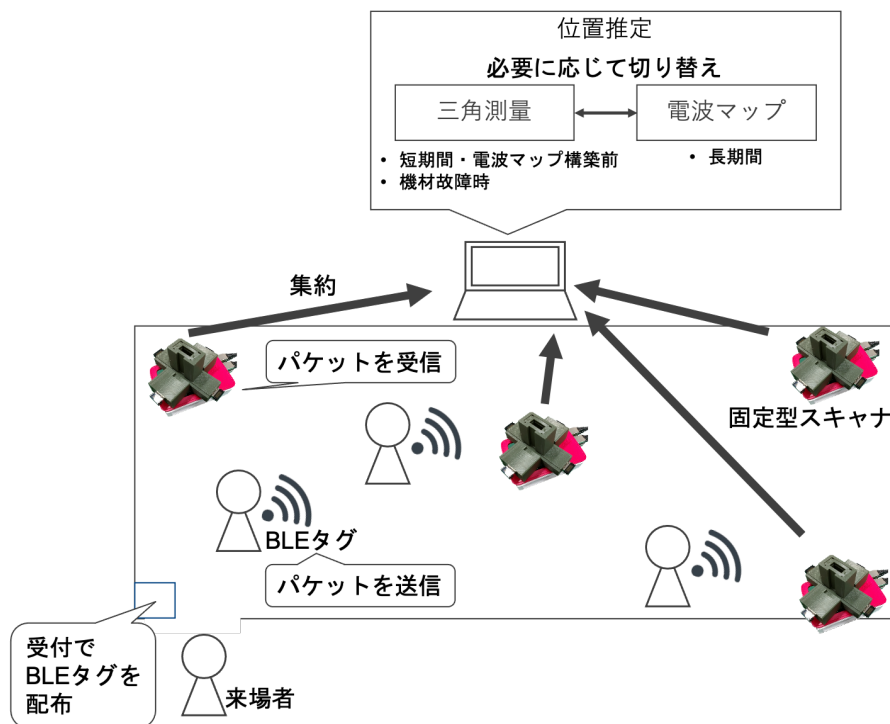


図 2.3: 提案する位置推定システムの概念図: 三角測量・電波マップ方式の推定とその切替の追加

三角測量方式の推定のうち、高精度な時刻同期や送受信間の見通しを要求する ToA や TDoA を用いる推定は、市販の BLE デバイスでは利用できない。したがって、BLE パケットを受信した際に得られる信号強度を用いて位置推定を行う。信号強度を用いる場合は、基地局の設置に関する条件として、会場内の各地で 3 台が観測可能というものが加わるが、これを満たせば設置の自由度は高い。一方、ブースの壁や展示品などで信号の干渉や反射が生じ、また来場者自身も障害物となるため、信号強度にはノイズが乗りやすく、他の BLE を用いる手法でも検討されているように、推定精度を上げる工夫が必要である。また、事前のデータ収集を必要としないため、準備期間が短いイベントでも利用しやすい点はこの方式の大きな利点である。

電波マップ方式の推定では、必要な基地局の数を減らせる一方で、事前の電波マップ構築時に会場全域でのデータ収集が必要になる。近接度と同様に 3 メートルごとにデータ収集を行う場合、各点で 60 秒計測を行うと 30 メートル四方の会場で 6000 秒 (100 分) が必要になる。必要になる時間次第では、限られた設営時間中に十分なデータを収集できない可能性がある。しかし、イベント期間が数時間や数日ではなく、1 週間や 1 ヶ月など比較的長期に渡る場合は、イベント開始から数日の間に電波マップ用のデータ収集を実行できるため、三角測量方式を最初使っておき、途中から切り替えての利用が可能になる。

以上より、配布型 BLE タグを用い、三角測量・電波マップ方式の位置推定を大規模イベント環境での位置推定システムの基礎的な設計とする。位置推定の方式も入れた概念図は図 2.3 のようになる。用いる推定方式はどちらか片方だけに絞らず、数時間から数日の短期間イベントや長期間のイベントの開始直後では三角測量を利用し、長期間のイベントでは電波マップを構築して推定方式を切り替えられるようにし、より高精度な推定を後から利用できるようなハイブリッド型の推定システムを前提に考える。このハイブリッド型では、時間経過での推定方式の切り替えだけでなく、機材故障で電波マップの方式が利用できない場合に三角測量に戻すといった、位置推定を止めずに継続して利用するような工夫も可能になる。実際のイベント環境でこの設計を用いるデータ収集の試みは行われていないため、以降ではデータ収集を行うデバイスの構築、データ収集システムの構築と実環境での実験を行い、収集したデータが位置推定に使えるかを確認するところから始める。

第 3 章

タンデム BLE スキャナの構築と実環境におけるデータ収集

本章では、実際に配布型 BLE タグを用いて位置推定を行うための、具体的なデバイスやデータ収集システムを説明する。また、前章で述べたように、アドバタイジング側のパケット送信頻度が低くても安定した受信を行うためのタンデム BLE スキャナを構築する。タンデム BLE スキャナを用いてデータ収集を行った実際の屋内イベントについて紹介し、実験用に構築したデータ収集システムについて述べる。その後、得られたデータの分析も行って、位置推定に利用できるような特徴を持つかどうかの検証と、実環境におけるタンデム BLE スキャナによるパケットロスの低減効果の確認を行う。

3.1 BLE の概要

まず、BLE で行われる通信の仕様について、バージョン 4.0 のものから本研究に関わる部分をまとめる。参考までに、Bluetooth 全体を含めた説明については付録 A にまとめた。

BLE (Bluetooth Low Energy) は 2010 年にリリースされた Bluetooth バージョン 4.0 から導入された仕様である。BLE は Nokia 社が開発していた Wibree という規格を源流 (2006 年に発表後、2007 年に Bluetooth との統合を発表) としており、BLE ではないクラシック Bluetooth と直接の互換性はない。Low Energy の名前の通り低消費電力を主眼としており、大容量のバッテリーを搭載できないスマートウォッチやセンサが利用することを念頭に置いている。




図 3.1: BLE のチャンネル

3.1.1 使用する周波数帯とチャンネル

BLE では 2MHz 幅のチャンネルを 40 個用いて通信を行う。チャンネルのうち 3 つはアドバタイジングチャンネル、残りの 37 チャンネルはデータチャンネルとして利用される。BLE 機器同士の探索・接続や情報のブロードキャストはアドバタイジングチャンネルを通して行い、接続が確立してからはデータチャンネルで周波数ホッピングを行いながら通信を行う。チャンネルの中心周波数は以下の式 3.1 に従う (ただし、アドバタイジングチャンネルの割り振りのため k とチャンネルの番号は一致しない)。

$$f_c = 2402 + 2k \quad (k = 0, 1, 2, \dots, 39) \quad [MHz] \quad (3.1)$$

各チャンネルの中心周波数と番号の対応を図 3.1 に示す。図内に橙色で示すチャンネルがアドバタイジングチャンネルで、残りはデータチャンネルである。アドバタイジングチャンネルの中心周波数はそれぞれ ch37, 38, 39 の順に 2402, 2426, 2480MHz となっており、無線 LAN で利用されるチャンネルの間に入るように割り当てられている。

3.1.2 接続形態とアドバタイジング・スキャンの仕様

BLE は接続形態がクラシック Bluetooth とは異なっており、必ずしも親機・子機間での接続を必要としない。接続を確立した親機・子機による 1 対 1 の通信だけでなく、あるデバイスが周辺のデバイスにブロードキャストを行える。ブロードキャストは周囲への情報配信に適した形で、本研究で用いる BLE タグもブロードキャストを用いて周囲に自身の情報を広告する。

ブロードキャストでは BLE で定義されている 5 つの状態のうち Advertising の状態を用い、アドバタイジングチャンネルへパケットを送信する。アドバタイジングパケットはそれを送信したデバ

イスに合わせていくつかの型が決まっており、BLE タグの場合は ADV_NONCONN_IND という、外部からの接続やスキャン要求を受け付けず、受け取り対象のデバイスを限定しないものを利用する。

このブロードキャストされているパケットの取得には、Scanning の状態にしたデバイスを用いる。この状態のデバイスはパッシブスキャンとアクティブスキャンの 2 種類を実行できる。アクティブスキャンでは Advertising 状態にある周辺のデバイスにパケットを送信するようスキャン要求を出せる。パッシブスキャンでは一切パケットを送信せず、アドバタイジングチャンネルの監視のみを行う。BLE タグはスキャン要求を受け付けない型のパケットを用いるため、スキャンはパッシブスキャンとする。

3.1.2.1 アドバタイジングとスキャンの制約

アドバタイジングでは、1 度に 1 つのパケットを 1 つのアドバタイジングチャンネルに送信できる。2 つのアドバタイジングパケットの間隔 ($T_{advEvent}$) には制限があり、以下の式 3.2 によって計算される。

$$T_{advEvent} = advInterval + advDelay \quad (3.2)$$

ここで、 $advInterval$ はパケットの送信間隔で、最低 20 ミリ秒から最大が 10.24 秒まで、0.625 ミリ秒の整数倍で選択できる。BLE タグが利用する ADV_NONCONN_IND 型のパケットでは追加の制限があり、 $advInterval$ の下限が 100 ミリ秒となる。したがって、BLE タグは最も頻繁にアドバタイジングパケットを送信しても、約 10Hz が上限となる。

$advDelay$ はアドバタイジングパケット同士の衝突や干渉を避けるための値で、0 から 10 ミリ秒の間でパケットごとに疑似ランダムに設定される。図 3.2 に $advInterval$ と $advDelay$ によるアドバタイジングパケット送信の時間的なランダム化について示す。

スキャンに関しては、監視するアドバタイジングチャンネルの選択やタイミングについての厳格なルールは存在しない。基本的にスキャン中のデバイスは 3 つのアドバタイジングチャンネルに対して一定の時間窓 ($scanWindow$) でスキャンを行う。一度スキャンを始めてから次のスキャンを行うまでの間隔は $scanInterval$ で決定される。各スキャン窓において、スキャン対象となるチャンネルは前回と異なるものでなければならない。また、3 つのチャンネルはすべてがスキャン対象となっている必要がある。したがって、チャンネルの順序のみが自由となっている。また、同時に複数のチャンネルを監視することはできず、パケットを受信した際にどのチャンネルで得たパケットかも検出でき

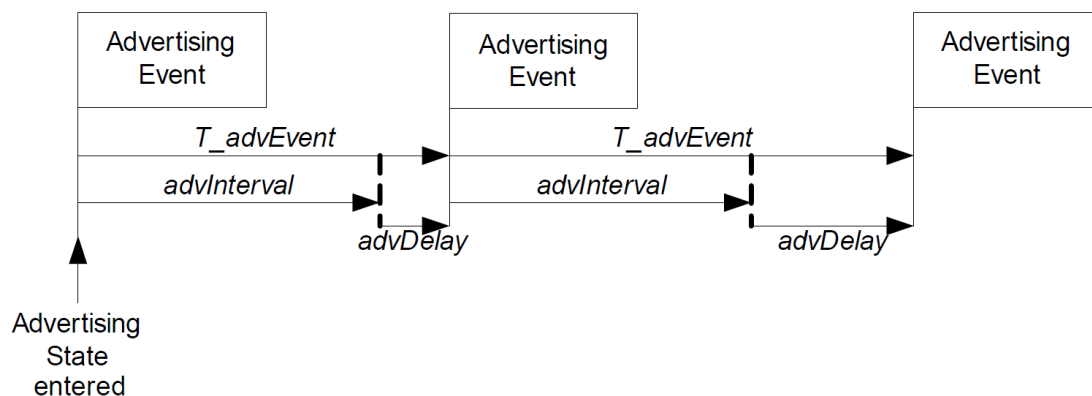


図 3.2: $advDelay$ を用いたアドバタイジングパケット送信の時間ランダム化 ([95] より引用)




図 3.3: スキャン窓を用いたアドバタイジングチャネルの監視 ($scanInterval < scanWindow$ の場合). 実際は対象のチャネルがこの順序で現れるとは限らない.

ない.

$scanInterval$ は 10.24 秒以下となっている必要がある. $scanWindow$ は $scanInterval$ 以下に設定しなければならず, $scanInterval = scanWindow$ の場合, デバイスは常にどこかのアドバタイジングチャネルに対してスキャンを行う. 図 3.3 にスキャン窓を用いたアドバタイジングチャネルのスキャンの例を示す.

以上のアドバタイジングとスキャンの制約により, ある時刻 t_{adv} であるチャネル ch_{adv} に送られたアドバタイジングパケットが受信されるのは, スキャナが t_{adv} において ch_{adv} をスキャンしていた場合のみである. したがって, アドバタイジングおよびスキャンに対して設定されるパラメータである $advInterval$ や $scanWindow$, $scanInterval$ がパケットの受信可否に影響を及ぼす.

3.1.3 パケットロス低減の必要性

配布型 BLE タグを用いる位置推定では, BLE タグからのアドバタイジングパケットを BLE スキャナが取得し, それをもとに行う. 前述のように, アドバタイジングとスキャンのタイミングが合致しないと BLE スキャナ側がアドバタイジングパケットを取得できない (パケットロス). また,



図 3.4: BLE スキャナ

BLE では、同じチャンネルに同時にパケットが流れるとパケットの衝突が起きる。3つのアドバタイジングチャンネルとパケット送信時に付与される *advDelay* が衝突の回避を担うため、アドバタイジングを行うデバイスが増えると衝突の確率が上がる。衝突が起きた場合もパケットロスとなる。

パケットロスがあまりに多いと、ある BLE タグからのパケットは途切れ途切れにしか取得できなくなり、位置推定を行えなくなる。そこで、BLE タグを位置推定に利用する場合、アドバタイジング側のパケット送信頻度を抑えつつ、より安定して受信を行えるような構成を取る必要がある。

3.2 イベント向け BLE 位置推定システムの具体的な構成検討

前章の図 1.3 で示した位置推定システムの具体的な構成を考える。位置推定で利用するハードウェアは、BLE タグと BLE スキャナの 2 種類が主となる。

BLE タグは市販品を利用できる。ADV_NONCONN_IND 型のアドバタイジングパケットを送信できるものでよいが、パケット内容やアドバタイジングの間隔を自由に変更できるものが望ましい。これは、BLE タグ以外にも多くの BLE デバイスが環境内に存在しており、位置推定で用いる BLE タグと、そうでない他の BLE デバイスを識別する情報が必要となるためである。

BLE スキャナはアドバタイジングパケットを受信できるものであればよく、スマートフォンや小型コンピュータが利用可能である。しかし、スマートフォンは単価が高く、イベント会場に放置すると持ち去られてしまう恐れがあるため、安価に入手できる小型コンピュータの使用を考える。

実際には BLE タグと BLE スキャナ以外に別のコンピュータを用意し、各 BLE スキャナが収集したパケットを転送して集約する。このコンピュータにはじゅうぶんな記憶域がある以外の特別な条件は存在しないが、潤沢な計算資源(多数の CPU コア・大容量メモリなど)が使用可能であればリアルタイムな推定も可能になり、混雑度に合わせて動的に人を誘導できるなどの応用が行える。

表 3.1: Raspberry Pi 各モデルの性能諸元

モデル	登場時期	CPU	メモリ	備考
1 B+	2014 年	BCM2835 (700MHz シングルコア)	512MB	
2 B	2015 年	BCM2836 (900MHz クアッドコア)	1GB	スペック違いの v1.2 が存在
3 B	2018 年	BCM2837 (1.2GHz クアッドコア)	1GB	1.4GHz 動作の B+ が存在
4 B	2019 年	BCM2711 (1.5GHz クアッドコア)	1/2/4/8GB	

3.2.1 用いる BLE スキャナの基本仕様

BLE スキャナは、小型コンピュータである Raspberry Pi[96] に市販の USB 接続型 Bluetooth アダプタ (受信機) を取り付けて利用する。BLE スキャナの写真を図 3.4 に示す。

Raspberry Pi はもともと教育用として開発されたクレジットカード程度の底面積のシングルボードコンピュータである。日本では 1 台 5000 円程度で販売されており、安価に高性能な小型コンピュータを製作できる。新バージョンの本体が登場するたびに高性能化・高機能化が行われており (主要諸元は表 3.1 参照)、消費電力が増えているものの本体のみでより複雑なデータ処理が可能になっている。

Raspberry Pi 上では OS として、Debian という Linux ディストリビューションをベースにした Raspberry Pi OS (旧名 Raspbian) を動作させる。Raspberry Pi OS の利用により、パッケージ管理システムを用いて容易にソフトウェアを導入でき、Python のような記述が簡便なプログラミング言語を使用できる。また、リモートログインも行えるため、使用中の BLE スキャナの管理も容易である。

実際のパケット受信は、Python から BlueZ[97] という Linux 向け Bluetooth プロトコルスタックを操作して、Bluetooth アダプタでパッシブスキャンを行わせて実現する。受信したアダプタイジングパケットは Raspberry Pi の本体ストレージ (microSD) に保存すると同時に、ログ転送ツールである fluentd[98] を用いてネットワーク経由でログ収集用サーバに転送する。fluentd はデータのバッファリングや送信失敗時のリトライが可能で、より安全にデータを転送できる。なお、Raspberry Pi には RTC (Real Time Clock) が搭載されておらず、電源が切れると時刻情報を保持で

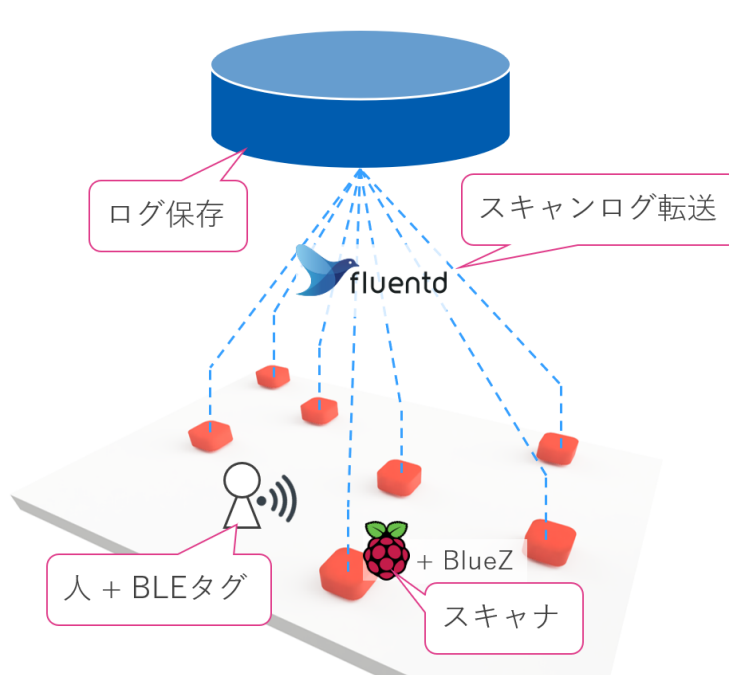


図 3.5: BLE スキャナで用いる技術を追加したデータ収集システムの概念図

きない。そこで起動時に NTP (Network Time Protocol) を用いて時刻を取得するように構成し、さらに起動状態では定期的に NTP による時刻同期を行って、正確な時刻を記録するようにする。

Raspberry Pi の利用により、BLE スキャナを簡単に構築でき、さらに運用中の管理や、外部へのデータ転送を実現でき、データ収集を行う際の設定に必要な労力を低減できる。以上をまとめると、データ収集システムの概念図は図 3.5 のように更新される。実際にイベント環境で位置推定を行う場合は、各 BLE スキャナから収集した情報を保存するサーバと連携して、位置推定を実行する部分加わることになる。

3.3 G 空間 EXPO2015 での実験における実環境でのパケットロス状況の確認

ここでは、実際にデータ収集システムを構築して行った、実際のイベント環境におけるデータ収集の実験について述べる。実験は、日本科学未来館で開催された G 空間 EXPO2015 で行った。G 空間 EXPO は地理空間情報活用推進基本計画に基づいて、G 空間情報 (位置と時間の情報) を活用する社会の実現に向け、産官学の連携により開催されている。2010 年に初回が開催され、2012 年の第 2 回からは毎年開催されている。2015 年の G 空間 EXPO は 11 月 26 日、27 日、28 日の 3 日

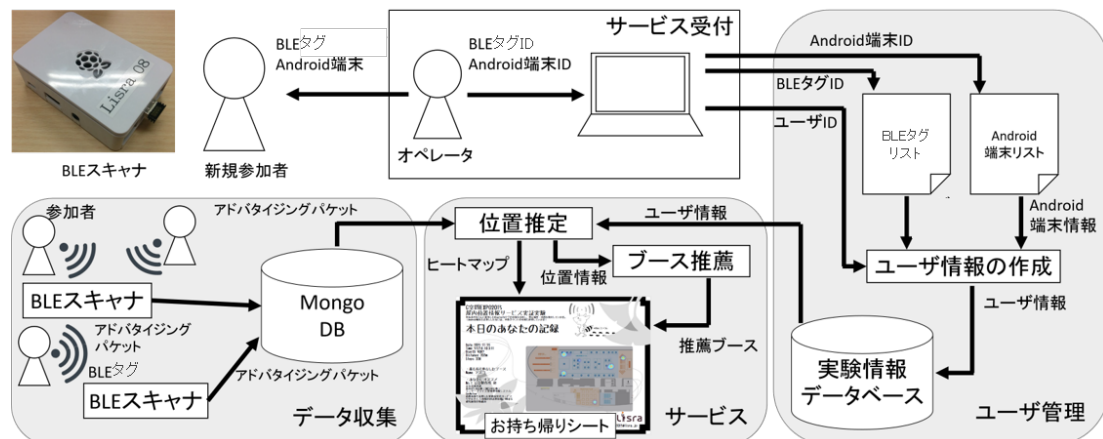


図 3.6: G 空間 EXPO2015 でのデータ収集システム

間で開催され、それぞれ 4,897 名、7,436 名、6,523 名が来場し、3 日間の来場者数はのべ 18,856 名だった。会場は 10 時から 17 時まで開いており、入場無料で年齢制限なく、幅広い年齢層の人が訪れた。実験では、3 日間でのべ 185 名が参加し、受付で BLE タグを受け取って会場内を観覧した。

3.3.1 データ収集システム

G 空間 EXPO2015 の実験では、図 3.6 のようなデータ収集システムを構築した。被験者はサービス受付で BLE タグと Android スマートフォン（同時に行っていた他の実験用）を受け取り、場内を観覧する。サービス受付では貸し出した BLE タグと Android スマートフォンの情報を手動で入力し、被験者の管理情報を生成させるようにした。

実際のデータ収集では、BLE スキャナで得たパケットは fluentd を通して外部のサーバに送信し、サーバでは MongoDB というデータベースに記録するようにした。また、被験者へのサービスとして、前日夜に各ブースに BLE タグを設置して収集した信号強度との類似度を使った簡単な滞在ブース推定を行い、長く滞在していたブースの情報と、それに基づくおすすめブースを推薦する紙を印刷して提供した。

3.3.2 会場内の BLE スキャナ配置

実験では日本科学未来館の 1 階に合計 30 台の Raspberry Pi 1B+ をベースにした BLE スキャナ（外観は図 3.4 と同様）を設置した。実際の配置は図 3.7 に示すとおりで、黄色い円の番号はスキャナの番号である。図内に青く網掛けされたメインエリアが主な展示ブースのある領域になっている。メインエリアはイベントが開催されていない時は図 3.8a のようになっており、G 空間





図 3.7: G 空間 EXPO2015 での BLE スキャナ配置図



(a) 設営前のメインエリア ([99] より引用)



(b) 設営後 ([100] より引用)

図 3.8: G 空間 EXPO2015 の展示ブース設営前後の様子

EXPO2015 では図 3.8b のように各種の展示が設営された。その他の場所でも G 空間 EXPO の展示が行われていたため、スカナは 1 階の全域に配置した。

3.3.3 利用した BLE タグ

G 空間 EXPO2015 の実験では、FDK 株式会社の「ここログ」AZ001 を 120 枚用意した。BLE タグを所持した被験者の様子を図 3.9 に示す。jaca 被験者はネームホルダを使って BLE タグを持ち歩いた。

AZ001 はごく薄いカード状の BLE タグで、1 秒に 1 度、独自形式のパケットを送信する。パ



図 3.9: G 空間 EXPO2015 での被験者

ケットは先述の ADV_NONCONN_IND 型となっているが、内容は自由に変更できず、BLE タグ個体の識別は MAC アドレスに依存した。また、BLE タグ自体の設定変更は BLE タグが起動している状態で設定変更のコマンドを送信する必要があり、120 枚の BLE タグすべてで行うのは事実上不可能であった。

これらのデータ収集システムと BLE タグは、それぞれ情報の手入力や、パケット内容の書き換え不可・設定変更の難しさなど運用しづらい面があった。そのため、より運用しやすいシステム構成や扱いやすい BLE タグが必要であることがわかった。

3.3.4 パケットロス状況の確認

会場内の大きな通路を受付位置から反時計回りに 1 周歩いた被験者について、正解となる位置情報を作成した。歩行開始時・終了時・左折時にその時刻を記録して、その間を等速で移動したものとして扱い、正解の位置情報とした。

この被験者の歩行中に各 BLE スキャナで観測されたパケットの信号強度と正解位置から算出した理想の信号強度を、一部のスキャナについて図 3.10 に示す。図内の各グラフは横軸で歩行開始からの秒数を、縦軸で信号強度を示すようにした。各グラフにおいて青い線は理想の信号強度を示し、緑色の点は実際に観測された信号強度を示す。

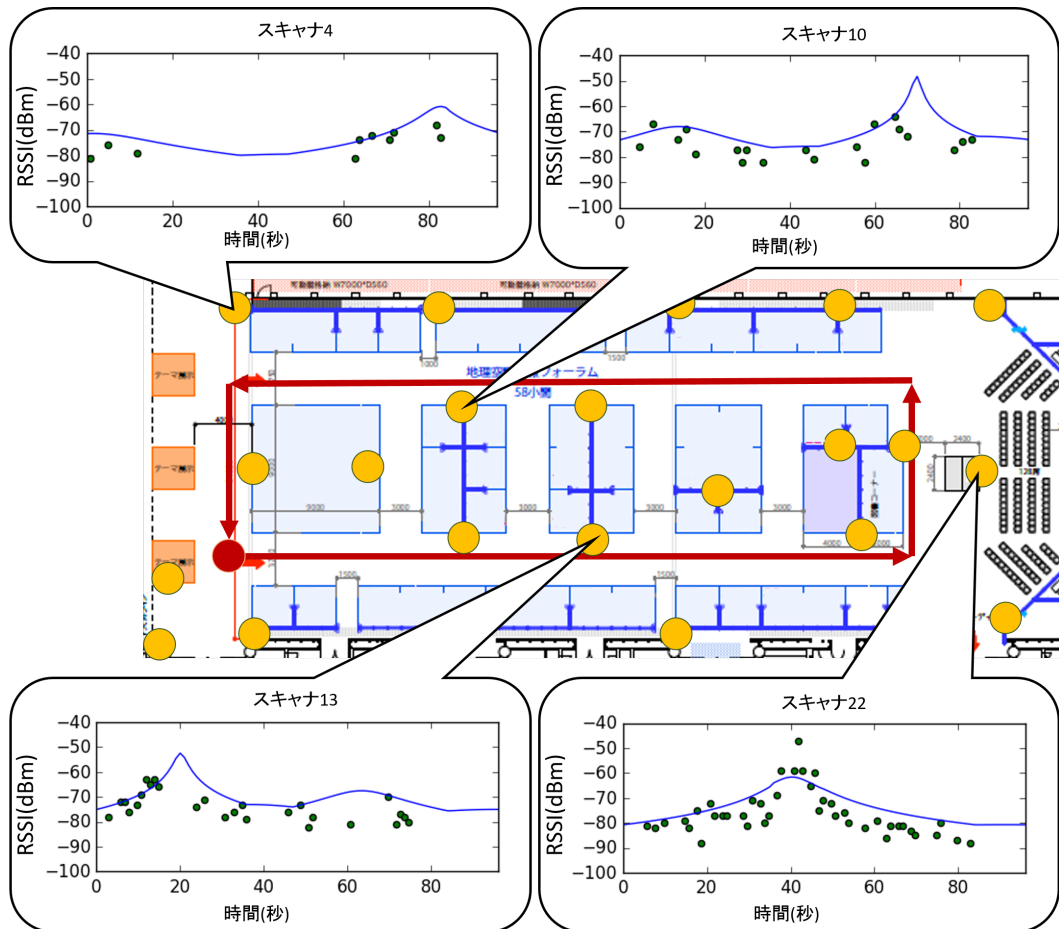


図 3.10: 半時計回りに歩いた被験者についての、実際に観測されたパケット信号強度と、理想の信号強度

図より、BLE スキャナによって観測したパケット数に大きな差があったことがわかる。スキャナ 4 ではほとんど観測できておらず、逆にスキャナ 22 では観測数が多い。スキャナ 10 やスキャナ 13 では歩行開始から終了までまばらにパケットを観測している一方で、被験者が最接近しているとき(理想の信号強度が極大のとき)に観測していない。これらより、スキャナが BLE タグからのパケットを観測できていないパケットロスが多数発生していることがわかった。そのため、より安定してパケットを収集できる改善が必要である。

3.4 タンデム BLE スキャナの構築

G 空間 EXPO2015 の実験で、実環境で BLE スキャナを用いると、多くのパケットロスが発生していたことがわかった。パケットロスが発生している状況では信号強度を得られず位置推定を行え




図 3.11: 7 個の Bluetooth アダプタを扱うタンデム BLE スキャナの例

ない。パケットロスの原因のひとつに、アドバタイジングパケットが BLE スキャナに到達した時点で、BLE スキャナが違うチャンネルを監視していた可能性が考えられる。BLE 仕様の制限により、アドバタイジングパケットは同時に複数のチャンネルには送信できず、スキャンも同時に複数のチャンネルに対しては行えない。そこで、擬似的に複数のチャンネルをスキャンしてより受信できる確率を上げられないかと考え、1 台で複数の受信機を備えるタンデム BLE スキャナを構築してパケットロスの低減を図ることにした。

Raspberry Pi は 4 つの USB ポートを備えており、また BlueZ では複数台の Bluetooth アダプタを個別に制御可能である。そこで、Raspberry Pi 3 に USB ハブ経由で複数の Bluetooth アダプタを取り付け、それぞれのアダプタでアドバタイジングパケットを記録できるタンデム BLE スキャナを構築した。アドバタイジングパケットの記録では、Bluetooth アダプタ毎にスレッドを生成して、USB バスの専有以外で可能な限り処理の並列性が高まるようにプログラムを記述した。タンデム BLE スキャナの例を図 3.11 に示す。このタンデム BLE スキャナは、実験的に 7 個の Bluetooth アダプタをシャフトに一系列に固定し、USB 延長ケーブルと USB ハブを介して Raspberry Pi 本体と接続する構成とした。

3.4.1 タンデム BLE スキャナを用いたデータ受信実験

タンデム BLE スキャナによるアドバタイジングパケットの受信状況について、名古屋大学の工学部棟内で 2 種類の実験を行った。各実験は (1) アドバタイジングパケットの受信回数の調査、(2) 距離に応じた信号強度の変化の調査である。この実験では、BLE スキャナのハードウェアを流用




図 3.12: 送信機に対する受信アダプタの配置

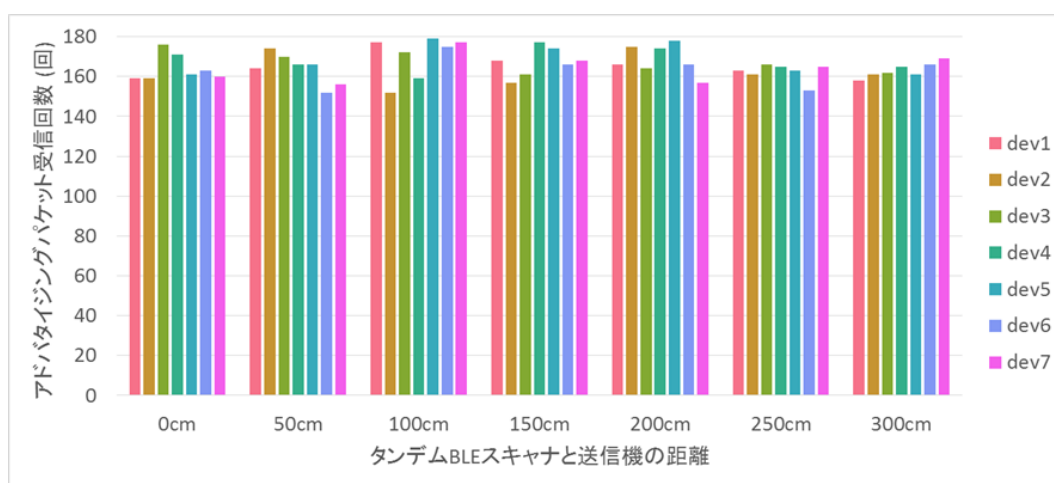


図 3.13: 各距離・各受信アダプタにおけるアドバタイジングパケットの受信回数

して作ったアドバタイジングパケット送信機を BLE タグの代わりに用いた。

実験 1: アドバタイジングパケットの受信回数の調査

タンデム BLE スキャナを用いて、送受信間の距離を変化させてアドバタイジングパケットの受信数を計測する。図 3.12 に示すように、タンデム BLE スキャナの 7 個の Bluetooth アダプタのうち中央 (dev4) の正面に送信機を設置した。送信機は BLE タグと同様の ADV_NONCONN_IND 型のパケットを送信するように設定した。

Bluetooth アダプタを固定している棒と垂直に、0cm から 50cm 刻みで 300cm まで送信機の位置を移動させ、各距離でパケットの受信を行わせた。送信機は 1Hz の周波数 ($advInterval = 100$ ミリ秒) でアドバタイジングパケットを送信させるようにし、その際のアドバタイジングパケット受信回数を数えた。各距離での 180 秒間の記録を図 3.13 にまとめた。

送信機は 1Hz を設定していたため、180 秒の計測では 178 個から 180 個のパケットが送信され

たはずである(1度の送信には0から10ミリ秒のランダム遅延が足されるため、177回目の送信が終わった時点で177+1.77秒を消費している可能性がある)。図を見ると、0から300cmというかなり近い距離であっても受信回数が160を切るような受信アダプタがあり、また同じ距離でも受信アダプタによって受信回数変動することがわかった。そのため、たとえば100cmのときにdev2の受信アダプタでは受信回数が少ない一方で、同じ距離のdev1やdev5の受信アダプタがあれば補うことが可能で、タンデムBLEスキャナを用いることでパケットロスを低減できるといえる。タンデムBLEスキャナの実現は、既存のBLEスキャナにBluetoothアダプタを複数取り付けるというシンプルなアイディアによるため、機材価格の上昇が少なく、構築に必要なハードウェアも大差ないため、安価な既製品を用いてBLEスキャナとするというイベント環境向けBLE位置推定の基本的な姿勢を崩すことなく、安定した受信を実現できる。

実験2: 距離に応じた信号強度の変化の調査

複数のBluetoothアダプタで、それぞれ違う信号強度が記録されるかどうかを確認する。実験1と同じように、図3.12に示すような配置で、0cmから50cm刻みで300cmまで送信機の位置を移動させ、各距離でパケットを受信させた。送信機の設定は10Hzでパケットを送信するように変更し、各距離で180秒の間記録を取って図3.14にまとめた。

図より、どのBluetoothアダプタでも距離が離れると信号強度が弱くなり、信号強度にも分散が生じることがわかる。また、図内のいくつかのグラフでは、信号強度が数段階になっている。dev2の0cmやdev6の200cmなどで3本の線のように、dev4の50cmやdev6の50cmなどでは2本の線のようになっており、ノイズの影響とは考えづらい特定の信号強度が現れている。

信号強度が3段階になっていることから、送信機が用いたアダプタイジングチャンネルの可能性を考えた。アダプタイジングチャンネルは図3.1で示したように、異なる周波数の3つが用意されている。通常はパケットの送信時にどのアダプタイジングチャンネルを使うかが自動的に決定される。この際、どのチャンネルを使ったかによって送信機と受信機の位置によっては得られる信号強度に差が生じ、複数本の線として現れたと考えて追加の実験を行った。

追加実験: チャンネルによる信号強度の変化の調査

送信機として使っているRaspberry Piのアダプタイジングパケット送信用プログラムを編集し、パケットを送信するアダプタイジングチャンネルを選択できるようにした。このプログラムを用い、1つのアダプタイジングチャンネルのみにパケットを送信して、先の実験と同様に180秒間データを記録した。図3.14で明確に3段階の信号強度が確認できた、Bluetoothアダプタdev2の0cmと




図 3.14: 各距離・各受信アダプタにおけるアダプタイジングパケットの信号強度

dev6 の 200cm について、それぞれ図 3.15a と図 3.15b に結果を示す。各アダプタイジングチャンネルは周波数が低い順に ch37 と ch38 と ch39 で示し、chall として図 3.14 から抜粋したものも示した。どちらの図でも横軸に計測開始からの時間 (0 から 180 秒) を、縦軸に信号強度を取った。

図 3.15a より、Bluetooth アダプタ dev2 の 0cm では ch37 のみ信号強度が低く、ch38 と ch39 ではほぼ同じ信号強度だった。図 3.15b より、dev6 の 200cm では ch39 のみ信号強度が高く、ch37 と ch38 がほぼ同じ信号強度だった。それぞれで ch37 から ch39 までを重ねても 3 本の線になるような差は生じなかったが、使用したアダプタイジングチャンネルによって信号強度に差が生じることがわかる。

以上より、図 3.14 で一部の Bluetooth 受信機・距離において観測された複数段階の信号強度は、用いたアダプタイジングチャンネルによって生じたものだといえる。図 3.14 では複数の線のようになっていないグラフもあるため、距離や角度の細かい差で信号強度に差が出るかどうかが決まると考えられ、静的な環境でも BLE の信号強度が安定しないことを示唆している。

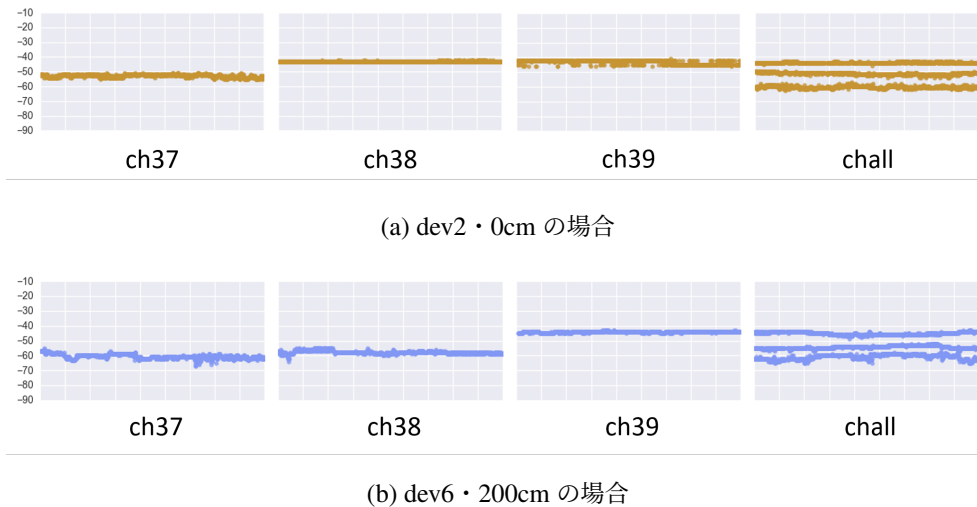


図 3.15: 特定のアドバタイジングチャンネルにパケットを送信した場合の信号強度

3.5 G 空間 EXPO2016 でのタンデム BLE を用いたデータ収集

G 空間 EXPO2015 に引き続き、G 空間 EXPO2016 でも実験を行った。G 空間 EXPO2016 は前年と同じく日本科学未来館で開催され、11 月 24 日から 26 日までの三日間、毎日朝 10 時から夕方 17 時の間が開場期間となっていた。入場無料・年齢制限無しで展示を観覧できたことも前年と同じで、のべ 19138 名 (24 日は 5321 名・25 日は 6955 名・26 日は 6862 名) が訪れた。会場の風景は図 3.16 のようになっており、展示ブースによっては大型の模型や車両が展示されていた。実験には一般の来場者も参加し、実験関係者を含めて 3 日感でのべ 260 名からデータを収集した。被験者は実験受付で BLE タグをはじめとする実験用の機材を受け取り、自由に場内を観覧した。

データ収集・位置推定の対象となる範囲は前年の実験から変更し、メインの展示ブースがある中央エリアのみとした。このエリアは横約 70 メートル×縦約 23 メートルの広さで、端はステージとなっている。この範囲を図 3.17 に示す。

図中に青もしくは橙で網掛けがされている部分が展示ブースとなっている。異なるブースの間にはパーティションが設置されており、角配置でないブースでは左右と奥が囲まれる。最小のブースサイズは縦横が各 3m となっている。大きなブースではより広い空間となっており、特に大きいブース 10(図 3.16b) では縦横 9m の広さに対して独自にパーティションが設置されていた。ブースはそれぞれ異なる展示内容で、資料や機材の展示のみのブースもあれば、デモ展示を行っているブースもあった。また、実験受付のブースは場内左下の、橙色の網掛けが施されている部分である。



(a) 実験受付近辺



(b) 最も広いブース



(c) 小さいブース



(d) 学生も来場

図 3.16: G 空間 EXPO2016 の場内の様子 ([101] より引用)

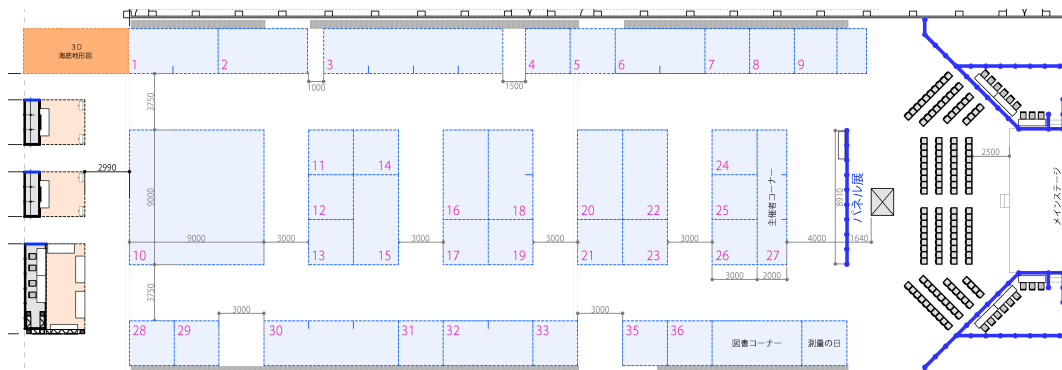


図 3.17: G 空間 EXPO 2016 における位置推定の対象エリア

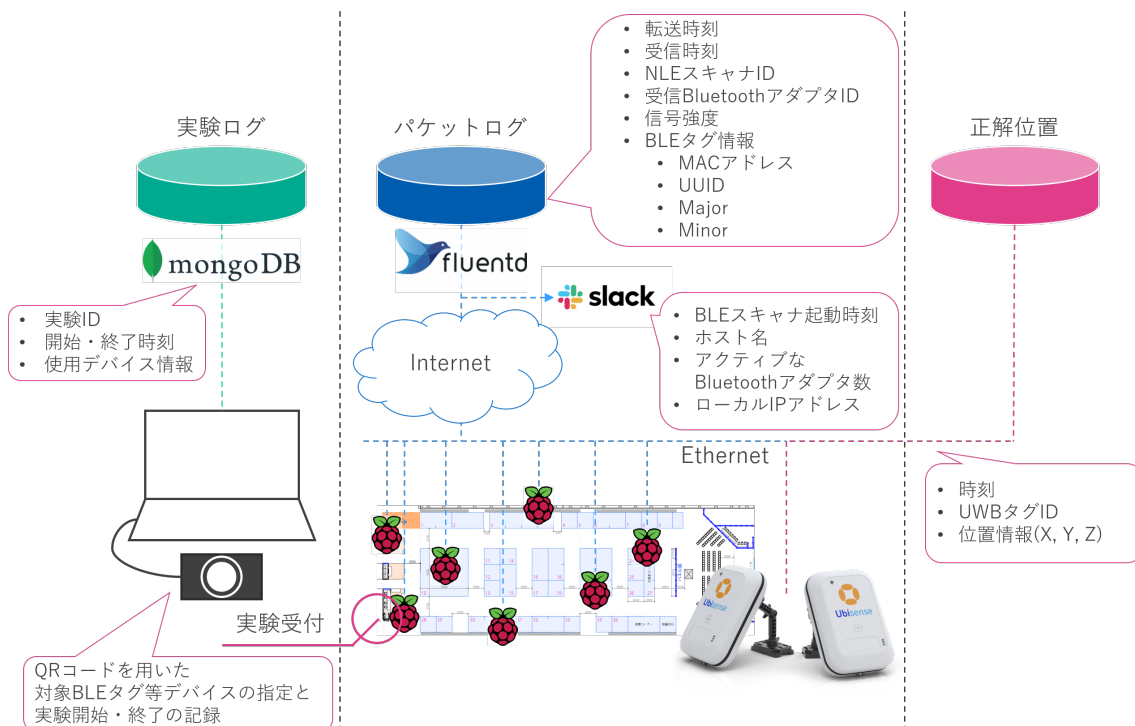


図 3.18: G 空間 EXPO2016 での実験システム概要

3.5.1 より扱いやすくしたデータ収集システム

実験では、図 3.18 に示すような構成の、新しいデータ収集システムを構築して、円滑な実施を図った。システムは個別の 3 パート構成とし、実験を管理するパート、BLER タグのログを収集するパート、正解位置を取得するパートとした。実験管理では、受付においてカメラを用いた情報の自動入力を行えるようにした。被験者が用いる機材セットに QR コードを貼り付けておき、読み取り時に自動的に BLE タグなど使用するデバイスの情報が入力されるようにし、情報の手入力を排除して実験の管理を行いやすくした。実験開始時には、用いる BLE タグ番号・UWB タグ番号と時刻を MongoDB に送り、自動生成された実験 ID とともに管理できるようにした。実験終了時の QR コード読み取りで、対応する実験 ID のデータに終了時刻が記録されるようにした。

BLE タグのログを収集するパートにも更新を施し、データ収集に加えて BLE スキャナの状態管理も行った。データは前回の実験と同様に、fluentd を用いて別のサーバに転送した。ただし収集中のデータに対して検索を行うことがなかったため、この実験ではサーバ側ではファイルに収集データを保存した。転送されるデータは JSON 形式とし、BLE スキャナ側の受信時刻・BLE スキャナの ID・受信に使われた Bluetooth アダプタの ID・データが転送されてきた時刻・BLE タグの各種

パケットのデータ部					
Company ID (2 octets) 0x4C00 [Apple]	iBeacon Prefix (2 octets) 0x0215 [fixed value]	iBeacon UUID (16 octets)	iBeacon Major (2 octets)	iBeacon Minor (2 octets)	iBeacon TxPower (1 octet)
iBeaconデータの実体					

図 3.19: iBeacon のパケットフォーマット

情報が送られるように構成した。

さらに、今回の実験では BLE スキャナの管理を容易にするため、チャットツールである Slack で各 BLE スキャナの情報を確認できるようにした。実験用のネットワークはプライベートネットワークとなっており、各 BLE スキャナには DHCP を用いて動的に IP アドレスを割り振っていた。そのままでは遠隔ログインが難しく、データ収集サーバでデータを確認しないと BLE スキャナの様子がわからない。そこで、死活監視・状態管理のために BLE スキャナに Slack ボット機能を付与した。これは BLE スキャナが自身の起動時に、自身のホスト名・割り振られた IP アドレス・起動時刻・認識した Bluetooth アダプタの状態を報告するものである。実際に G 空間 EXPO2016 では BLE スキャナが障害を起こしており、状況の確認の役に立った。

前年の実験では正解位置を自動で収集する手段がなく、一部の実験関係者が自身の歩行ルートを手動で記録していたため、一般の被験者の正解位置データが得られなかった。そこで商用の UWB タグを用いたシステム (Ubisense 社製 [57]) を用い、別のコンピュータに正解となる位置情報を記録した。記録した情報は時刻・UWB タグの ID・位置情報 (3 次元) となる。

3.5.2 iBeacon 動作の BLE タグの使用

前回の実験で使用した BLE タグはパケットの内容が独自の形式になっており、MAC アドレスでしか個体を識別できず、管理が煩雑だった。今回の実験では容易な管理のために、iBeacon として動作する BLE タグを使用した。iBeacon は Apple 社が定義している BLE タグのアドバタイジングパケットの形式で、図 3.19 のパケットフォーマットを持つ。パケット内で重要なのは、16 オクテットの UUID、2 オクテットの Major、2 オクテットの Minor、1 オクテットの TxPower である。iBeacon ではこれらの設定で BLE タグへの連番の付与やグルーピングが可能になる。

UUID は 128 ビットの値で、最上位の識別子となる。これはたとえば、その iBeacon デバイスを運用する団体を示す。残りの Major と Minor は下位の識別子として動作する。これらは 0 から 65535 までの値を設定でき、iBeacon デバイスの個体識別に利用できる。

一般的な iBeacon の使い方としては、デパートに多数の iBeacon を設置する例が考えられる。

デパートであることを示すためにすべての iBeacon デバイスに共通の UUID を設定し、Major と Minor を個々の iBeacon デバイスで変更し、Major で階を識別して Minor で階のどの店舗かを指定する使い方ができる。今回の実験では、BLE タグごとに異なる Minor を設定して個体を識別した。

TxPower は、iBeacon デバイスから 1m 離れた地点で観測されるべき信号強度として定義されている。もともと近接度に応じてサービスを行う想定となっている iBeacon では、受信側デバイスが取得した実際の信号強度と、パケット内の TxPower を比較してビーコンまでのおおよその距離を判定する (Apple 社の iOS では immediate, near, far の 3 段階で距離が通知される)。

3.5.3 使用機材

実験で利用した機材を表 3.2 に示す。また、実験中の被験者の様子を図 3.20 に示す。今回の実験では UWB タグによる高精度測位で被験者の位置情報を取得した。UWB タグは障害物に弱いいためバイザーに乗せる形で頭に装着した。BLE タグは前回と同様にネームホルダに入れ首から下げようにした (管理用の QR コードはネームホルダに貼付した)。BLE タグはファームウェアを変更しやすいものを使用し、異なる設定の 3 個を 1 セットとして使用した。3 種類の設定を表 3.3 に示す。ここで設定している送信パワーは、iBeacon パケットの TxPower として設定した値である。

各 BLE スキャナは図 3.21 に示すようにパーティション上部に設置した。会場内における各 BLE スキャナの設置場所は図 3.22 に示す。

タンデム BLE スキャナは図 3.22 のうち 1 から 11 までである。すべて Raspberry Pi 3 Model B をベースとしており、1 から 10 は 3D プリンタで製作した専用の器具と、自作の USB 延長ケーブルを用いて十字形に 4 個の Bluetooth アダプタを取り付けた。タンデム BLE スキャナ 1 から 10 は図 3.23 に示すような外見をしている。タンデム BLE スキャナ 11 は並列に 7 個の Bluetooth アダプタを備える (これは図 3.11 と同等の外見である)。タンデム BLE スキャナの Bluetooth アダプタには図 3.22 で示すような番号を割り当てた。12 番以降の BLE スキャナは、前年の実験で使用したのと同じで、1 つの Bluetooth アダプタを備える (外見は図 3.4 と同等)。Bluetooth アダプタ複数社のもを混在させて使用した。内訳は ELECOM 社 LBT-UAN05C2[102] および IO DATA 社 USB-BT40LE[103]、PLANEX 社 BT-Micro4[104] とサンワサプライ社 MM-BTUD44[105] である。

表 3.2: G 空間 EXPO2016 における実験で利用した機材

種別	型番・品名	数量
BLE タグ	uCXpresso LilyPad for nano51822	30 個 ×3 セット
タンデム BLE スキャナ	Raspberry Pi 3 Model B	11 個
通常の BLE スキャナ	Raspberry Pi 1 Model B+	27 個
UWB タグ	Ubisense RTLS[57]	30 個



図 3.20: BLE タグ・UWB タグを装着した被験者

表 3.3: BLE タグの設定

	アドバタイジング周期	送信パワー
設定 1	0.1 秒 (10Hz)	-59dBm
設定 2	0.1 秒 (10Hz)	-63dBm
設定 3	0.25 秒 (4Hz)	-59dBm



図 3.21: 設置場所の例




図 3.22: 会場内の BLE スキャナ配置とタンデム BLE スキャナのアダプタ方向




図 3.23: 実験で使したタンデム BLE スキャナ

3.6 G 空間 EXPO2016 での収集データの基礎分析

3.6.1 得られたデータ量・パケット量の調査

全期間で収集できたデータは、すべてのスキャナ・すべての Bluetooth アダプタをあわせて 300GB を超える容量になった。一部のスキャナは電源に障害が起きて起動できていない日があったり、ストレージを消費しきってデータを記録できなくなったりした。したがって、すべてのスキャナが正常動作していればデータ量の増加があったはずである。全パケットを集計したところ、全日程通して 426,892,228 パケットが記録されていた。

全スキャナ・全 Bluetooth アダプタが観測した実験 BLE タグのパケットカウントでは、48,249,521 パケットが記録された。内訳は初日 9,857,833 パケット、2 日目 18,704,320 パケット、3 日目 19,687,368 パケットとなる。したがって、実験で使った BLE タグのパケット以外にも、大量のアドバタイジングパケットが観測されていたことになる。

3.6.2 被験者の行動の確認

各被験者について、受付で BLE タグと UWB タグを受け取ってから返却するまでの時間(実験時間)を 10 分ごとにまとめた。3 日の各日程のヒストグラムを図 3.24 に示す。1 日目は木曜日で人が少なく、3 日目は土曜日だったので多くの来場者がおり、被験者の人数も多い。図より、多くの被験者が 10 分から 30 分程度、長くても 2 時間ほどで受付に戻ってきたことがわかる。また、ごく一部の被験者は実験時間が 3 時間から 4 時間となっており、長時間滞在していた。

イベント環境での来場者の位置データを取得できるとどのようなことがわかるのかについての基礎的な分析として、UWB タグで取得した正解位置のデータを用いて、被験者がどのように会場内を移動していたかを確認する。UWB タグの位置データから、会場内のどの位置に長く滞在していたかのヒートマップを作成した。ヒートマップでは、会場を 1 メートル単位に区切って、各位置での滞在秒数ごとに色を割り当てた。図 3.25 に、実験時間が 13 分 29 秒、1 時間 3 分 36 秒、2 時間 43 分 36 秒、3 時間 55 分 43 秒だった 4 人の被験者のものを示す。

図 3.25a より、短時間しか会場にいなかった被験者は場内を大きく一周し、受付に戻っていた。実験時間が長い人は場内の様々なところに移動していることがわかる。図 3.25b の被験者は場内の中央部を移動しており、上部・下部の展示ブースには近づいていないことがわかる。図 3.25c の被験者は場内右側のメインステージ前に長時間滞在していた。図 3.25d の被験者は中央上部で長時間




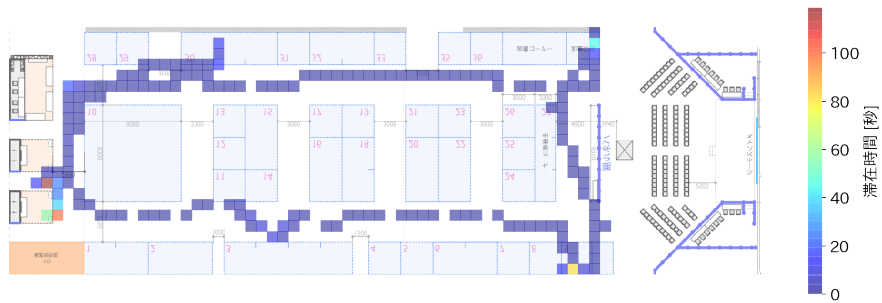
図 3.24: 被験者の実験時間の分布

滞在しており、この位置にあったブースに特に興味があったと推察される。以上より、人によって会場内にいた時間や滞在している場所が異なることがわかる。


各被験者が絶え間なく移動しているのか、それとも展示ブースであまり移動しないのかを調べるために、実験時間と、実験時間中の総移動距離をまとめた。図 3.26 に散布部の形で示す。図より、移動時間に比べて総移動距離が長く常に歩き回っていた人や、移動時間が長い総移動距離が少なく特定のブースに長く滞在したと考えられる人が確認でき、多様な観覧行動が見られた。配布型 BLE タグを用いた位置推定でこのようなデータを得られれば、移動時間・移動距離・滞在ブースについての分析様々なイベントで行えるようになるため、その意義は大きいといえる。

3.6.3 タンデム BLE スキャナによるパケットロス低減の確認

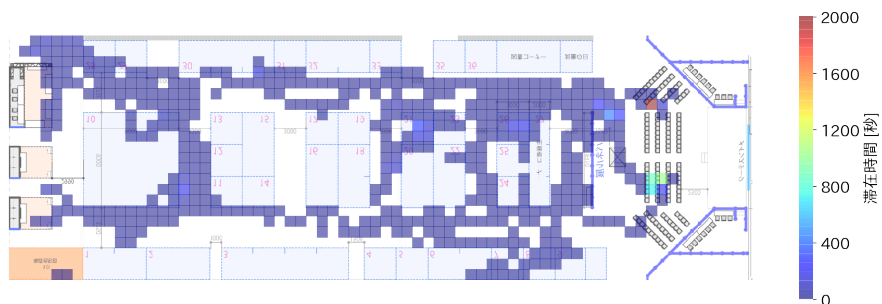
実験で得たデータを使って、実環境における (1) タンデム BLE スキャナがパケットロスを低減できているかを確認する。被験者に配布した BLE タグのうち、10Hz でアドバタイジングパケットを送信する設定のものについて、この検証を行った。タンデム BLE スキャナの各 Bluetooth アダプタは、他の Bluetooth アダプタとは独立にパケットを受信する。1 台のタンデム BLE スキャナ



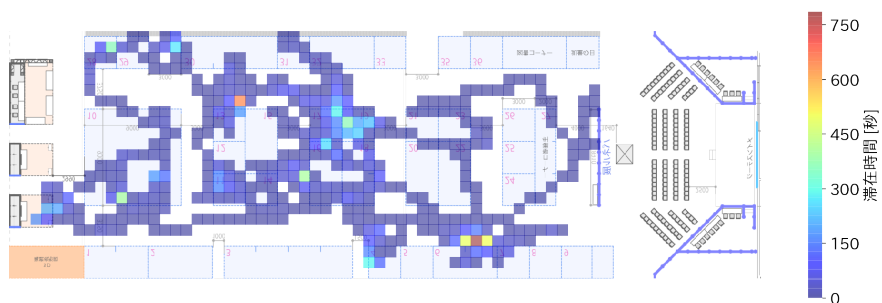
(a) 実験時間 13 分 29 秒の被験者



(b) 実験時間 1 時間 3 分 36 秒の被験者



(c) 実験時間 3 時間 55 分 43 秒の被験者



(d) 実験時間 3 時間 55 分 43 秒の被験者

図 3.25: UWB タグの正解位置から作成した滞在ヒートマップ




図 3.26: 各被験者の実験時間と、その間の総移動距離




図 3.27: タンデム BLE スキャナが観測したパケットについての、各 Bluetooth アダプタでの受信数とユニークな受信数の比較

が備える複数の Bluetooth アダプタのうち、どれかひとつでもパケットを受信できればパケットロスを防げる一方で、ある 1つのパケットを複数の Bluetooth アダプタで受信すると重複が生じる。そこで、受信時刻が 0.1 秒の位まで一致するパケットは同一パケットとみなして重複を排除したユニークな受信数を計算し、図 3.27 にまとめた。

図より、どのタンデム BLE スキャナにおいても、ユニークなアダプタイジングパケット受信数は各 Bluetooth アダプタでの受信数を上回り、2 倍程度に受信数が向上した。Bluetooth アダプタの数が多いタンデム BLE スキャナ 11 では、特にユニークな受信数の伸びが大きい。以上から、各

Bluetooth アダプタで受信したパケットはある程度重複しているものの、特定の Bluetooth アダプタでしか取得できていないものも多くあったといえる。特定の Bluetooth アダプタでしか取得できていないパケットは、その Bluetooth アダプタがなければパケットロスとなっていたということであり、実環境においてもタンデム BLE スキャナの使用によりパケットロスを減らしてデータを収集可能であるといえる。

同じく図より、タンデム BLE スキャナの個体ごとに最大の受信数を記録した Bluetooth アダプタの番号が異なっていることがわかる。たとえばタンデム BLE スキャナ 1, 2, 3 で最大のパケット受信数を記録していたのは Bluetooth アダプタ 0 であった。すべての Bluetooth アダプタが同じ方向を向いていたスキャナ 11 においても各アダプタ間の受信数の差が存在する。そのため、位置や向きの差で得られるパケットに差が生じると考えられ、この影響をタンデム BLE スキャナで緩和できるといえる。

また、Bluetooth アダプタによって受信数が異なっており、同じ場所にスキャナを設置しても Bluetooth アダプタの向きで観測できるパケットの量が異なる可能性が示唆された。

3.6.4 信号強度の分布の確認

距離と信号強度の関係

実験では UWB タグを用いて被験者の位置を取得していたため、各パケットとその送信位置を結び付けられる。したがって、一般の来場者が歩いている実環境において、信号強度が送受信間の距離に応じてどのように分布するかを調査できる。そこで各 BLE スキャナからの距離と信号強度の関係をまとめたものを図 3.28 に示す。図より、どのスキャナにおいても最大の信号強度はおおむね距離に応じて減衰する一方で、最も弱い信号強度は距離に関係なくほぼ一定となっている。図中、各 BLE スキャナでおおむね 30m より遠いところで急に現れる強い信号強度は、実験受付の位置で送信されたパケットを捉えたものである。また BLE スキャナ 35 は故障していた時間が長く、有効なデータを得られなかった。実験受付では、実験開始・終了の前後で機材についての説明があり、BLE タグが机の上に置かれている時間があったため、人の影響を受けずにパケットが送信されたものだといえる。

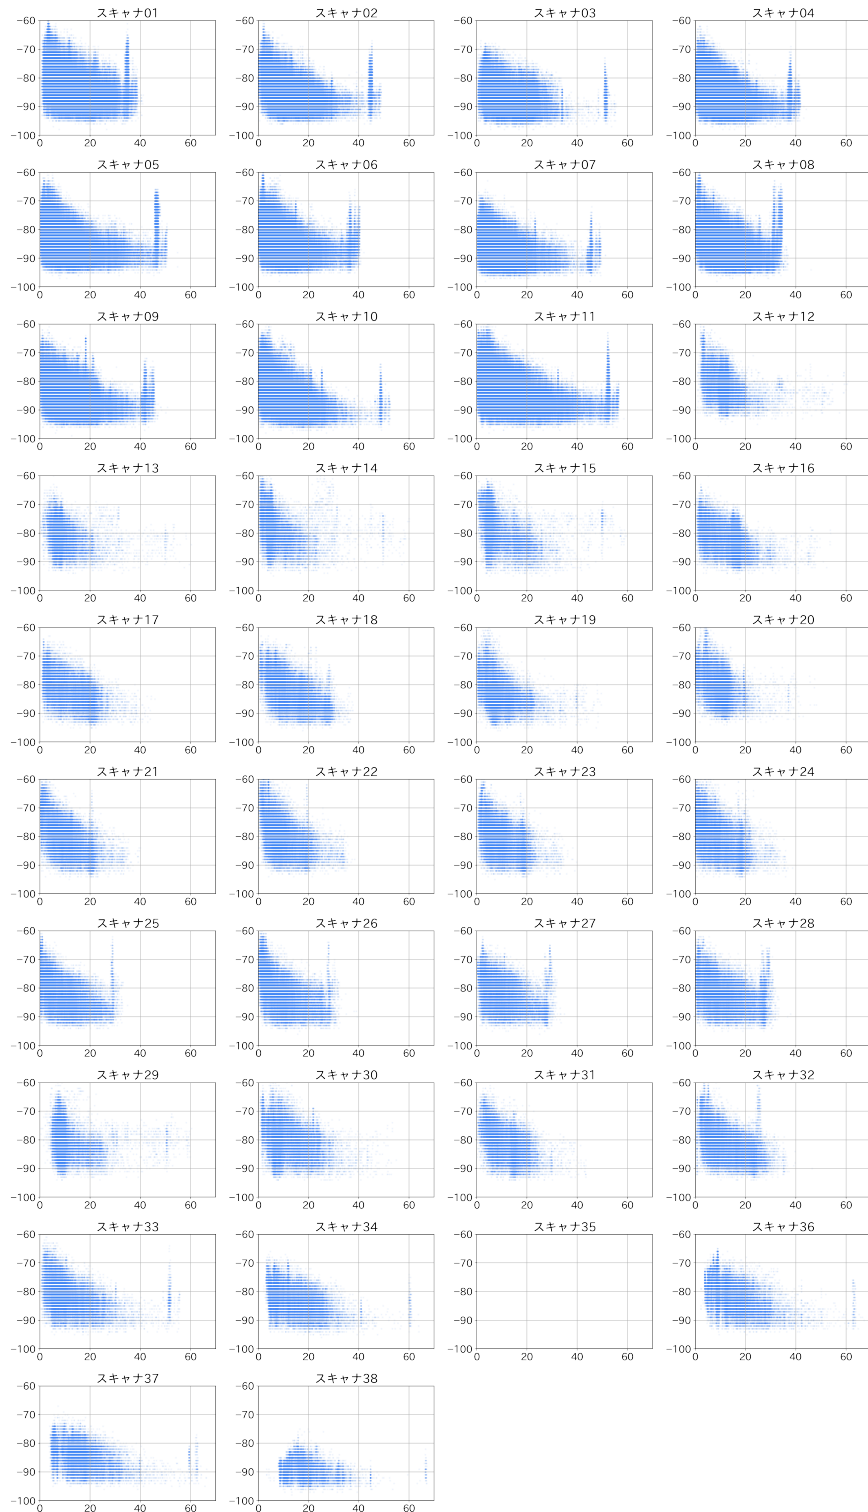


図 3.28: 距離に対する信号強度の分布

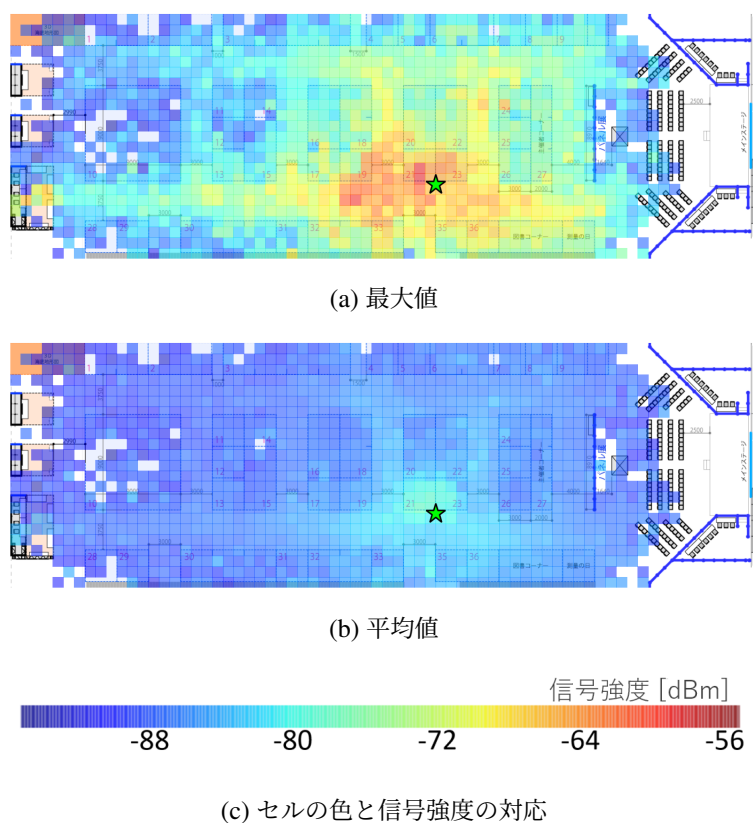


図 3.29: タンデム BLE スキャナ 6 の信号強度分布

会場内位置と信号強度の関係

各パケットの送信位置をもとに、信号強度の空間な分布を調べた。会場を 1m 単位に区切って、各位置に割り当てた信号鏡について、その最大値、平均値のヒートマップをそれぞれ作成し、場内地図に重畳した。タンデム BLE スキャナ 6 の例を図 3.29 に示す。

図において緑色の星印はタンデム BLE スキャナ 6 の位置を示す。ヒートマップの色は信号強度に対応し、-55dBm から-95dBm の範囲で描画して図 3.29c の色を割り当てた。色のない地点は、その位置と結びついたパケットがひとつもなかったことを示す。図 3.29a を見ると、最大の信号強度は BLE スキャナ周辺で強い値を記録しており、離れるにつれて弱くなる。しかし、BLE スキャナ位置を中心とした放射状の分布とはなっておらず、通路にそって分布している。これは、展示ブースの壁が信号強度に影響を及ぼしたためだと考えられる。一方、図 3.29b より、信号強度の平均値は BLE スキャナ近辺で多少大きいものの、会場のどこであっても大きな差がなく、位置推定での利用は難しいといえる。

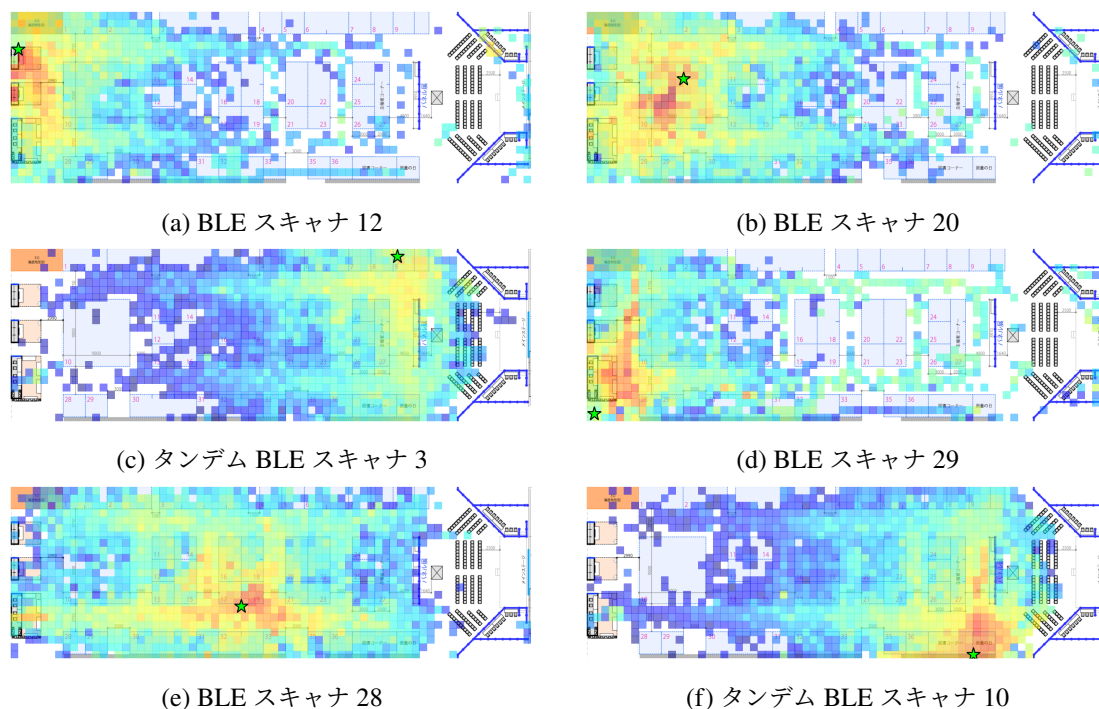


図 3.30: BLE スキャナごとの信号強度分布の違い (最大値)

また、図 3.30 に BLE スキャナ 12, 20, 28, 29 およびタンデム BLE スキャナ 3, 10 でそれぞれ得たパケットの信号強度の最大値の分布を示す。信号強度と色の対応は図 3.29c に示したものと同一である。図 3.29 と同様に、BLE スキャナの位置は緑色の星印で示す。図 3.30 より、BLE スキャナの位置に応じてそれぞれ異なる信号強度の分布ができていることがわかる。会場内の位置に応じて各 BLE スキャナが得る信号強度が異なるため、位置推定が行えることが示唆された。なお、BLE スキャナ 12 と BLE スキャナ 29 では橙色で示される強い信号強度が図の左側、上下方向に現れており、人通りが多かったことがうかがえる。

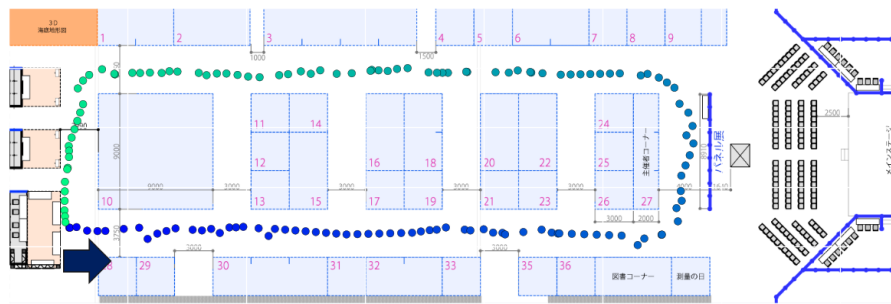
3.6.5 精度検証用の経路

以後の位置推定の精度検証用として、4 パターンの経路を用意した。それぞれ図 3.31 に示す。図上の各点は UWB タグによって計測された位置情報で、色は青から緑に向かって歩行開始から終了までを示す。歩行開始・終了位置は実験受付の位置で、歩行開始時の方向を矢印で示す。図 3.31a および 3.31c は会場内を単純に一周するのみであるため、簡単な経路であるといえる。図 3.31b では被験者が会場中心部の展示ブース島を回っており、難易度が上がっている。さらに図 3.31d では会場内の曲がり角ごとに被験者が曲がるため、経路長も伸びている。長い経路では継続的な位置推

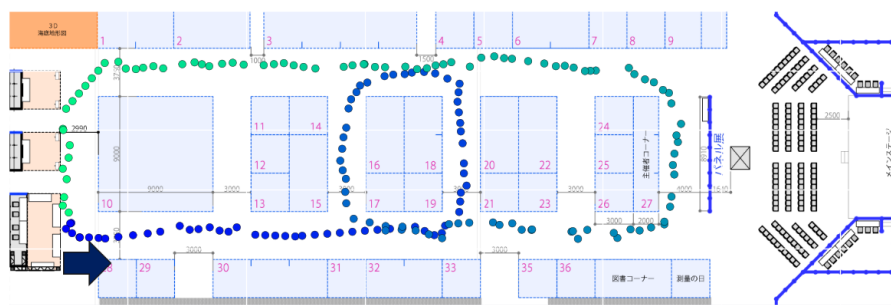
定の途中で追跡に失敗しやすくなっていると考えられ、難易度はこの4経路の中で最も難しい。

3.7 本章のまとめ

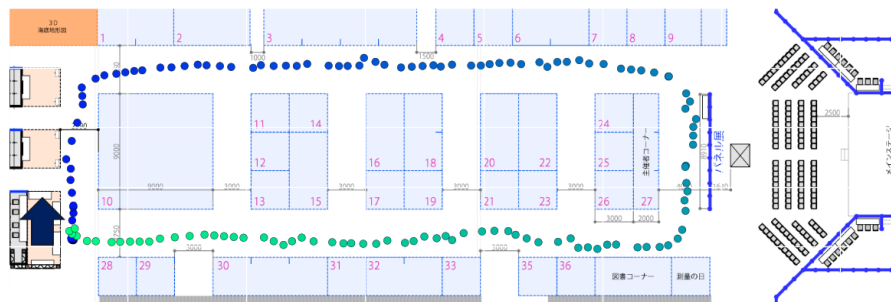
本章では、配布型 BLE タグを用いる位置推定の具体的な構成を示し、実際にデータ収集システムを運用して実験を行い、実環境ではパケットロスという信号強度の不安定さとは別の問題が発生していることを明らかにした。このパケットロスを減らして安定した受信を実現するために、1台の BLE スキャナが複数の Bluetooth アダプタを用いるタンデム BLE スキャナを提案し、実環境においてもタンデム BLE スキャナを用いてパケットロスを軽減できることを示した。また、正解の位置情報をもとに送受信間の距離と信号強度の関係を作成すると、送信・受信間が短距離でも弱い信号強度を観測するという、信号強度の不安定さが確認できた。次の章では、事前の収集データを必要としない、三角測量を用いる推定手法について述べる。



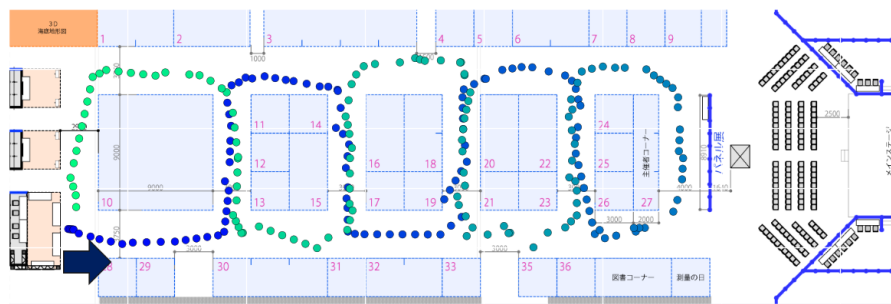
(a) 反時計回り



(b) 反時計回り (ループ)



(c) 時計回り



(d) ジグザグ

図 3.31: 精度検証用の経路

第 4 章

タンデムスキャナで得た信号強度を用いた位置推定

この章では、三角測量の考え方をもとにした位置推定手法を用い、短期間のイベントで利用しやすい事前データを行わない位置推定の精度を確認する。

三角測量では最低 3 つの点からの距離を用いて位置を推定する。BLE スキャナが観測したパケットで距離と相関が生じるものは信号強度である。しかし、一般に信号強度は不安定であるため、距離の推定には誤差が生じる。本章で用いる手法では、多数の粒子を用いて対象の状態を表現するパーティクルフィルタを組み合わせ、過去の位置をもとに、より安定した位置推定を実現する。

4.1 推定アルゴリズムの概要

提案する手法は、信号強度からの距離推定と、パーティクルフィルタによる位置推定を組み合わせた 2 パート構成を取る。つまり、以下のような手順の推定を考える。

- (1) 信号強度をもとにした環境全体での推定パート
 - (a) スライド窓を用いた時刻 t を代表する信号強度の抽出
 - (b) 信号強度の有無に応じた、個々の BLE スキャナについての重みマップの生成
 - (c) 重みマップの統合
- (2) パーティクルフィルタパート
 - (a) 時刻 $t-1$ の状態を示すパーティクルを移動
 - (b) 信号強度からの推定パートの統合重みマップに基づく、パーティクルへの重み付与
 - (c) 等間隔リサンプルによるパーティクルの選別

(d) 推定位置の出力

信号強度からの推定パートでは、信号強度をもとに、対象空間全体のどこに対象となる BLE タグがありそうかを探す。誤差のない三角測量では対象の位置が一意に定まるが、実際は信号強度にノイズがあるため、点での表現ができない。かわりに、個々の BLE スキャナで対象がいる可能性の高い領域を考える。本提案手法では、対象の環境をメッシュ状に区切り、各位置に重みを与える(重みマップの生成)こととした。しかし、信号強度の不安定さから時刻ごとに重みの大きい領域が異なることも多い。

そこで、位置の時間的な連続性を利用して、過去の位置の周囲を探索し、現在位置を推定する。推定対象の位置は、必ず過去の位置と相関するため、現在の位置は少し前の時刻の位置からある程度の距離にある。これを表現するために、パーティクルフィルタを用いる。パーティクルフィルタでは、多数の粒子を用いて対象の状態を表現する。今回は、推定位置の候補としてパーティクルを用いる。現在時刻の位置の表現は、1 タイムステップ過去の時刻を示すパーティクルを移動させ、その中から重みの高いものを用いて行う。このパーティクルへの重みの割り振りに三角測量パートで生成された重みマップを用いる。

4.2 信号強度をもとにした対象空間全体での推定

まず、対象となる環境内の各 BLE スキャナで得た信号強度をもとに、時刻 t において環境内のどこに推定対象が存在するかの重みマップを生成する。まず、推定に利用する信号強度を取得する。ここでは、信号強度にはノイズが含まれること、またパケットロスが発生しやすいことを考慮し、時刻 t から過去 w だけの時間幅のスライド窓を利用して、この窓内にあるデータから位置推定に利用する信号強度を抽出する。

まずは、時刻 $t-w$ から t の間に BLE スキャナ k で得たすべての信号強度 R_k を抽出する。その後、実際に時刻 t での推定に利用する信号強度 r_k^t として、 R_k 内の最大の信号強度を抽出する。スライド窓の窓幅 w は変更可能なパラメータとなる。大きな w を与えるとより長い期間の信号強度から位置を推定する。また、窓のスライド幅の設定も必要となる。スライド幅は推定の頻度に直結することになる。今回は1秒ごとの推定を考えて、1秒のスライド場を設定する。

次に、信号強度をもとに、個々の BLE スキャナに対する重みマップの生成を行う。重みマップは、対象の位置が場内のどこにあるかを示すためのもので、信号強度から推定した距離をもとに生成する。ただし、スライド窓を用いて時間的な幅を持たせても信号強度が利用できない場合がある

ため、場合分けを行う。信号強度が利用できない場合は単純に、その BLE スキャナに対しての重みマップは位置に関わらず一律の値を使う。

一方、信号強度が利用できる場合は、以下の手順に従って信号強度 r_k^t に応じた重みマップを生成する。

- (1) 信号強度 r_k^t にもとづく BLE スキャナと BLE タグ間の距離 d_{est} の推定
- (2) 推定距離 d_{est} を平均に持つ正規分布による、距離 d に対する重みの生成
- (3) BLE スキャナ位置とメッシュ上セルとの距離を利用した重みの割り振り

信号強度からの距離 d_{est} の推定では、スキャナ k の信号強度 r を入力に、フリスの公式を元にした以下の式 (4.1) を用いる。式では、 T_x および n がパラメータとなる。 T_x は送信パワーで、iBeacon 形式の packets に記録されている値を用いる。iBeacon の packets での T_x は送受信間が 1m のときの値であるため、 $r_k^t = T_x$ のときにたしかに、 $d_{est} = 1$ を得られる。

$$d_{est} = 10^{\frac{r_k^t - T_x}{-10n}} \quad (4.1)$$

これで得られた推定距離 d_{est} は誤差を含んだ値である。実際にはこの距離 d_{est} の周辺に真の距離が存在すると考え、推定距離が d_{est} のもとで送受信間が距離 d となる点に与える重みを考える。ここでは、正規分布で距離に応じた存在確率を考えて、そのまま重みとして利用することにした。推定距離 d_{est} を平均に、 σ を標準偏差に持つ正規分布の確率密度関数 $P(d)$ は以下の式 (4.2) で表される。

$$P(d) = \frac{1}{\sqrt{2\pi} \cdot \sigma} \exp\left(-\frac{(d - d_{est})^2}{2 \cdot \sigma^2}\right) \quad (4.2)$$

これを用いて、BLE スキャナからの距離に対応する確率を計算できる。スキャナ k の設置位置を (x_k, y_k) として、位置 (x, y) の点との距離は式 (4.3) で計算できる。実際は BLE タグと BLE スキャナ位置の高さの差が生じるが、今回はこれを無視して二次元的な距離で扱う。

$$d = \sqrt{(x_k - x)^2 + (y_k - y)^2} \quad (4.3)$$

また、信号強度は基本的に大きい値であればその分送受信間の距離が近いと考えられる。そこで、信号強度の大小に由来する追加の重みとして、式 (4.4) を用いて $v(r_k^t)$ を追加する。ここでは \max を用い、 -100 より小さい信号強度 r_k^t は無視するように設定する。これはいくつかの実験から

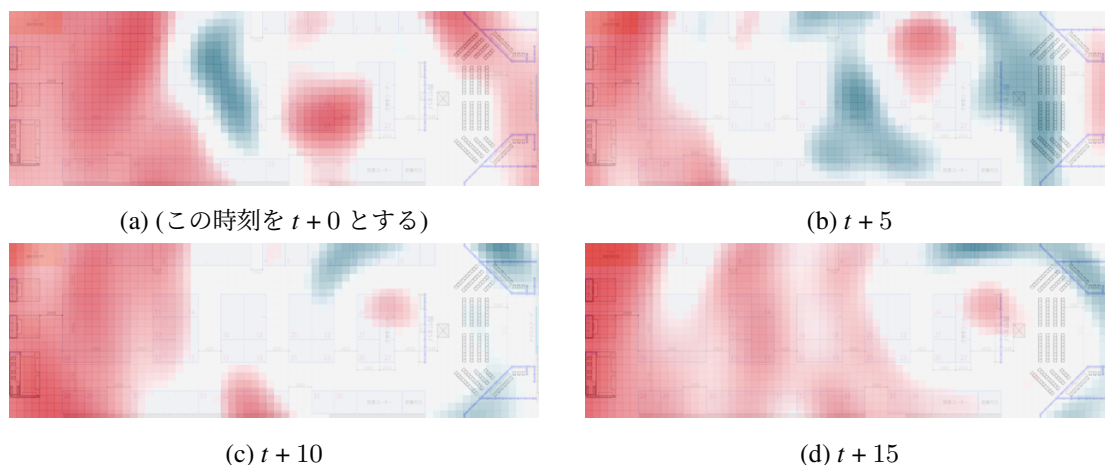


図 4.1: テスト用被験者の重みマップ

経験的に設定したもので、ごく小さい信号強度では軽く、大きい信号強度では大きな重みとなる。

$$v(r_k^t) = \frac{100 + \max(-100, r_k^t)}{10} \quad (4.4)$$

最終的に、ある BLE スキャナから距離 d の地点には式 (4.2) と式 (4.4) の積を重みとして割り当てる。会場全体に関して考えるために、会場を 1m 単位のメッシュに区切り、メッシュ上の各点で BLE スキャナとの距離を計算し、それをもとに重みマップを作成する。実際にできあがる重みマップは、BLE スキャナの位置を中心にして円形に重みの高い領域を持つ。これは BLE タグからのアドバタイジングパケットから得られる情報が信号強度のみで、到来方向はわからないこととも合致する。全 BLE スキャナに対して重みマップの生成が終わったあとは、それらの和を取って時刻 t における対象環境の統合済み重みマップとする。

実際に 1m 四方のセルを用いて生成された統合済みの重みマップの例を図 4.1 に示す。ヒートマップの青色部分が高い重みを、赤色部分が低い重みになるよう設定した。 $t+0$ と $t+5$, $t+5$ と $t+10$ の間では重みの高い領域の形状が大きく変化していることがわかる。また、 $t+0$ では重みの高い領域がひとつで、楕円に近い形状になっているが、他の時刻では複数の領域にわかれているか、円弧に近い形状となっている。そのため、これらのセルの位置の平均を取っても、正確な推定位置にならない。また、重みの高い領域の形状が劇的に変化すると、推定される位置がジャンプしてしまう。これを防ぐため、パーティクルフィルタを用いて推定を安定させる。

4.3 パーティクルフィルタによる過去の推定位置情報の利用

先述のように、信号強度から生成した重みマップは時間的に安定しないことが多いため、そのままでは位置推定に使えない。そこで、過去の推定位置をもとに現在位置を推定するためにパーティクルフィルタを用いる。今回は、位置と方向を持つパーティクルを使い、それらを推定位置の候補とする。

パーティクルフィルタによって推定位置が出力されるまでを順に説明する。前提として、次の記号を定義しておく。 n 個のパーティクルの集合を P とする。ひとつのパーティクルを p とし、その位置と向きを (x_p, y_p, θ_p) とする。また、向き θ_p は x 軸正方向から反時計回り方向を正に取り、角度の単位は度で扱う。

まず、 $t-1$ の状態を示す P^{t-1} 内の全てのパーティクル p を以下にしたがって移動させ、 t の状態の候補とするパーティクルの集合 \hat{P}^t とする。このときのあるパーティクル p の位置と向き $(\hat{x}_p^t, \hat{y}_p^t, \hat{\theta}_p^t)$ は式 (4.5) で計算する。 \hat{x}_p^t と \hat{y}_p^t は、 $t-1$ の位置から、パーティクルがもともと持っていた向きに $d_m \delta$ だけ移動させた位置を与える。 δ は区間 $[0, 1)$ における一様分布から取得した乱数値で、移動量に関わる。 d_m は 1 タイムステップでの移動距離となるパラメータとする。新しい方向 $\hat{\theta}_p^t$ は前の時刻 $t-1$ で取っていた方向を基準に、標準正規分布に従う乱数 γ を用いて決める。基本は前のタイムステップと同じ方向のままとし、 20γ ぶんだけ方向を変える。直進性の高いランダムウォーク状態での移動となる。

$$\hat{x}_p^t = x_p^{t-1} + d_m \delta \cos(\theta_p^{t-1}) \quad (4.5)$$

$$\hat{y}_p^t = y_p^{t-1} + d_m \delta \sin(\theta_p^{t-1}) \quad (4.6)$$

$$\hat{\theta}_p^t = \theta_p^{t-1} + 20\gamma \quad (4.7)$$

次に、統合済みの重みマップを用いて、 \hat{P}^t 内のパーティクルに重み w_p を割り振る。重みマップから \hat{x}_p^t と \hat{y}_p^t と対応する値を参照し、そのパーティクルの重み w_p とする。

その後、等間隔リサンプル (系統サンプリング)[106] を行って、 \hat{P}^t 内のパーティクルの個数 n を保ちつつパーティクルの選別を行い、時刻 t の状態を表すパーティクルの集合 P^t とする。等間隔リサンプルでは、個々のパーティクルの重みとその総和にしたがってそれぞれのパーティクルの扱いを決める。

等間隔リサンプルによるリサンプリングの概念図を図 4.2 に示す。パーティクルの重みを並べ、

等間隔に打たれたピンに対応するパーティクルを残すパーティクルとする。ピンが打たれなかったパーティクルは消滅し、複数打たれたパーティクルは増殖することになる。

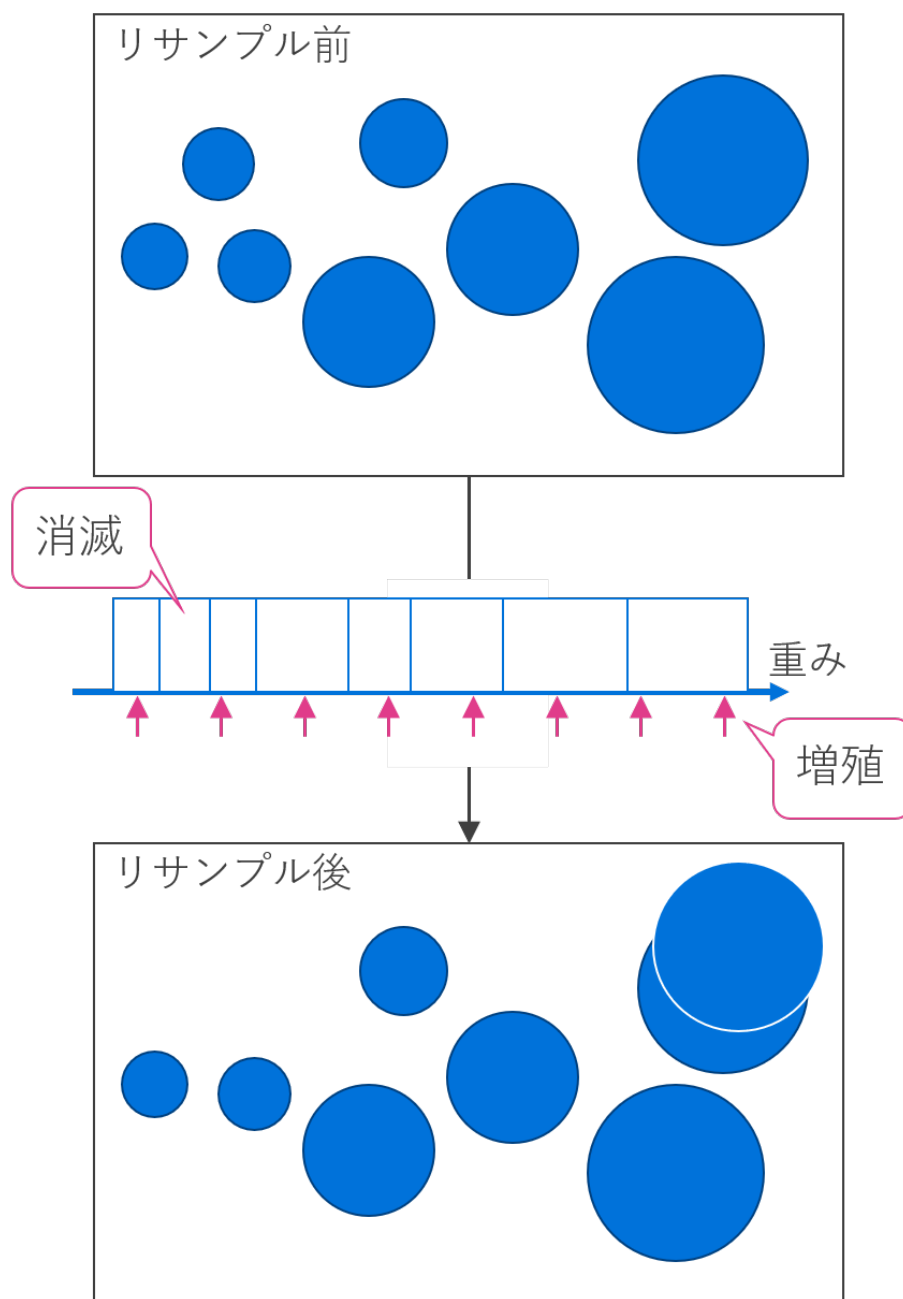


図 4.2: 等間隔リサンプルの概念図

最後に、リサンプル後のパーティクルの重み w_p を用いた加重平均として、対象の推定位置 (\hat{x}^t, \hat{y}^t) を決める。その後、 P^t 内の全パーティクルの重みをリセットして、 $t+1$ の推定に移行する。

$$\hat{x}^t = \frac{\sum w_p^t x_p}{\sum w_p^t} \quad (4.8)$$

$$\hat{y}^t = \frac{\sum w_p^t y_p}{\sum w_p^t} \quad (4.9)$$

過去の位置をもとにして推定を行うため、パーティクルフィルタには $t=0$ を示す初期状態 $P_{t=0}$ が必要である。初期状態のパーティクルの配置については、複数のパターンが考えられる。ひとつは、会場全域に一様にパーティクルを配置するパターンである。この場合、パーティクルフィルタは対象の位置についての知識を持たず、最初の更新で位置が定まる。もうひとつは、 $t=0$ において推定対象がいる位置を指定し、その周辺にパーティクルを配置するパターンである。これは、推定対象が決まった地点から歩行を開始する場合に対応する。今回は、イベントの来場者が必ず受付を通過すると仮定し、受付位置の近辺にパーティクルを配置する。

4.4 推定精度の評価

G 空間 EXPO2016 で取得したデータを用い、位置推定の精度を評価する。利用するのは、図 3.31 に示した 4 経路・3 人の 12 パターンである。時刻 t における推定の誤差は式 (4.10) のように、正解位置 (x^t, y^t) と推定位置 (\hat{x}^t, \hat{y}^t) の距離 e^t とする。また、歩行開始から終了までのすべての推定位置に対する誤差の平均と標準偏差で精度を評価する。正解位置には被験者が身につけていた UWB タグから取得したデータを用いる。

$$e^t = \sqrt{(\hat{x}^t - x^t)^2 + (\hat{y}^t - y^t)^2} \quad (4.10)$$

まず、各種パラメータの設定を行う。最良時の推定精度の評価のために、以下に示すパラメータの全組み合わせで位置推定を行い、精度が高い組み合わせを調べた。

- スライド窓の窓幅 w : 1, 3, 5, 10 (秒)
- 信号強度-距離関数の定数 n : 1.906, 2.0, 3.0, 4.0
- 距離の誤差として利用する正規分布の標準偏差 σ : 1.0, 2.0, 3.0, 4.0 (m)
- パーティクルの最大移動速度 d_m : 1.0, 1.2, 2.0, 3.0, 4.0 (m/s)

それぞれのパラメータの設定がどういう意味になるか述べる。スライド窓は信号強度の抽出のために用いており、その窓幅は対象の環境がどれくらい電波的に不安定かに依存する。短い窓幅は比較的安定して信号強度が取得できる環境に対応し、長い窓幅はパケットロスを起こしやすい環境に対応する。

信号強度-距離関数の定数 n は式 (4.1) で出てきたものである。これは減衰定数と呼ばれ、信号強度が短距離でも強く減衰する (大きな n) か・少ない減衰で長距離を飛ぶ (小さな n) かに対応する。このうち 1.906 は過去の屋外実験で得た値である。

正規分布の標準偏差 σ は式 (4.2) に必要な値で、正規分布の値の変化の急峻さに対応する。小さい σ を用いると、推定距離 d_{est} から遠い場所では、得られる値が急激に小さくなるため、より d_{est} を信頼する意味合いになる。

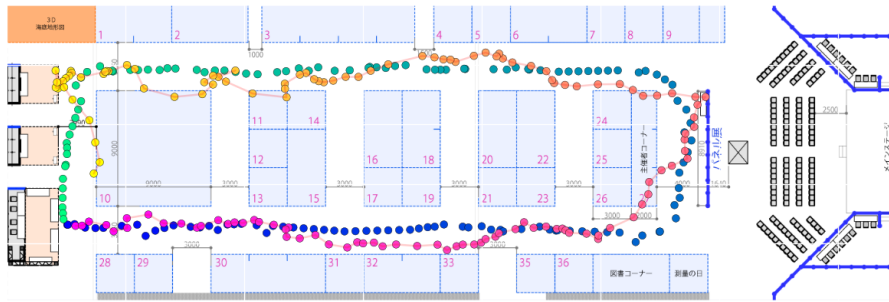
パーティクルの最大移動速度 d_m は、歩行速度の最大値とみなせる。これはパーティクルフィルタの探索範囲の広さに関係する。1.2メートル毎秒は人のおおよその歩行速度として候補に追加した。

最良の推定精度の探索では、BLE タグの設定は 3 種類すべてを用い、BLE スキャナについては会場に設置した 38 台すべてのデータを利用した。全組み合わせの評価の結果、全経路での平均の誤差が最も小さいパラメータのセットは $(w, n, d_m, \sigma) = (3, 2.0, 4.0, 4.0)$ だった。以降の位置推定ではこれを利用する。


4.4.1 最良の設定での軌跡

図 4.3 に、各経路において最も良い精度を記録した被験者の軌跡を示す。この時のパーティクルフィルタのパラメータは前項に示したもので、BLE タグは周期 0.1 秒 (10Hz) で送信パワーが -59dBm の設定を用い、会場内すべての BLE スキャナを利用した。いずれの軌跡でも、歩行開始から終了に向かって青色から緑色に変化する点で正解位置情報を示し、同様に歩行開始から終了に向かって紫色から黄色に変化する点で推定された位置を示している。また、表 4.1 に通常の BLE スキャナを設置していた会場の左半分と、タンデム BLE スキャナを設置していた右半分での各経路の精度を示す。


図 4.3a では左上を除き経路を復元できている。図 4.3c では右下の角をうまく復元できていない。また、左下に点が飛んで動いている箇所がある。表 4.1 では右下の角の部分の影響で右半分の精度が悪くなっている。図 4.3b ではおおむね経路を復元できているものの、全体に中央部に寄った形状で復元されている。図 4.3d では概形をおおよそ復元できているものの、会場内左側ではう



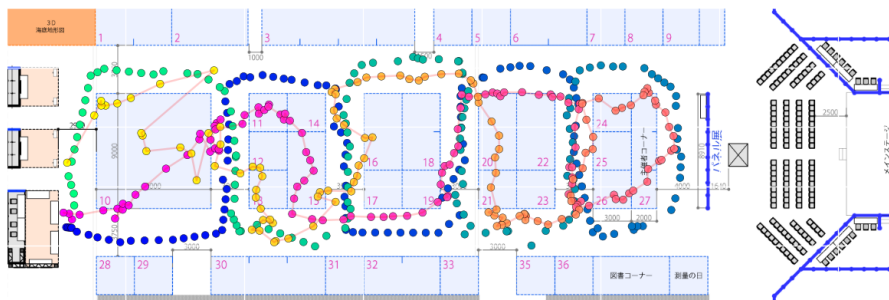
(a) 反時計回り



(b) 反時計回り (ループ)



(c) 時計回り



(d) ジグザグ

図 4.3: 各経路において精度が最も良い軌跡

(歩行開始から終了に向かって、青色から緑色に変化する点で正解位置を示し、紫色から黄色に変化する点で推定位置を示す)

表 4.1: 図 4.3 の各経路における会場内左右での精度

経路	左半分		右半分	
	平均誤差 (m)	標準偏差 (m)	平均誤差 (m)	標準偏差 (m)
反時計回り	2.02	1.18	2.18	1.12
反時計回り (ループ)	2.92	1.45	3.27	1.18
時計回り	2.90	1.95	4.09	2.11
ジグザグ	3.02	1.48	3.41	1.09

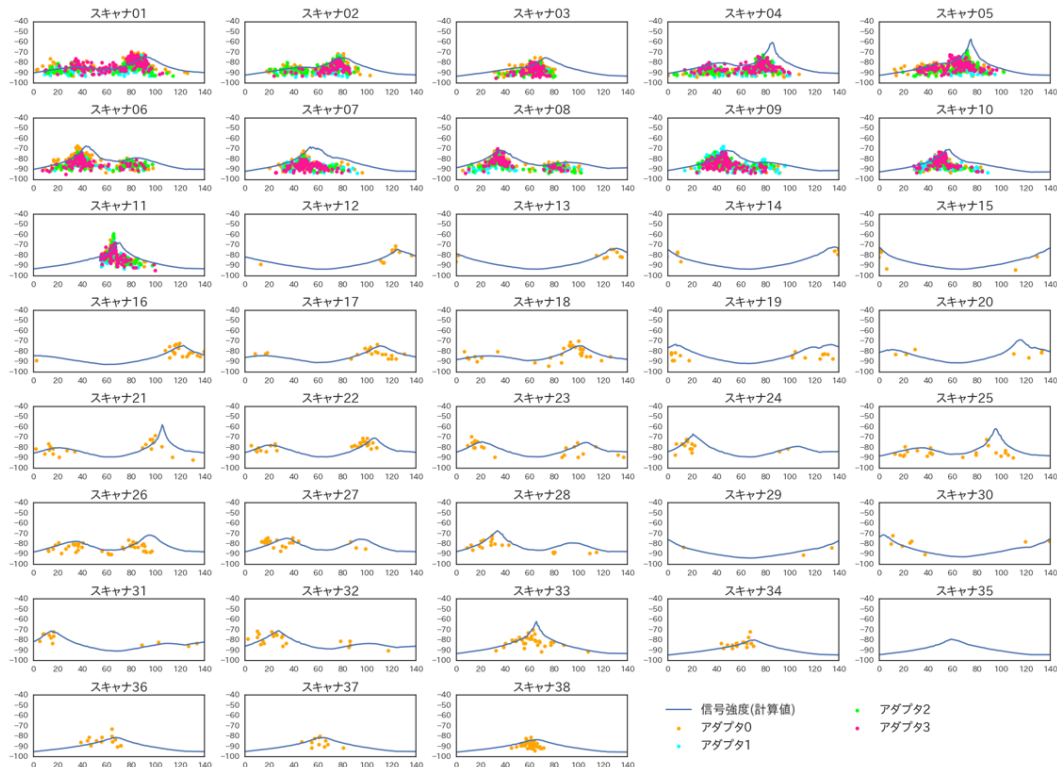


図 4.4: 計算した信号強度と実際に観測された信号強度の比較。各グラフの横軸は歩行開始からの秒数を、縦軸は信号強度を dBm で示す。

まく推定できていない。

表 4.1 を見ると、どの経路でもタンデム BLE スキャナの有無にかかわらず、時計回りを除いては左右で同じ精度を達成した。標準偏差では右半分のほうが良い値を出す傾向にあるが、大きな差はなかった。反時計回りに歩いた被験者について、正解の位置から計算した信号強度と、実際に受信したアダプタイジングパケットの信号強度を図 4.4 に示す。青色の線が計算による値で、点が実際の信号強度を示す。点の色は Bluetooth アダプタの番号に対応し、通常の BLE スキャナでは複





図 4.5: BLE タグの設定による平均誤差の変化


数の Bluetooth アダプタを持たないため、アダプタ 0 のみとなっている。タンデム BLE スキャナ 1 から 11 では各 Bluetooth アダプタにより多数のパケットが捉えられている一方で、その他の番号の BLE スキャナでは計算値が高いときにのみまばらに受信する傾向がわかる。タンデム BLE スキャナを利用することで多数のアドバタイジングパケットを捉えられ、より理想的な信号強度を抽出しやすくなるといえる。

4.4.2 BLE タグの設定による精度変化


表 3.3 で示した通り、今回の実験では被験者が設定の異なる 3 つの BLE タグを同時に携行したため、アドバタイジング周期と送信信号強度による精度への変化があるかを検証する。各経路での 3 名の被験者の平均誤差を図 4.5 に示す。いずれの経路でも、アドバタイジング周期が 0.25 秒 (4Hz) で送信パワーが -59dBm の BLE タグを使った場合は平均誤差が大きく、精度が悪い。一方、アドバタイジング周期が 0.1 秒 (10Hz) の場合は経路によって精度が良い送信パワーが異なる。したがって、送信パワー 4dBm の差は精度に大きな影響を与えず、主にアドバタイジング周期が精度に影響を与えるといえる。



(a) 島に1つのみ (a)



(b) 島に1つのみ (b)



(c) 左側の密度を調整

図 4.6: 一部の BLE スキャナを利用しない設定




図 4.7: 一部の BLE スキャナを利用しない場合の平均誤差の変化

4.4.3 利用する BLE スキャナ台数による精度変化

会場内の BLE スキャナ配置は図 3.22 に示したである。このうち、会場内左側の BLE スキャナ 12 から 15 および、中央の島部分の BLE スキャナ 12 から 28 は高密度に設置した。利用する BLE スキャナの台数により精度にどのような変化が起きるかを検証するため、一部の BLE スキャナを利用しない設定で精度を検証する。

設定は次のとおりとした: 会場右側と同じ程度の密度となるよう会場左側の一部の BLE スキャナを利用しない設定、中心部の島の BLE スキャナが 1 つずつになるように利用する BLE スキャナを制限した設定。各設定で利用されない BLE スキャナを図 4.6 にグレースアウトさせて示す。結果は図 4.7 に示す。もっとも複雑なジグザグ経路では、台数の制限で多少変化が見られるものの、大きな精度の変化は生じなかった。したがって、より少ない BLE スキャナ台数でも位置推定を行えるといえる。これは故障した BLE スキャナが出てでも推定を続行できることを示す。また、最初から設置する台数を減らすと、位置推定システムを低価格にできると考えられる。

4.4.4 タンデム BLE スキャナの Bluetooth アダプタ台数による精度変化

タンデム BLE スキャナは 1 台に複数個の Bluetooth アダプタを備えるため、利用するアダプタを制限した際の精度を検証する。タンデム BLE スキャナ 1 から 11 の Bluetooth アダプタ 0,1,2,3 から得られる 15 通りの組み合わせについて、それぞれ位置推定を行った。通常の BLE スキャナは使う Bluetooth アダプタの制限を無視して利用可能とした。結果を平均誤差が小さい順に並べて表

表 4.2: タンデム BLE スキャナの利用 Bluetooth アダプタによる精度の変化

利用アダプタ	平均誤差 (m)	標準偏差 (m)
0,1,2,3	3.62	1.75
0,2,3	3.65	1.78
0,2	3.66	1.79
0,3	3.72	1.94
0,1	3.73	1.87
0,1,3	3.74	1.87
0	3.75	1.83
0,1,2	3.77	1.90
1,2,3	5.40	2.98
2,3	5.75	3.11
1,2	5.91	3.48
1,3	6.24	3.25
3	6.40	3.25
2	7.00	3.67
1	8.71	4.43

4.2 に示す. 表より, 最も良い精度を達成できるのはタンデム BLE スキャナのすべての Bluetooth アダプタを利用した場合で, 平均誤差 3.62m であった. この 3.62m は, 展示ブースの 1 辺や通路の大きさが 3m の倍数を基準にしていることを考えると, 6m を超える大きさのブースや通路を用いるイベントで十分人の移動や滞在を推定できる精度といえる. 以降では使うアダプタが減るたびに精度が落ちていくが, Bluetooth アダプタ 0 を利用する場合はすべて 3 メートル台の精度を達成し, 利用しない場合は精度が大きく落ち込んだ. Bluetooth アダプタ 0 を利用しない場合でも, 各 Bluetooth アダプタを単体で利用するより, 複数利用するほうが精度は向上するといえる.

Bluetooth アダプタ 0 を利用するかどうかで精度の変化が起きた理由は Bluetooth アダプタごとに受信数が異なり, Bluetooth アダプタ 0 での受信数が多かったためだと考えられる. 実際の各 Bluetooth アダプタでのパケット受信数の平均値は表 4.3 に示すとおりで, Bluetooth アダプタ 0 が多かった.

表 4.3: Bluetooth アダプタごとのタンデム BLE スキャナ 1 台あたりの平均パケット受信数

アダプタ	受信数
0	217,916
1	181,701
2	181,490
3	188,159

4.4.5 議論

実データでの位置推定時、最良のパラメータの組は $(w, n, d_m, \sigma) = (3, 2.0, 4.0, 4.0)$ だった。スライド窓の窓幅 w が 3 秒だった理由は、取得できる信号強度サンプルの量と、歩行速度との兼ね合いだったと考えられる。長い窓幅を用いると遠い過去の位置で計測された信号強度が利用されてしまい、精度の低下につながる。また、パーティクルの最大移動速度 d_m が 4 メートル毎秒となった理由としては、より広範囲にパーティクルを散布して重みの大きい位置を探索する必要があったためだと考えられる。

信号強度-距離関数の減衰定数 n はベースとした位置推定手法と近い値が選ばれた。これは、信号強度における 1dBm の差が大きな距離の差として現れる (距離による減衰が生じにくい) ことを意味する。実際に G 空間 EXPO の会場はかなり広く、かつ天井が高かった。信号強度からの推定距離 d_{est} と対応させる σ は大きな値となった。これは、 d_{est} から多少遠い距離でも大きい重みを付与することを意味し、信号強度がノイズの影響を受けており、 d_{est} があまり正確でないということになる。

利用する機材の設定を変更した際の精度の変化を検証したところ、4.4.2 項より BLE タグのアダプタイジング間隔が短いほど、高精度に推定できた。タンデム BLE スキャナの利用 Bluetooth アダプタを変更した場合でも、複数の Bluetooth アダプタを用いるほうが良い精度となる傾向にあった。したがって、高精度な推定にはパケットを大量に受信し、信号強度をより多く取得する必要があるといえる。

また、台数を変化させての精度評価より、BLE スキャナの設置台数を減らしても精度への影響が少なかった。したがって、同じ面積に対してより少ない BLE スキャナ台数で推定を行える可能性が示唆された。精度に影響を及ぼさない範囲で BLE スキャナの台数を減らせば、機材に必要な金額を抑えられる。逆に、過酷な環境で BLE スキャナが故障しやすい場合は冗長性を持たせること

もでき、用途に合わせて調整が行える。

4.5 本章のまとめ

本章では、三角測量の考え方を基本に、パーティクルフィルタを組み合わせることで位置推定を行い、G 空間 EXPO2016 のデータを用いて誤差が平均で 3.62m となることを確認した。また精度検証では、被験者が所持していた 3 種類の設定の異なる BLE タグで精度が変化するか、BLE スキャナの台数を減らしても精度を保てるかについて実験を行い、BLE タグはパケットの送信頻度が高いものを用いると精度が良いこと、会場内の BLE スキャナは台数を減らしても精度をある程度保てることを確認した。また、タンデム BLE スキャナで利用可能な Bluetooth アダプタの数を減らした際の精度変化から、位置推定においてもタンデム BLE スキャナが有効に働くことを確認した。以上より、前章で提案したタンデム BLE スキャナが位置推定に有効にはたらし、イベント環境で事前データ収集なしに 3.62m の平均誤差で推定を行えることが明らかになった。また、BLE タグのパケット送信頻度の変更や、タンデム BLE スキャナの利用可能 Bluetooth アダプタの変更から、大量のパケットを取得して位置推定を行うほうが精度が良いこともわかった。

第 5 章

深層学習を利用した位置推定

この章では、前章で示した精度より高い精度を狙い、深層学習を用いた位置推定を提案する。深層学習を用いた手法は、画像認識・音声認識・自然言語処理などの分野で成功を収めており、他分野での利用も試みられている。位置推定分野でも、無線 LAN を用いた位置推定では従来の電波マップに代わって深層学習を用いる手法が提案されている。精度の改善が報告されている一方で、実環境への対応可能性は十分検証されていない。

電波マップを用いた位置推定でも深層学習を用いた位置推定でも、対象となる環境で学習用のデータを収集する必要がある。イベント環境では準備期間が短く、十分な量の学習用データを事前に収集できないため、数時間や数日のイベントでは使用が難しい。ある程度長期間で開催されるイベントでは学習に使えるようなデータを徐々に収集できるため、最初は他の手法を用いて途中から切り替え、より高精度な推定を使うという運用になる。ここでは、少ないデータでも効率的に学習を行えるような工夫として、信号強度の簡易なシミュレーションを行って、利用できるまでのリードタイムを減らすことも考える。

5.1 深層学習を利用した位置推定の試み

5.1.1 電波マップの利用から深層学習へ

すでに述べたように、無線通信を利用した位置推定では信号強度の不安定さが問題となる。電波は壁や床で反射・干渉を起こし、また利用する周波数によっては人体に吸収されてしまう。そのため電波の伝搬モデルによって送受信間の距離を推定すると、誤差が生じやすい。反射・干渉の正確な把握は難しく、また人体による減衰は環境内の人数にも影響されるため、伝搬モデルへの注入が難しい。

そこで、環境の電波的特性を考慮して位置推定を行うために、環境内の各地点で生じる電波的な特徴を事前に記憶しておく電波マップの構築が行われてきた。位置推定を行う際は観測した電波の情報をクエリとして電波マップとのマッチングし、推定位置を探す。

近年では、深層学習を用いた位置推定が提案されている。深層学習を用いる場合でも基本は変わらず、事前のデータ収集と実際の位置推定の2段階でモデルの構築・位置推定を行う。深層学習を用いた位置推定では、モデルの柔軟な表現力を生かして、電波マップを用いた手法を上回るような精度が達成されてきた。

高精度を達成してきた電波マップや深層学習にも、考慮しなければならない点がある。データ収集にかかるコストが大きな問題となるのは自明である。対象となる環境の特徴を学習させるためには、その環境で大量のデータ収集を行う必要がある。利用するモデルや求める精度次第ではあるものの、数分間の計測を数 m おきに行う時間的・人的コストは大きい。対象の環境が広ければそれに比例してデータ収集のコストが大きくなる。学校の教室や小規模なオフィス程度なら許容できたデータ収集コストも、より広い環境では現実的でなくなってくる。

イベント環境での位置推定では、データ収集がさらに難しい。準備期間の短さのため、事前のデータ収集が困難で、十分な量のデータを得られない。一方イベントの開催期間が長ければ、徐々に学習用のデータを収集できるため、最初は前章の手法を用いて、途中から切り替えるという運用が可能になる。以降では、深層学習を用いた2つの手法を考え、より高精度な推定を行えないかを検討する。最初に、前章の推定をより高精度に行うために信号強度を補正する手法を考え、次に信号強度の時系列から直接位置を推定する手法を考える。

5.2 オートエンコーダを用いた信号強度の補正の試み

深層学習を用いる際に、まず既存手法と組み合わせることを考えた。位置推定まで行うモデルの設計には多くの要素の考慮が必要だと考え、既存手法を用いつつ、精度を向上できないかを検討した。信号強度から距離を推定して利用する手法では、ノイズへの対処が肝要であるため、事前にノイズを除去した信号強度を入力することで、より安定して高精度な推定を実現できるのではないかと考えた。

この信号強度からのノイズ除去に深層学習を用いることとした。位置推定自体には前章の手法を用いることにし、信号強度からのノイズ除去にのみ深層学習を利用する。つまり、このモデルは(ノイズの乗った)信号強度の組を入力に、入力からノイズを除去した信号強度の組を出力する。入出力がほぼ同じものであるため、オートエンコーダを用いてこのノイズ除去を行うこととした。

オートエンコーダは、エンコーダ部分とデコーダ部分からなる。エンコーダ部分は入力側に配置され、入力されたデータを少ない数の特徴量に変換する。デコーダ部分は出力側に配置され、エンコーダの出す特徴量を伸張して入力されたデータを再構築する。オートエンコーダの学習時は通常、入力にも出力にも同じデータを与えるが、今回は実際の信号強度を入力に取り、正解位置から算出した理想値の信号強度を出力ターゲットにして学習させる。

5.2.1 オートエンコーダの構成

構成するオートエンコーダは、時刻 t において N 台の BLE スキャナ $(1, 2, \dots, N)$ が得た信号強度 r_k^t を並べた \mathbf{R}^t を入力として、それに含まれるノイズを除去した理想値 $\hat{\mathbf{R}}^t$ を出力する。入力 \mathbf{R}^t は式 (5.1) で示す。

$$\mathbf{R}^t = (r_1^t, r_2^t, \dots, r_N^t) \quad (5.1)$$

利用する層は全結合層とし、活性化関数には PReLU[107] を用い、過学習の抑制に Dropout を利用することにした。PReLU は入力のある成分 x_i に対し $f(x_i) = \max(0, x_i) + a_i \min(0, x_i)$ を出力する。これは負の入力に対して ReLU と異なる挙動を示し、値が 0 にならない。Dropout は学習時のみ利用し、事前に決めた確率にしたがって、ランダムに出力を 0 に置き換えて欠落を発生させることで、汎化性能を向上させる。

これらを用い、エンコード 3 層、デコード 3 層のオートエンコーダを図 5.1 のように構成した。オートエンコーダの入力側には、前処理を行う Preprocess 部を付与した。これは、入力する信号強度に存在する欠損値 (=パケットロス) の穴埋めを行い、またオートエンコーダへの入力に適するように値の変換を行う処理となる。この Preprocess では欠損値となっている部分を -100 で埋め、各スキャナで得られる信号強度の平均値をもとに -90 を 0 移動するようにすべての値への $+90$ の値のシフトを施す。またオートエンコーダの出力側に付与した Postprocess では出力の後処理を行い、Preprocess で行われた値シフトを戻すために -90 の値シフトを行う。

5.2.2 シミュレーションを併用した学習

実際にオートエンコーダを学習させ、信号強度を補正できるか検証する。対象の環境・データは前章と同じく G 空間 EXPO2016 とした。ただし先述のように、大規模イベントにおいては十分な学習データを収集するまでにはいくらかの期間が必要になる。そこでこの収集に必要な期間を低減するために、人工的に生成 (シミュレーション) した信号強度を用いて初期の学習を行い、その後実




図 5.1: デノイジングオートエンコーダ

データで追加の学習を行うことを考えた。これは、以下のようなシナリオを想定している。対象環境における展示ブースの配置や、スキャナの設置位置は事前に検討が行われ、問題が起きない限りはそのとおりに設営されるはずである。事前に対象環境の各所における信号強度がどうなるかをシミュレートし、そのデータを元に事前に学習済みモデルを作成しておく。その後、イベントの開催中に得たデータを追加の学習に用いて、モデルのパラメータを更新する。

信号強度シミュレーションでは、対象となる環境内でランダムに設定した 1 点について、 N 台の各 BLE スキャナ $1, 2, \dots, N$ に対する距離 $\mathbf{d} = (d_1, d_2, \dots, d_N)$ から、観測されるべき信号強度の組 $\mathbf{R}'' = (r''_1, r''_2, \dots, r''_N)$ を計算する。スキャナ k との距離 d_k から理想の信号鏡強度 r''_k を計算する際は、式 (5.2) を用いる。式 (5.2) における T_x と n はそれぞれ送信パワー (iBeacon パケット内に記載される値) と減衰定数である。

$$r''_k = T_x - 10n \log_{10} d_k \quad (5.2)$$

その後、 \mathbf{R}'' 内の信号強度 $r''_k (k = 1, 2, \dots, N)$ に対し、信号強度のノイズとして、式 (5.3) のように、事前に決めた平均と分散を持つ正規分布に従う乱数 γ を加え、 r''_k からなる信号強度の組 \mathbf{R}' を得る。

$$r'_k = r''_k + \gamma \quad (5.3)$$

さらに、パケットロスに相当する挙動として、 \mathbf{R}' 内の信号強度を事前に決めたパケットロス確率に従って -100 (=欠損値を示す値) で置き換え、式 (5.4) に例示するような信号強度の組 \mathbf{R} を生成する。この方法での信号強度の生成は非常に単純で並列化しやすいため、大量のデータをごく短い時間で生成できる。

表 5.1: シミュレーションのパラメータ

パラメータ	値	備考
送信パワー T_x	-59	実際の BLE タグの設定値
減衰定数 n	2.0	前章で用いた値
ノイズ γ の平均	-5	
ノイズ γ の標準偏差	4	
パケットロス率	0.85	全スキャナで共通

$$\mathbf{R} = (-100, r_2^t, r_3^t, -100, -100, \dots, r_N^t) \quad (5.4)$$

この \mathbf{R} を入力データに用い、 \mathbf{R}'' を教師データとしてオートエンコーダの学習を行う。学習に使うためのシミュレーションデータの生成では、パラメータを G 空間 EXPO2016 の環境に合わせる。そのためスキャナの数 $N = 38$ を設定し、スキャナ位置も実際のものを与えた。対象エリアも G 空間 EXPO2016 と同じく x 方向に 0 から 70m を、 y 方向に 0 から 23m を設定した。実際には到達不能な地点が混じる (例えば講演ステージ上にいるときのデータは登壇者が被験者でなければ得られない) が、今回はそのような条件を考慮しない。また、その他のパラメータを表 5.1 の通りに設定した。ノイズ γ が従う正規分布のパラメータは、得られる信号強度が理想的な値から平均で -5dBm 減衰するという想定のもとで、約 90% の値が理想強度以下になるように分布させた。上記の設定で、16 万組の $(\mathbf{R}, \mathbf{R}'')$ を生成した。

また、追加の学習を行う際は G 空間 EXPO2016 で得たデータのうち、精度検証に使うデータとは異なる被験者・異なる取得日のデータから 20 名分を用いた。実際に学習に用いるデータはこの 20 名分のデータについて、幅 1 秒の窓で窓内の最大の信号強度を抽出し、データを切り出した。BLE タグは 10Hz でパケットを送信するものを用い、窓内に存在する信号強度から最大のものを抽出し、最終的に 7.8 万の入力用信号強度データを得た。これに対応する教師データは UWB タグを用いて取得された正解位置情報を元に、各 BLE スキャナとの距離 d を算出し、式 5.2 を用いて理想の信号強度とした。

シミュレーションで生成したデータにおいても、実環境で得たデータにおいても、教師データには欠損値が含まれない (理想値をそのまま用いる) ようにした。これは、オートエンコーダによる欠損値の補完を期待してのことである。したがってこのオートエンコーダは、ノイズ除去のみでなく、欠損値に関して他の BLE スキャナで得た値を元に推測を行う役割も担う。

表 5.2: デノイズングオートエンコーダの学習時のパラメータ

パラメータ	値
入力特徴数	38 (BLE スキャナ台数と同じ)
全結合層の出力特徴数	19, 9, 5, 5, 9, 19, 38
Dropout の確率	0.3, 0.2, 0.1, 0.1, 0.2, 0.3
損失関数	L1Loss
最適化法	Adagrad
バッチサイズ	1000

オートエンコーダの学習時のパラメータは、表 5.2 に示す値を用いた。エンコーダの全結合層の出力はそれぞれ入力された次元数のおよそ半分とした。損失関数には平均絶対誤差を出力する L1Loss を用いて、入力と出力の差分を比較させる。バッチサイズには 1000 を用い、エポック数はシミュレーションデータで 200、追加の実データで 100 とした。実際の実装と学習は Python 向けの深層学習用ライブラリである PyTorch (バージョン 0.4.1) を用いて行った。

5.2.3 再構築した信号強度と実データの比較

学習したオートエンコーダに、実際に被験者のデータを入力して得られた結果の例を図 5.2 に示す。図では横軸に歩行開始からの経過時間を、縦軸に信号強度を示す。図上の点は、橙色が正解位置から算出した理想の値を、緑色がオートエンコーダの出力値を、紫色が実際に得られた信号強度を示す。図より、パケットロスが多い BLE スキャナ 12 以降では理想に近い信号強度を復元できていることがわかる。スキャナ 12 以降はすべて 1 つの Bluetooth アダプタを持つ通常の BLE スキャナであったため、パケットの受信性能が悪く、もともと得られるパケットが少なかった。入力した信号強度を示す紫の点は、これらの BLE スキャナでは理想の信号強度が強いタイミングでしか得られず、ほとんどの時間においてパケットロスが起きていた状態である。この傾向は BLE スキャナ 12 から 17 で顕著に出ている。しかしオートエンコーダが出力した信号強度ではおおむね理想の信号強度に近い形状が得られており、このオートエンコーダに期待した性能のうち、欠損値の補完に関してはよい働きをしているといえる。

一方で、理想の信号強度が大きくなる箇所でも出力された値が理想の値に追従できていない。この傾向は理想の信号強度に急峻な変化で極大値が現れるすべてのスキャナで共通して見られる。信号強度が急激に大きくなる場所は、推定対象がスキャナに接近しているときを示す。推定対象とス

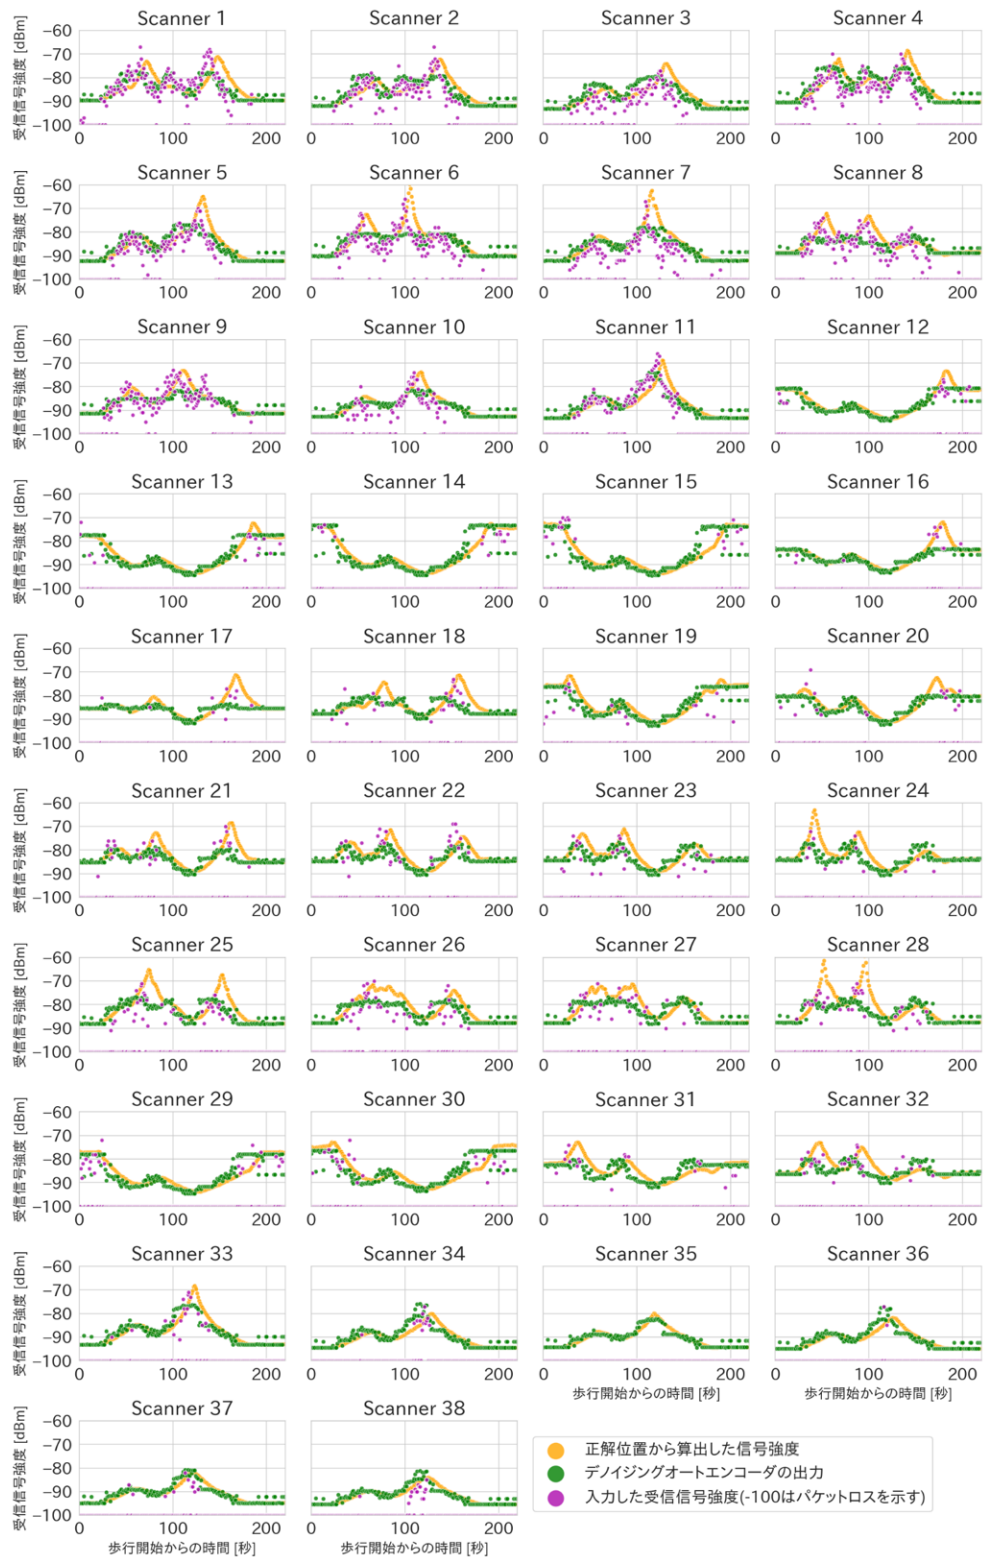


図 5.2: オートエンコーダによる信号強度の補正の例 (入力・理想・再構築)

キャナの距離がじゅうぶんに近いときは、少しの距離変化が信号強度の大きな変化につながる。したがってこのときに得られる強い信号強度は、位置推定に対して重要な役割を果たす。そのため、オートエンコーダが出力した信号強度がこの変化を再現できないことは、そのまま低精度な位置推定結果につながる可能性が高い。

ほぼパケットロスになるような弱い信号強度の領域をじゅうぶん再現できる一方で、位置推定で重要と思われる大きな変化のある信号強度を再構築できなかった理由として、値の復元のしやすさの差が挙げられる。信号強度は送受信間の距離 d に応じて $-\log_{10} d$ の定数倍で変化し、スキャナと推定対象の距離が大きいと変化量が小さくなる。したがって、あるスキャナから十分離れた位置で推定対象が移動しても、信号強度に生じる変化は微小であるか、緩やかな変化である。このときの信号強度はほぼ同じ値となるため、相対的にサンプル数が増え、ノイズの形状を学習しやすく、パケットロスが多くても値を復元しやすかったと考えられる。また、もともとパケットロス部分では入力が単に欠損値を示す値なので意味を持たず、オートエンコーダが自由に入出力の関係を定義できたために一部のスキャナでほぼ完璧に理想値をなぞる出力が得られたとみなせる。

一方、あるスキャナと被験者が近い場合は急峻な信号強度の変化が生じる。またこのときはノイズによって信号強度が受ける影響が大きい(減衰しても受信は可能。遠方では減衰したらそのままパケットロスになってしまう)。そのため、信号強度が大きいときは急峻な変化のためにサンプル数が相対的に少なく、またノイズによる分散が大きいため真の値を推定しづらい。またこのときは他のスキャナにおける小さな変化量から、そのスキャナにおける大きな信号強度を再構築しなければならない。これは直感的に考えても困難であり、学習方法に工夫を加えないと解決が難しいと考えられる。

5.2.4 再構成した信号強度を利用した既存手法での位置推定

このオートエンコーダで復元した信号強度を用いて、位置推定を試みる。前章の手法をそのまま利用し、入力するデータのみをオートエンコーダの出力で得られた信号強度にした。結果、各経路における推定経路は図 5.3 のようになった。時計回り・反時計回り関係なく、どの経路においても推定位置が左下の歩行開始位置から会場内の通路を無視して右上に向かい、右から2つ目のブース島で鋭角に曲がって真右に向かい、来た道を戻りつつ若干上側を通りながら歩行終了位置に向かうという、上弦の弧・方向転換・下弦の弧の形状となった。推定精度自体は前章の結果より大きく悪化し、誤差が平均 8.41m かつ標準偏差 4.51m となった。

推定結果の点が無条件で会場を斜めに移動する理由の調査のために、位置推定時に生成される重

みマップの可視化を行った。時計回りの例を図 5.4 に、ジグザグ経路の例を図 5.5 に、それぞれ示す。これらの図からわかるように、経路に関係なく、会場を横断するように重みの高い領域が作られていた。また、図上に矢印で示されるパーティクルもこの領域に沿っておらず、位置を推定できていない状態とみなせる。このような重みマップとなった理由と、推定結果が悪かった理由を考える。

まず重みマップが一様となった理由として、欠損値が補完されたために低い信号強度が大量に利用可能になったことが挙げられる。低い信号強度を利用して重みマップを生成すると半径の大きい円状となる。欠損値の補完により、多数のスキヤナで低い信号強度が利用可能になってしまうため、この大きな半径の円形状の重みマップが大量に生成される。それらを重ね合わせた際の重複領域は BLE スキヤナによりまったく生じないか、逆に多く重複し帯状になる。3 台の BLE スキヤナで大きく異なる信号強度から重みの高い領域を生成した場合と、そこに追加で弱い信号強度からも重みの高い領域を生成した場合の模式図を図 5.6 に示す。この図と同様の状況が生じ、図 5.4 や図 5.5 のような重みマップとなったと考えられる。

重みマップからもわかるように推定結果が悪かった理由も弱い信号強度の補完にあると思われる。そもそも弱い信号強度は 1dBm の変化が大きな距離の差になってしまうため、位置推定に対する価値が低い。そのため、いたずらに弱い信号強度を増やしても意味がない。さらに、図 5.2 からわかるように、今回構成したオートエンコーダでは信号強度の高い領域の復元性が悪かった。強い信号強度は位置推定に対して重要であるため、この復元性が悪かったことも悪い推定精度につながった。以上より、オートエンコーダによって補正した信号強度を用いて既存の位置推定を利用する試みはうまく働かなかった。逆にこれらを組み合わせて用いる場合は、位置推定側にも手を加える必要がある。




図 5.4: 再構築した信号強度を用いた推定における重みマップの例 (時計回り)

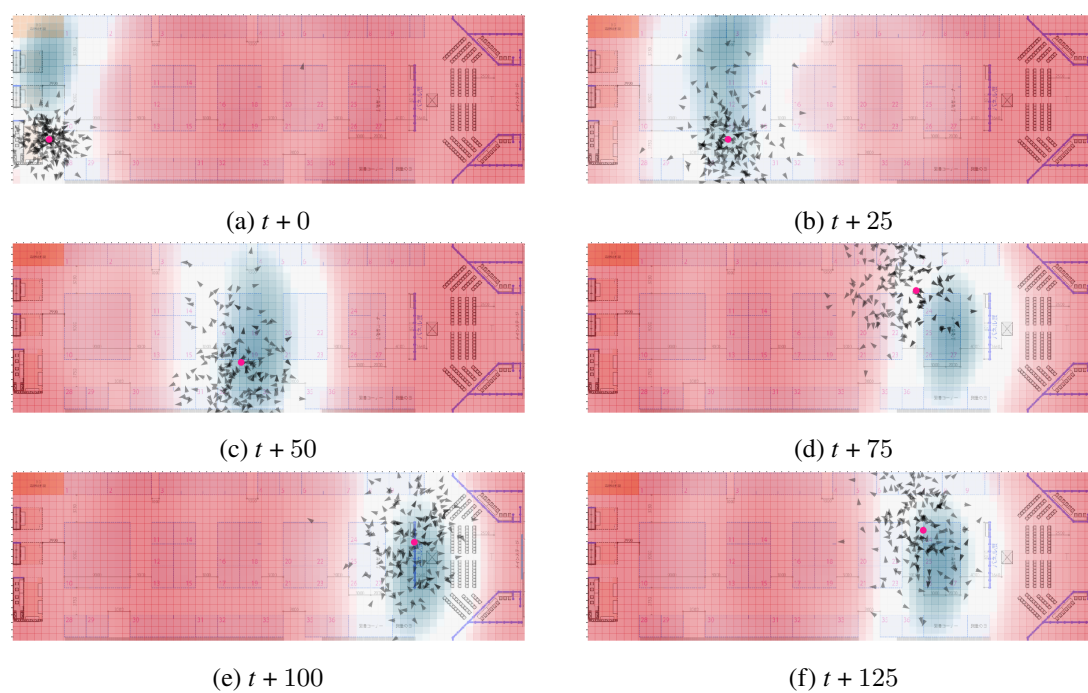


図 5.5: 再構築した信号強度を用いた推定における重みマップの例 (ジグザグ)

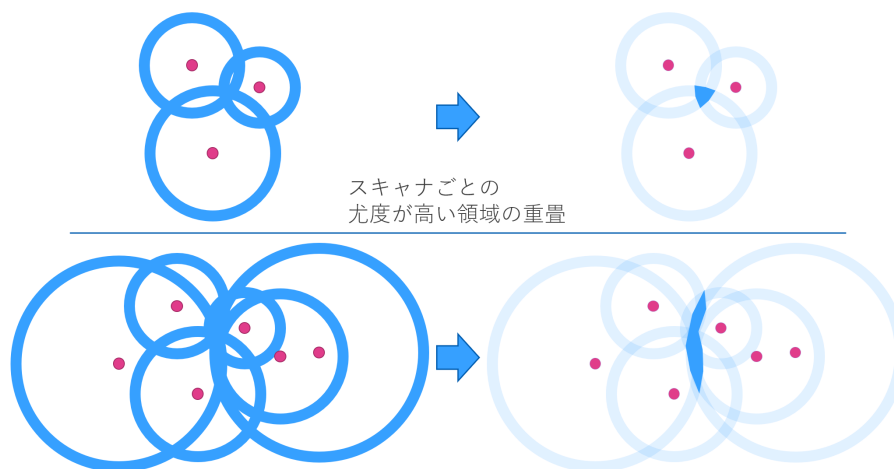


図 5.6: 利用可能な信号強度の多寡による重みマップの面積の模式図

5.3 時系列情報の利用を考慮した深層学習位置推定モデル

オートエンコーダによる信号強度の再構成と既存手法の組み合わせでは精度が向上しなかったため、他の手法を考える。既存の深層学習による位置推定では、モデルが電波マップの置き換えに使われ、モデルの出力がそのまま位置ではなかった。モデルの出力は重みとして用いられ、最終的な位置は加重平均を取って表現していた。

モデルが位置に対応する適切な重みを出力できるなら、直接位置を出力させることもできると考えた。そこで、信号強度を入力にして推定位置を直接出力する End-to-end の深層学習位置推定モデルを提案する。出力を位置とするため、モデルの出力にさらに操作を加えて推定位置にする必要がない。

モデルの設計には様々なものが考えられるが、推定対象の位置は以前の位置に依存して、信号強度もそれに合わせて時系列で変化することに注目する。そこで、時系列情報を取り扱うために再帰型ニューラルネットワーク (RNN; Recurrent Neural Network) を用いる。これに合わせ、入力を信号強度の時系列に、出力をその時系列における最新の位置とした。以上より、入力・出力の形式は次のとおりとなる。

時刻 t においてスキャナ k が観測した信号強度 r_k^t の組 \mathbf{R}^t を用いて、 N 台のスキャナの場合には式 (5.5) で示される行列になる。モデルには信号強度の時系列を入力するため、式 (5.5) で示される時刻 t_1 から t_2 までの \mathbf{R} を並べた $\mathbf{R}^{(t_1, t_2)}$ を用いる。出力は、入力内の最新の時刻 t_2 における対象の推定位置 $\hat{\mathbf{P}}^{t_2} = (\hat{x}^{t_2}, \hat{y}^{t_2})$ とする。

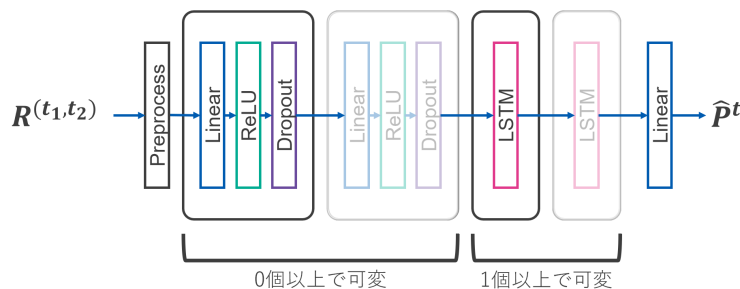


図 5.7: 全結合層と LSTM からなるネットワーク構成の概要

$$R^{(t_1, t_2)} = \begin{pmatrix} r_1^{t_1} & r_2^{t_1} & \cdots & r_N^{t_1} \\ r_1^{t_1+1} & r_2^{(t_1+1)} & \cdots & r_N^{(t_1+1)} \\ \vdots & \vdots & \ddots & \vdots \\ r_1^{t_2} & r_2^{t_2} & \cdots & r_N^{t_2} \end{pmatrix} \quad (5.5)$$

5.3.1 モデル概要

モデルの層構成の概要を図 5.7 に示す，モデルは Preprocess-Linear-LSTM の形を基本とすることにした．Preprocess はオートエンコーダで利用したものと同じ前処理（欠損値の穴埋めと，値のシフト）を行う．Linear 部は全結合層で，0 個以上において，時系列の長さは変えずに信号強度に線形変換を施して特徴量にする（全結合層 0 の場合は信号強度をそのまま後ろの層に渡す）．全結合層で用いる活性化関数には正の入力はそのまま出力し，負の入力は 0 を出力する ReLU を用いた．また，学習時はここに Dropout を入れ，過学習の抑制を行わせる．全結合層を通過したデータは，1 つ以上の LSTM 層を通過させるようにした．時系列の利用はこの LSTM 層に行わせる．複数層の場合は，後の LSTM 層が前の LSTM 層の出力データを処理するように動く．LSTM 層での処理が終了したら，LSTM 層の最後の隠れ層の状態 h を後に続く全結合層で 2 次元位置に変える．全結合層と LSTM 層には学習時に Dropout を挿入し，過学習を抑制する．

5.3.2 損失関数

モデルが出力する推定の評価には損失関数が必要である．ここでは，既存の損失関数ではなく人の移動が持つ特性を考慮した損失関数を設定する．今回用いる損失関数は，式 (5.6) のように 3 つの項から構成した．入力にはモデルが出力した $\hat{\mathbf{P}}^t$ と，その時刻の正解位置 \mathbf{P}^t に加え，1 タイムステップ前の正解位置 \mathbf{P}^{t-1} も用いる．式中の w_m, w_c, w_r は各項に対する重みとする．ただし式

(5.7) および (5.8) ではそれぞれ \mathbf{P}^t と \mathbf{P}^{t-1} の間、 $\hat{\mathbf{P}}^t$ と \mathbf{P}^{t-1} の間の距離を計算する。

$$\begin{aligned} L(\hat{\mathbf{P}}^t, \mathbf{P}^{t-1}, \mathbf{P}^t) &= w_m \cdot \text{MSE}(\hat{\mathbf{P}}^t, \mathbf{P}^t) \\ &\quad + w_c \cdot d \cdot (1 - \cos(\mathbf{P}^t - \mathbf{P}^{t-1}, \hat{\mathbf{P}}^t - \mathbf{P}^{t-1})) \\ &\quad + w_r \cdot \text{ReLU}(\hat{d} - d) \end{aligned} \quad (5.6)$$

$$d = \text{distance}(\mathbf{P}^t, \mathbf{P}^{t-1}) \quad (5.7)$$

$$\hat{d} = \text{distance}(\hat{\mathbf{P}}^t, \mathbf{P}^{t-1}) \quad (5.8)$$

損失関数の各項は、第一項は一般的に使われる MSE (Mean Squared Error) を示す。第二項は $t-1$ から正解位置と推定位置がどの方向に動いたかをコサイン類似度で比較し、進行方向についての損失とする。人が歩く時、その進行方向は急激には変化しないという仮定を置き、お互いの進行方向に差があるときに大きい値が生じるようにした。この項にはさらに正解位置の移動距離の積算を行う。これは、対象があまり移動していないときには多少移動方向を間違えても許容するが、大きな移動の際には方向を間違えないようにさせる効果を持つ。第三項は実際の移動距離より推定が飛躍する際にのみ値が生じる。これらにより、単純な位置に加えて、進行方向を間違えない制約と、遠くに行きすぎないようにする制約を加える。

5.4 End-to-end 位置推定モデルの推定精度の評価

実際にモデルの学習を行い、G 空間 EXPO2016 で収集したデータを用いて推定精度を評価する。前章と同様に、推定位置と正解位置との距離で評価を行う。

学習時はオートエンコーダの際と同様に、簡単な信号強度のシミュレーションで生成したデータでの学習と、実データでの追加学習を行う。ただし、今回は信号強度の時系列が必要となるため、それぞれに以下の変更を加える。変更したシミュレーションでは、まず対象となる位置 \mathbf{P}^{t_1} を 1 点ランダムに選んだあと、その位置から指定距離以内の別なランダムな点 \mathbf{P}^{t_2} を選ぶ。その間を時刻 t_1 から t_2 で移動したものとして扱い、 t_1 から t_2 までの各タイムステップのデータを生成する。これを並べて、モデルへの入力データ $R^{(t_1, t_2)}$ とする。出力形式は推定位置であるため、入力と組み合わせる教師データは \mathbf{P}^{t_2} をそのまま用いる。また、損失関数の入力とするため、 \mathbf{P}^{t_2-1} の点も保存しておく。

シミュレーションでは生成する時系列の長さ (モデルに入力する時系列の長さに同じ) と、時刻

表 5.3: 位置推定モデルのパラメータ

パラメータ	値	備考
入力時系列の長さ	10	(秒)
モデルへの入力特徴数	38	スキャナ台数と同じ
全結合の出力特徴数	$2 * N_{in_feat}$	入力された特徴量の倍を出力
Dropout の確率	0.3	全 Dropout で共通
LSTM 隠れ層の次元	64	
損失関数の重み	1, 10, 5	順に w_m, w_c, w_r
最適化法	Adagrad	
バッチサイズ	100	

t_1 から t_2 での最大の移動距離が必要となる。今回は時系列の長さを 10 秒とし、最大の移動距離には 10m を設定した。この設定で $(R^{(t_1, t_2)}, P^{t_2}, P^{t_2-1})$ の組を 16 万生成した。

追加の学習に用いる実データも今回のデータ形式に合わせて取得方法を変更する。連続した 10 秒のデータが必要となるため、1 つの入力データを作る際は、幅 1 秒・スライド 1 秒のスライド窓を用いて窓内最大の信号強度を抽出する操作を 10 秒分行った。対応する教師データ、損失関数用のデータは UWB タグによる正解位置から取得した。上記の方法を用いて、オートエンコーダの際と同様に、G 空間 EXPO2016 で得たデータから精度検証に使うデータと異なる被験者・異なる取得日のデータから 20 名分使い 7.8 万のデータを抽出した。

5.4.1 最適な層の数の検討


モデル概要で述べたように、まずは推定精度がよい層の組み合わせを探す。全結合層を 0,1,2,3,4 層・LSTM を 1,2 層から組み合わせた合計 10 パターンの構成について推定精度を評価して、最も精度の良いものを以後の検証でも用いる。直感的には全結合層が多ければ信号強度がその分柔軟に処理され、LSTM については 1 層の場合は時系列の情報をそのまま利用し、2 層の場合は時系列の変化度を捉える。利用するパラメータは表 5.3 の通りとし、シミュレーションで生成したデータを用い 200 エポック、実データを用いて 100 エポックの学習を行った。モデルの学習後、精度検証用のデータを用いて位置推定を行い、量的・質的な評価を行った。

表 5.4: 累積確率 0.5, 0.75, 0.9 の点での誤差


全結合層	LSTM 層	各累積確率 p での誤差 [m]		
		p=0.5	p=0.75	p=0.9
0	1	2.19	3.83	6.15
1		1.30	2.44	4.26
2		1.80	2.88	4.94
3		1.60	3.07	4.39
4		2.36	4.59	10.1
0	2	1.87	3.37	5.70
1		1.48	2.97	5.70
2		1.66	2.93	4.62
3		1.51	2.85	4.95
4		1.56	3.02	4.83

表 5.5: 誤差平均と標準偏差

全結合層	LSTM	平均 [m]	標準偏差 [m]
0	1	2.83	3.47
1		1.92	2.05
2		2.27	2.05
3		2.07	1.74
4		3.62	3.52
0	2	2.53	2.38
1		2.39	2.56
2		2.20	2.11
3		2.22	2.27
4		2.20	2.19



(a) LSTM が 1 層の場合



(b) LSTM が 2 層の場合

図 5.8: ネットワーク構成ごとの累積誤差分布

量的評価

それぞれの層数について正解位置と推定位置の誤差をとり、累積確率を計算してグラフを作成した。グラフを図 5.8 に示す。図 5.8a は LSTM 層が 1 つのもの、図 5.8b は LSTM 層が 2 つのものにそれぞれ対応する。また、各構成で累積確率が 0.5, 0.75, 0.9 になったときの誤差を表 5.4 に示し、平均及び標準偏差を表 5.5 に示す。

図 5.8a では、全結合層の数が 0 のときと 4 のときに性能が劣っていた。最も良かったのは全結合層が 1 層のときであった。LSTM が 2 層のときは、図 5.8b からわかるように、全結合層の数にかかわらずあまり性能は変化しなかった。この傾向は表 5.4 でも同様である。表より全結合層が 1 層で、LSTM 層が 1 層の設定が累積確率 0.5, 0.75, 0.9 の各点において最もよい精度を達成した。次点で良かったのは全結合層が 3 層で、LSTM 層が 1 層のものだった。表 5.5 でも全結合 1 層・LSTM1 層が最もよい平均誤差となった。また全結合 3 層・LSTM1 層は誤差の標準偏差が最もよいものである。しかし、明らかに精度で劣る全結合層の数が 0 または 4 で LSTM 層が 1 層のものを除けば、LSTM の数に関わらずどの構成にも精度に大きな差はない。類似する精度ならシンプルなモデルを選ぶべきだと考えると、全結合層が 1 層で、LSTM 層が 1 層の構成がもっともよいモデルとなる。


一方、表 5.5 より、ほぼすべての構成で誤差の標準偏差が 2m を超えており、安定して収束しているとは言えない結果となった。安定した推定を行うには、今回検討しなかった変更が必要と思われる。例えば、推定した信号強度も出力できるようにして損失関数の項として利用するなどである。質的評価では実際に推定された位置を地図上に表示してこれを確認する。

質的評価


量的評価で誤差が小さかった (全結合層, LSTM) = (1,1), (2,2) と、推定誤差が大きかった (4,1), (0,2) について、正解位置と推定位置を会場地図にプロットしたものを図 5.9 に示す。すべてジグザグ経路に対しての推定結果を用い、図内の各点は、橙色の点が推定位置を、紫色の点が実際の被験者の位置を示す。

最も精度が良かった構成の推定結果を示す図 5.9a では、実際の経路からばらつきは生じるものの、推定点はおおむね経路に沿って分布している。一方全結合 2 層・LSTM2 層の場合の結果である図 5.9b では、図 5.9a と比較して実際の経路上に来る点が多いものの、推定点が集まる節のような箇所が存在する。精度が悪かった例の図 5.9c では、会場内左側の点が正解位置とは異なる場所に推定されていた。また、図 5.9d は最も精度が良かった図 5.9a と似たような出力となったものの、実験受付周辺で点が収束しなかった。


量的な評価で述べたように、標準偏差が大きかったことに対応して、どの図でも推定点が被験者の歩いた通路に沿っていないことがわかる。いずれの結果でも特に会場の左側で結果が悪い。会場の右側にはタンデム BLE スキャナが置かれ、左側には通常の BLE スキャナのみがあったことから、その有無が精度に影響したといえる。




(a) 最良の場合: 全結合1層・LSTM1層



(b) 良い場合: 全結合2層・LSTM2層



(c) 悪い場合: 全結合4層・LSTM1層



(d) 悪い場合: 全結合0層・LSTM2層

図 5.9: 精度が良い場合・悪い場合の推定位置・正解位置の地図プロット

表 5.6: 出力特徴数を変更した際の誤差の平均と標準偏差

倍率	平均 [m]	標準偏差 [m]
2 倍 (デフォルト)	1.92	2.05
1 倍	2.95	2.28
3 倍	2.47	2.26
4 倍	2.15	1.97

表 5.7: LSTM の隠れ状態の次元を変更した際の誤差の平均と標準偏差

隠れ状態の次元	平均 [m]	標準偏差 [m]
64 (デフォルト)	1.92	2.05
32	2.64	2.45
128	2.24	2.16
256	2.19	2.03

5.4.2 各種パラメータを変更しての評価

モデルが持つパラメータを変更した際の推定精度を確認する。

全結合層の出力特徴数

表 5.3 では、全結合層が出力する特徴の数は、その入力の 2 倍に設定していた。たとえば、入力 が 38 の場合は出力が 76 となる。ここでは、その倍率を 1 倍、3 倍、4 倍に変更して評価した。結果を表 5.6 に示す。2 倍が最も良い小さい平均誤差となり、それに 4 倍が続いた。1 倍の場合は 2 倍のときより平均誤差が 1m ほど劣るため、ある程度の特徴数が必要だといえる。また、4 倍のときは標準偏差が小さく、より多くの特徴を使えばより安定した推定を行える可能性がある。

LSTM の隠れ状態の次元

LSTM の隠れ状態の次元は、LSTM の表現力に影響する。表 5.3 で設定していた LSTM の隠れ状態の次元は 64 であった。これを 32, 128, 256 に変更して位置推定を行った結果を表 5.7 に示す。表より、もともと使っていた 64 が最も小さい誤差となり、128 や 256 でも大きな精度の差はなかったいっぽうで、32 では少々劣った結果となった。そのため、ある程度の大きさの値が必要だといえる。実際には入力の時系列を伸ばしたら、より大きな表現力が要求されるため、この値も大きくすべきである。

表 5.8: 最適化手法を変更した際の誤差の平均と標準偏差

手法	平均 [m]	標準偏差 [m]
Adagrad (default)	1.92	2.05
Adam	2.28	1.99
SGD	3.15	2.56

最適化手法

学習時の最適化を表 5.3 で利用していた Adagrad から変更して、推定精度が変化するか調べた。SGD (確率的勾配降下法) と Adam の 2 手法を使ってそれぞれ位置推定の精度を調べた。この結果を表 5.8 に示す。表より、Adam はデフォルトの Adagrad と大きく変わらない結果を出した一方で、SGD では劣った結果となった。以上より、より様々な工夫が施されている Adam や Adagrad のほうがより高精度に推定できるモデルを作成しやすいといえる。

損失関数の項の重み

式 5.6 の各項に付与した重み (w_m, w_c, w_r) について、値を変更して精度を調べた。重みは順に MSE に対して、コサイン類似度に対して、位置の飛躍に対してのものであり、どの損失を重く扱うかを決める。デフォルトの (1, 10, 5) では、方向を間違えた際に大きな損失が発生する。ここでは、(1, 10, 5) の順序を入れ替えたパターンと、全てに同じ重みを課す (1,1,1) を比較した。結果は表 5.9 に示したとおりで、どの組み合わせでもあまり大きな差は生じなかった。これは、最適化手法が優れておりそれぞれの項の重みが異なってもうまくモデルのパラメータを更新できたためだと考えられる。 w_m に大きい重みをかけた際は標準偏差が小さくなっており、今後安定した推定を狙う際には重みをいくらかかけるべきだと示唆された。

表 5.9: 損失関数の各項の重みをを変更した際の誤差の平均と標準偏差

重さの組み合わせ	平均 [m]	標準偏差 [m]
1, 10, 5 (default)	1.92	2.05
1, 5, 10	2.26	2.14
5, 1, 10	2.26	2.03
5, 10, 1	2.08	1.76
10, 1, 5	2.21	1.81
10, 5, 1	2.20	2.24
1, 1, 1	2.37	2.12

表 5.10: 実データ量を変更した時の累積確率 0.5, 0.75, 0.9 の点での誤差

実データ量	各累積確率 p での誤差 [m]		
	$p=0.5$	$p=0.75$	$p=0.9$
78,000 (デフォルト)	1.30	2.44	4.26
39,000	1.87	3.37	5.49
18,000	1.42	2.82	4.66
8,900	1.27	2.50	4.78
0	3.21	6.21	9.53

表 5.11: 実データ量を変更した時の誤差平均と標準偏差

実データ量	平均 [m]	標準偏差 [m]
78,000 (デフォルト)	1.92	2.05
39,000	2.42	2.07
18,000	2.08	2.07
8,900	1.97	2.10
0	4.14	3.39

5.4.3 実環境トラブルを想定した精度検証

実際にイベント環境で位置推定を行う場合は、様々なトラブルが起きる可能性がある。ここでは、(1) 実データの量を減らした場合と (2) 利用できるスキャナ台数を減らした場合の 2 パターンについて、精度の評価を行う。

実データ量を減らした場合の精度

本手法では、シミュレーションデータと実データを併用した学習を採用した。長期の開催期間では徐々に学習に用いるデータが増えていき、精度に変化が生じるはずである。ここでは、学習で利用する実データ量が少ない場合の精度変化を検証する。もともと利用していた 20 名分・7.8 万のデータから、実験時間が長い被験者のデータから取り除いて量を減らしたデータで学習を行う。これは、正確な位置を記録しながら長時間の学習用のデータ収集を行うことが難しいという想定に基づく。特に元の実験時間が長い 5 人を除いた 15 名分・3.9 万、更に減らして 11 名分・1.8 万、8 名分・0.89 万と追加学習を行わない 0 名分・0 万の 4 パターンについて推定精度を調べた。





図 5.10: 実データ量を変更した際の誤差分布

誤差の分布を表 5.10 および図 5.10 にそれぞれ示す。また、誤差の平均と標準偏差を表 5.11 に示す。実データを全く使わない場合は明らかに精度が劣ることが表と図よりわかる。もともとの 7.8 万の場合と比較して 1.8 万、0.89 万の場合は精度の低下が小さかった。


実際に会場地図上に推定位置をプロットした結果を図 5.11 に示す。図 5.11a においては、左半分が特に悪い結果となっている。表 5.10 や図 5.10 に見られた精度の悪化はこれが原因だったと推測される。図 5.11b および図 5.11c は図 5.9a と類似した結果となっている。

データ量を絞っても精度の低下が少なかった理由としては、データに含まれる歩き方のバリエーションが考えられる。今回データ量を減らす際は実験時間が長い順に脱落させていった。そのため、実験時間が短い被験者のデータが残ることになった。実験時間が短い被験者は単純な(会場を一周するだけ、特定の展示のみ観覧する、などの)経路を取ったはずである。結果として、追加の学習で利用したデータがテストデータと近いものになり、過学習状態を招いて精度の低下が少なかったと考えられる。


イベント来場者の歩行パターンは、あたりを見回しつつ遅めに歩く、人を避けて左右に振れつつ歩く、興味のあるブースに滞在し続けるなどが支配的だと考えられる。そのため、データ収集時にはなるべく多様なパターンが含まれるように注意するべきである。



(a) データ量: 39,000



(b) データ量: 18,000



(c) データ量: 8,900

図 5.11: 推定結果のプロット (データ量変更時)

BLE スキャナが故障した場合

BLE スキャナに発生するトラブルはハードウェア的な故障・電源断・ネットワーク障害など多岐にわたる。この状況では、トラブルが起きた BLE スキャナからは一切の packets 情報が転送されない。ここでは、このようなスキャナ故障を想定して、学習時はすべての BLE スキャナからのデータを利用可能にし、テスト時はいくつかの BLE スキャナのデータを常時欠損させて位置推定を行う。BLE スキャナの制限パターンとしては、前章でも利用した「島に1つのみ (a)」(図 4.6a)に加え、図 5.12 に示すように左側の BLE スキャナを減らした「さらに低密度」の2つを用意した。学習時のデータには変更を加えず、テスト時に利用不可能な BLE スキャナの信号強度を -100 (欠損値)としてモデルに入力した。

量的な評価を表 5.12 と表 5.13 に示す。BLE スキャナを制限しない場合に比べ、精度が劣る結果となった、この傾向は、図 5.13 に示した誤差の分布でもわかる。精度は劣るものの、島に1つのみ (a) の平均誤差は、前章の同じ状況の結果 (5.49m) をしのいでいる。




図 5.12: 「さらに低密度」の BLE スキャナ制限パターン

表 5.12: スキャナ脱落時の累積確率 0.5, 0.75, 0.9 の点での誤差

パターン	各累積確率 p での誤差 [m]		
	$p=0.5$	$p=0.75$	$p=0.9$
脱落なし	1.30	2.44	4.26
島に 1 つのみ (i)	1.88	3.44	6.25
さらに低密度	2.01	3.76	6.26

地図上での表示は図 5.14 に示した。図 5.9a と比較して、図 5.14a では BLE スキャナ 5 と BLE スキャナ 6 の周辺で差が大きい。これらの BLE スキャナはパケットロスの少ないタンデム BLE スキャナであるため、制限したときの影響が大きかったと推測される。対照的に BLE スキャナ 22 から BLE スキャナ 27 は通常の BLE スキャナであり、図 5.14a でもその影響は少ない。通常の BLE スキャナはタンデム BLE スキャナと比較してパケットをロスしやすいため、通常稼働時でも欠損値が混ざる可能性が高い。そのため、これらの BLE スキャナの脱落は推定精度にあまり影響しなかった。しかし図 5.14b では BLE スキャナ 13, 15, 17, 30 の脱落で会場左上のほうに大きな影響が生じた。そのため、利用不可能になると精度に影響する BLE スキャナと影響しづらい BLE スキャナがあるといえ、冗長性を確保しようとする配置の検討の余地が大きい。実際の環境ではデータ収集システムでスキャナ状態の監視を行うことになるため、故障が発生した段階でこの手法で推定した位置を信用せず、前章の手法に切り替えるべきである。

表 5.13: スキャナ脱落時の誤差平均と標準偏差

パターン	平均 [m]	標準偏差 [m]
脱落なし	1.92	2.05
島に1つのみ (i)	2.63	2.60
さらに低密度	2.73	2.44






図 5.13: スキャナ脱落時の誤差分布



(a) 島に1つのみ (i)



(b) さらに低密度

図 5.14: スキャナ脱落時の推定位置のプロット

5.4.4 他手法との比較

G 空間 EXPO2016 でのデータ収集では他手法を直接適用可能なデータが集められていないため、直接の比較が行えない。本来、他手法との比較は同じ環境での検証がひとつであるが、ここでは環境やデバイスの差を考慮しつつ論文で報告されている精度との比較を行う。

Faragher ら [79] は電波マップを用いて、固定型の BLE ビーコンとスマートフォンを用いて累積確率=0.5 で 1m 程度の精度を示している。この手法では、19 個の高出力・高広告頻度の BLE ビーコンを使っており、対象空間は 50m × 15m のオフィスだった。エリア形状は G 空間 EXPO の形状と似ているが面積が半分で、(送受信は逆となるが) デバイスの個数も半分となり、よって環境中のデバイスの密度はほぼ同じである。大きく差があるのは BLE ビーコンの packets 送信頻度で、50Hz であった。これは packets の受信率に大きな影響を及ぼし、より高精度な推定につながったと考えられる。本研究では面積がより大きい会場で、10Hz の packets 送信頻度の BLE タグを用いて累積確率=0.5 のときに 1.3m の誤差となっており、より厳しい環境でほぼ同じ精度を達成している。

DABIL[85] ではデノイズングオートエンコーダを用いて三次元の BLE 位置推定が提案されており、2D の平均誤差で 1.09m が報告されている。対象の空間は 9.6m × 17.5m の部屋になっており、さらにその内側の空間でデータの取得と位置推定が行われている。DABIL では BLE ビーコンを会議室に設置しており、数が 10 個だったため、密度が G 空間 EXPO2016 の実験より高い。本章の提案手法では DABIL の実験環境の 10 倍近い広さの環境で平均誤差が 1.92m となっており、精度の差は面積差に比して小さい。

Hoang ら [70] は無線 LAN を用いた位置推定で、推定対象の経路に注目している。この手法では、信号強度を入力として複数の RNN を構成し精度を比較している。本章の提案手法と着眼点が類似しており、誤差平均で 0.75m の精度を 16m × 21m の大学の屋内空間で達成したと報告している。環境中の基地局 (無線 LAN を用いるため正確には SSID の数) は 11 台で、デバイスの密度は G 空間 EXPO2016 の実験より少し高い。また、空間中においてデータ計測を行った移動ロボットの取れる位置は、より狭い四角形の通路に限定されていたうえ、データ計測では 10 人程度の人の量だった。非常に良い精度である一方で、対象が取れる位置が狭く、デバイスの密度が高いため、高精度が出やすかったと考えられる。

5.5 本章のまとめ

本章では、イベントの期間がある程度長いときに事前データ収集を行えるという想定で、深層学習を用いた位置推定を提案した。信号強度の時系列を入力し、全結合層と LSTM を用いて直接位置を出力するモデルにより、誤差平均 1.92m で位置推定を行えることを明らかにした。これは、BLE ビーコンとスマートフォンを用いる方式の BLE 位置推定で報告されている精度と並ぶ精度であり、イベント環境における配布型 BLE タグを用いた位置推定でも精度よく推定できることを示している。

また、実環境で起きる各種の問題を考え、学習時のデータ量や利用可能な BLE スキャナを絞り込んだ推定も行った。その結果、学習に使ったデータへの過学習の傾向や、故障したスキャナがある場合の精度低下があり、用いるデータへの依存度の高さが示唆された。前者についてはデータ収集時の経路を注意深く選ぶこと、後者についてはスキャナの故障を発見した段階で前章の手法を使うようにするなど、運用面での支援が必要である。

第 6 章

おわりに

6.1 本論文のまとめ

本研究では、ユビキタスコンピューティングにおける位置情報の重要性に注目し、屋内で開催されるイベントに特に注目して位置推定に取り組んだ。イベント環境においては、来場者の行動の分析が重要である。どこをどう移動したか・どの展示ブースを見たかといった情報はイベントの成功に関して重要な情報である一方で、これまで提案されてきた人流推定手法では不十分で、屋内位置推定による詳細な位置の追跡が必要であった。本研究では、イベント来場者に対して BLE タグを配布し、その広告パケットを会場内の BLE スキャナで収集して行う位置推定を実現するために、データ収集を行うハードウェアと位置推定のアルゴリズムの両面を工夫した。

BLE は消費電力面で優れており、かつ低価格な機器を構成可能で、かつ位置推定のインフラとしての利用も考えられている。信号強度が不安定で、パケットロスも多く発生するイベント環境での利用のためにハードウェア面の改良を行った。具体的には、安価に入手でき導入コストを抑えられる既存デバイスを用いて不安定な電波環境でも利用できるタンデム BLE スキャナを構築した。ベースには小型コンピュータである Raspberry Pi を用い、市販の Bluetooth アダプタを複数取り付けてパケットロスを低減し、安定した信号強度の取得を可能にした。また、実際の大規模展示会イベントである G 空間 EXPO において実験を行い、データを収集した。データ収集では専用のシステムを構築し、のべ 260 名の被験者に BLE タグを配布し、正解となる位置データを含めてデータを集めた。このデータの分析で、実際のイベント環境で収集したデータが位置推定に利用できるような特徴を持つこと、タンデム BLE スキャナがパケットロスを低減できることを確認した。

実際の推定手法となるアルゴリズム面では、2 種類の手法を提案した。ひとつ目は三角測量の考え方を利用する手法で、ふたつ目は深層学習を利用した手法である。信号強度からスキャナと対象

との距離を推定する手法は、環境に合わせて設定するパラメータが少なく、準備で利用できる時間が限られるイベント環境でも利用しやすい。一方で、信号強度に含まれるノイズにより推定が安定しづらい。そこで、パーティクルフィルタを用いて安定した推定を行える手法とした。これを用いて、イベント環境における配布型 BLE タグを用いた位置推定のベースラインとなる精度を示した。深層学習を用いた手法では、事前にある程度のデータが得られる前提を置き、より高精度に位置を推定することを考えた。時系列の特徴を捉えられる LSTM を核に構成したモデルを用い、信号強度の時系列を入力に、推定位置を出力する手法とした。また、人の移動特性を考慮した損失関数や、人工的に生成したデータを用いた学習などを組み合わせて、実データへの依存度を下げる工夫を行った。

推定精度の評価では G 空間 EXPO2016 の実データを用い、信号強度からの距離推定を用いる手法・深層学習の手法でそれぞれ平均で 3.62m および 1.92m の誤差で推定を行えることを確認した。また本研究の深層学習を用いた手法と既存の他手法との比較では、広さと人数を考慮して本研究の手法の精度が他の BLE ビーコン + スマートフォンの手法と同じように高精度に推定できることを議論した。また、一部の BLE スキャナを利用できなくする、深層学習に用いる実データを減らすなどの実験も行い、実環境での利用におけるトラブルを模してその精度を検証した。これらの検証では、深層学習を用いた手法ではこれらのトラブルに対してあまり安定した結果を示さず、学習に用いるデータへの依存が反映された結果となった。一方で信号強度からの距離推定を用いる推定手法では、実環境で起きるトラブルに対しても頑健に動作することが示唆された。以上より、用いる推定方式はどちらか片方だけに絞らず切り替えられるようにしたハイブリッド型の推定システムを用い、時間経過、機材故障などを考慮して適切な手法を選択するという示唆も得られた。

本研究により、イベント環境における位置情報の利用の可能性がひらけた。また、一時的な環境であるイベントで少ない準備でも利用できる位置推定は、イベント以外でも利用できる。人かわりにカートに BLE タグを貼付すれば店舗で容易に来店者の分析を行えるし、博物館や科学館で案内端末と組み合わせて利用するなど、様々な応用も可能である。位置情報の利用は今後人の位置の分析だけでなく、モノの位置の把握でも重要になってくる分野であり、BLE タグを貼付するだけでよい本手法は応用が期待できる。また、センサ情報・管理情報などを発信するような IoT デバイスでも BLE タグとしての機能は組み込みやすく、位置推定を行うことも可能になるため、位置を気にせず IoT デバイスを散布してデータが収集されれば同時に位置情報も付与できるといった、人・モノ・センサの位置を簡単に取得できるようになる発展が期待できる。

6.2 今後の展望

本研究では、データ収集と実際の位置推定はそれぞれ別になっていた。実運用を考えると、それらを統合してリアルタイムな実行を行うデータ収集・位置推定システムが必要になる。リアルタイムな混雑状況がわかれば、それに合わせて混雑していない通路にイベント来場者を誘導することができる。

Bluetooth 規格は BLE が登場した 4.0 以後も拡張されており、2020 年現在は 5.2 が最新となっている。このバージョンでは電波の方向推定 (AoA) に関する機能が追加されたり、より安定して通信を行うための物理層の拡張が行われている。これらの最新仕様を利用できれば、さらに高精度を目指す検討が行えると思われる。

謝辞

本研究を行い、ここにまとめるにあたり、多くの方にお世話になりました。この場を借りて、感謝の意を述べさせていただきます。まず、終始あたたかく丁寧な指導をしてくださった主指導教員の名古屋大学 河口信夫教授に心から感謝の意を表します。私が「あまり良い結果にならなかった」と思った事柄に対しても、注意深く観察いただき、新しい発見のもとになる気づきを得られました。同様に研究に対し日頃より助言や添削をいただきました京都大学 廣井慧准教授、名古屋大学 米澤拓郎准教授、愛知工業大学 梶克彦准教授にもお礼申し上げます。各先生方には、日々の研究における議論や、論文原稿のチェックやプレゼンテーションスライドの修正など、多くの点でよりよい結果のための議論や、的確に読者・聴講者に伝えるための工夫についての指摘をいただき、内容のレベルアップに繋がりました。日頃から研究を進める上でペースが安定せず、締切が近くなると毎期限直前になって焦るということを繰り返した私は、深夜でも修正点を伝えていただく、発表直前でも練習を見ていただくなど、多大なご迷惑をおかけしたこともこの場を借りてお詫び申し上げます。

修士から同期で一緒に研究してきた渡邊康祐さんにも、日頃から情報交換や議論を行い、ときには一緒にゲームを遊ぶなど、研究を進める面でも息抜きして遊ぶ面でも大きな励ましになった感謝をここで述べさせていただきます。修士・博士を通して研究室で関わった先輩、後輩、スタッフの皆様にも、研究室でのプロジェクト、コンペティションへの出場などの面でサポートをしていただき、感謝しています。

また、本研究での実験環境である G 空間 EXPO を運営する皆様、会場を提供いただいた日本科学未来館、実験の出展担当であった NPO 法人 Lisra 様にも御礼申し上げます。実験に関連して、お手伝いをいただきました千葉工業大学の皆様、奈良先端科学技術大学院大学の皆様にも感謝いたします。

最後に、父 光正、母 裕美子、弟 健次には日々の生活を支えていただきました。以上のすべての皆様の助言や支援・叱咤激励に対し、重ねて御礼申し上げます。

参考文献

- [1] A. C. Kay. A Personal Computer for Children of All Ages. In *ACM Annual Conference - Volume 1*, ACM '72, New York, NY, USA, 1972. Association for Computing Machinery.
- [2] 総務省. 情報通信白書 (令和 2 年). 総務省, 2020.
- [3] M. Weiser. The Computer for the 21st Century. *SIGMOBILE Mob. Comput. Commun. Rev.*, Vol. 3, No. 3, p. 3–11, July 1991.
- [4] R. Hall, B. Bowerman, Joseph Braverman, J. Taylor, Helen Todosow, and U. Wimmersperg. The Vision of a Smart City. *2nd Int. Life.*, 01 2000.
- [5] H. Abdelhaq, C. Sengstock, and M. Gertz. EvenTweet: Online Localized Event Detection from Twitter. *Proc. VLDB Endow.*, Vol. 6, No. 12, p. 1326–1329, 2013.
- [6] E. D'Andrea, P. Ducange, B. Lazzerini, and F. Marcelloni. Real-Time Detection of Traffic From Twitter Stream Analysis. *IEEE Transactions on Intelligent Transportation Systems*, Vol. 16, No. 4, pp. 2269–2283, 2015.
- [7] S. Aoki, K. Sezaki, N. J. Yuan, and X. Xie. BusBeat: Early Event Detection with Real-Time Bus GPS Trajectories. *IEEE Transactions on Big Data*, pp. 1–1, 2018.
- [8] トヨタ自動車、通行実績マップを見られる無料ナビアプリの提供を開始. https://qzss.go.jp/news/archive/toyota_161224.html. (2020 年 11 月閲覧).
- [9] モバイル空間統計. <https://mobaku.jp/>. (2020 年 11 月閲覧).
- [10] KDDI Location Data. <https://iot.kddi.com/services/iot-cloud-apimarket/location-data/>. (2020 年 11 月閲覧).
- [11] J. Collin, O. Mezentsev, and G. Lachapelle. Indoor Positioning System Using Accelerometry and High Accuracy Heading Sensors. In *ION GPS/GNSS 2003 Conference*, pp. 9–12, 2003.
- [12] S. Beauregard and H. Haas. Pedestrian Dead Reckoning: A Basis for Personal Positioning. In *3rd Workshop on Positioning, Navigation and Communication*, pp. 27–35, 2006.

- [13] A. J. Davison. Real-Time Simultaneous Localisation and Mapping with a Single Camera. In *9th IEEE International Conference on Computer Vision*, pp. 1403–1410 vol.2, 2003.
- [14] D. Nister, O. Naroditsky, and J. Bergen. Visual Odometry. In *2004 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2004. CVPR 2004.*, Vol. 1, pp. 652–659, 2004.
- [15] M. Hazas and A. Hopper. Broadband Ultrasonic Location Systems for Improved Indoor Positioning. *IEEE Transactions on Mobile Computing*, Vol. 5, No. 5, pp. 536–547, 2006.
- [16] V. Pasku, A. De Angelis, G. De Angelis, D. D. Arumugam, M. Dionigi, P. Carbone, A. Moschitta, and D. S. Ricketts. Magnetic Field-Based Positioning Systems. *IEEE Communications Surveys & Tutorials*, Vol. 19, No. 3, pp. 2003–2017, 2017.
- [17] J. Blankenbach and A. Norrdine. Position Estimation using Artificial Generated Magnetic Fields. In *2010 International Conference on Indoor Positioning and Indoor Navigation*, pp. 1–5, 2010.
- [18] H. Liu, H. Darabi, P. Banerjee, and J. Liu. Survey of Wireless Indoor Positioning Techniques and Systems. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, Vol. 37, No. 6, pp. 1067–1080, 2007.
- [19] Y. Gu, A. Lo, and I. Niemegeers. A Survey of Indoor Positioning Systems for Wireless Personal Networks. *Communications Surveys & Tutorials, IEEE*, Vol. 11, No. 1, pp. 13–32, 2009.
- [20] カメラ画像を活用した人流可視化ソリューション：社会情報システム：日立 . http://www.hitachi.co.jp/products/it/society/product_solution/mobility/human_flow_cctv/. (2020年11月閲覧).
- [21] 導線分析ソリューション | デジタルサイネージ | 株式会社クラウドポイント. <https://www.cloudpoint.co.jp/digitalsignage/conductor-analisy/>. (2020年11月閲覧).
- [22] 哲郎森本, 勝太白浜, 恒雄上善. Wi-Fi パケットセンサを用いた人流・交通流解析の手法. 第14回情報科学技術フォーラム, pp. 505–511, 2015.
- [23] iOS 14、iPadOS 14、watchOS 7 でプライベート Wi-Fi アドレスを使う - Apple サポート. <https://support.apple.com/ja-jp/HT211227>. (2020年12月閲覧).
- [24] プライバシー: MAC アドレスのランダム化 | Android オープンソース プロジェクト. <https://source.android.google.cn/devices/tech/connect/wifi-mac-randomization?hl=ja>. (2020年12月閲覧).
- [25] Getting Started with iBeacon. <https://developer.apple.com/ibeacon/Getting->

- Started-with-iBeacon.pdf. 2018年1月参照.
- [26] M. Veloso, S. Phithakkitnukoon, and C. Bento. Urban mobility study using taxi traces. In *2011 International Workshop on Trajectory Data Mining and Analysis*, TDMA '11, p. 23–30, 2011.
- [27] M. A. Hoque, X. Hong, and B. Dixon. Analysis of Mobility Patterns for Urban Taxi Cabs. In *2012 International Conference on Computing, Networking and Communications (ICNC)*, pp. 756–760, 2012.
- [28] U. Blanke, G. Tröster, T. Franke, and P. Lukowicz. Capturing Crowd Dynamics at Large Scale Events using Participatory GPS-localization. In *2014 IEEE Ninth International Conference on Intelligent Sensors, Sensor Networks and Information Processing (ISSNIP)*, pp. 1–7, 2014.
- [29] N. Maisonneuve, M. Stevens, M. E. Niessen, and L. Steels. NoiseTube: Measuring and Mapping Noise Pollution with Mobile Phones. In *Information Technologies in Environmental Engineering*, pp. 215–228, 2009.
- [30] D. Hasenfratz, O. Saukh, S. Sturzenegger, and L. Thiele. Participatory Air Pollution Monitoring using Smartphones. *Mobile Sensing*, Vol. 1, pp. 1–5, 2012.
- [31] 高橋淳二, 小花祐輔, 磯山直也, 戸辺義人, ロベズギヨーム. YKOB: 参加型センシング志向の自転車とスマートフォン端末を用いた道路路面状態の調査. 電気学会論文誌C (電子・情報・システム部門誌), Vol. 137, No. 4, pp. 658–666, 2017.
- [32] A. Mednis, G. Strazdins, R. Zviedris, G. Kanonirs, and L. Selavo. Real Time Pothole Detection using Android Smartphones with Accelerometers. In *2011 International Conference on Distributed Computing in Sensor Systems and Workshops (DCOSS)*, pp. 1–6, 2011.
- [33] 啓明浅尾, 哲郎森本, 翔洋望月, 純二西田, 直紀安藤. Wi-Fi パケットセンサーによる交通流動解析. 第 53 回土木計画学研究発表会, pp. 2104–2110, 2016.
- [34] Sippakorn Khaimook, 健人葉, 優治八木, 保親青木, 博登猪井, 健司土井. 限定設置条件下での Wi-Fi パケットセンサに基づく来街者の回遊行動の把握. 第 59 回土木計画学研究発表会, pp. 1–9, 2019.
- [35] J. Weppner and P. 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.
- [36] Arkadiusz Stopczynski, Jakob Eg Larsen, Steffen Lehmann, Lukasz Dynowski, and Manuel Fuentes. Participatory Bluetooth Sensing: A Method for Acquiring Spatio-temporal Data About Participant Mobility and Interactions at Large Scale Events. In *2013 IEEE International*

- Conference on Pervasive Computing and Communications Workshops (PERCOM Workshops)*, pp. 242–247, 2013.
- [37] D. Oosterlinck, D. F. Benoit, P. Baecke, and N. Van de Weghe. Bluetooth tracking of humans in an indoor environment: An application to shopping mall visits. *Applied Geography*, Vol. 78, pp. 55 – 65, 2017.
- [38] K. Al Nuaimi and H. Kamel. A Survey of Indoor Positioning Systems and Algorithms. In *2011 International Conference on Innovations in Information Technology*, pp. 185–190, 2011.
- [39] A. Yassin, Y. Nasser, M. Awad, A. Al-Dubai, R. Liu, C. Yuen, R. Raulefs, and E. Aboutanios. Recent Advances in Indoor Localization: A Survey on Theoretical Approaches and Applications. *IEEE Communications Surveys Tutorials*, Vol. 19, No. 2, pp. 1327–1346, 2017.
- [40] F. Zafari, A. Gkelias, and K. K. Leung. A Survey of Indoor Localization Systems and Technologies. *IEEE Communications Surveys & Tutorials*, Vol. 21, No. 3, pp. 2568–2599, 2019.
- [41] C. Tom Judd. A Personal Dead Reckoning Module. In *10th International Technical Meeting of the Satellite Division of The Institute of Navigation (ION GPS 1997)*, pp. 47–51, 1997.
- [42] D. Kamisaka, S. Muramatsu, T. Iwamoto, and H. Yokoyama. Design and Implementation of Pedestrian Dead Reckoning System on a Mobile Phone. *IEICE Transactions on Information and Systems*, Vol. E94.D, No. 6, pp. 1137–1146, 2011.
- [43] C. Chen, X. Lu, A. Markham, and N. Trigoni. IONet: Learning to Cure the Curse of Drift in Inertial Odometry, 2018.
- [44] J. Nozaki, K. Hiroi, K. Kaji, and N. Kawaguchi. Compensation Scheme for PDR Using Sparse Location and Error Model. In *2017 International Workshop on Human Activity Sensing Corpus and Applications*, UbiComp '17, p. 587–596, 2017.
- [45] T. Taketomi, H. Uchiyama, and S. Ikeda. Visual SLAM Algorithms: A Survey from 2010 to 2016. *IPSP Transactions on Computer Vision and Applications*, Vol. 9, No. 1, June 2017.
- [46] G. Klein and D. Murray. Parallel Tracking and Mapping for Small AR Workspaces. In *6th IEEE and ACM International Symposium on Mixed and Augmented Reality (ISMAR'07)*, pp. 1–10, Nara, Japan, November 2007.
- [47] R. A. Newcombe, S. J. Lovegrove, and A. J. Davison. DTAM: Dense Tracking and Mapping in Real-Time. In *2011 International Conference on Computer Vision*, pp. 2320–2327, 2011.
- [48] Ngewi Fet, Marcus Handte, and Pedro J. Marrón. Autonomous Signal Source Displacement Detection and Recalibration of Fingerprinting-based Indoor Localization Systems. In *2017*

-
- International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, pp. 1–8, 2017.
- [49] A. Harter, A. Hopper, P. Steggles, A. Ward, and P. Webster. The Anatomy of a Context-Aware Application. In *5th Annual ACM/IEEE International Conference on Mobile Computing and Networking, MobiCom '99*, pp. 59–68, 1999.
- [50] N. B. Priyantha, A. K.L. Miu, H. Balakrishnan, and S. Teller. The Cricket Compass for Context-Aware Mobile Applications. In *7th Annual International Conference on Mobile Computing and Networking, MobiCom '01*, p. 1–14, 2001.
- [51] Y. Fukuju, M. Minami, H. Morikawa, and T. Aoyama. DOLPHIN: An Autonomous Indoor Positioning System in Ubiquitous Computing Environment. In *IEEE Workshop on Software Technologies for Future Embedded Systems. WSTFES 2003*, pp. 53–56, May 2003.
- [52] ファーストリテイリンググループのジーユーに RFID 読取りセルフレジを納入. https://www.toshibatec.co.jp/release/20170420_01.html. 2020 年 10 月 参照.
- [53] L. M. Ni, Y. Liu, Y. C. Lau, and A. P. Patil. LANDMARC: Indoor Location Sensing Using Active RFID. In *1st IEEE International Conference on Pervasive Computing and Communications, 2003. (PerCom 2003)*, pp. 407–415, 2003.
- [54] D. Joho, C. Plagemann, and W. Burgard. Modeling RFID Signal Strength and Tag Detection for Localization and Mapping. In *2009 IEEE International Conference on Robotics and Automation*, pp. 3160–3165, 2009.
- [55] R. J. Fontana. Recent System Applications of Short-Pulse Ultra-Wideband (UWB) Technology. *IEEE Transactions on Microwave Theory and Techniques*, Vol. 52, No. 9, pp. 2087–2104, 2004.
- [56] S. Gezici and H. V. Poor. Position Estimation via Ultra-Wide-Band Signals. *Proceedings of the IEEE*, Vol. 97, No. 2, pp. 386–403, 2009.
- [57] Ubisense. <http://ubisense.net/en>. 2018 年 1 月 参照.
- [58] Philips Hue スマート ライトの仕組み. <https://www.philips-hue.com/ja-jp/how-it-works>. 2020 年 10 月 参照.
- [59] Q. Yao, F. Wang, H. Gao, K. Wang, and H. Zhao. Location Estimation in ZigBee Network based on Fingerprinting. In *2007 IEEE International Conference on Vehicular Electronics and Safety*, pp. 1–6, 2007.
- [60] M. Uradzinski, H. Guo, X. Liu, and M. Yu. Advanced Indoor Positioning Using Zigbee Wireless Technology. *Wireless Personal Communications*, Vol. 97, No. 4, pp. 6509–6518, August 2017.
- [61] P. Bahl and V. N Padmanabhan. RADAR: An In-building RF-based User Location and Track-

- ing System. In *INFOCOM 2000. 19th Annual Joint Conference of the IEEE Computer and Communications Societies*, pp. 775–784, 2000.
- [62] M. A. Youssef, A. Agrawala, and A. U. Shankar. WLAN Location Determination via Clustering and Probability Distributions. In *1st IEEE International Conference on Pervasive Computing and Communications, 2003.(PerCom 2003).*, pp. 143–150, 2003.
- [63] S. He and S.-H. G. Chan. Wi-Fi Fingerprint-Based Indoor Positioning: Recent Advances and Comparisons. *IEEE Communications Surveys Tutorials*, Vol. 18, No. 1, pp. 466–490, 2016.
- [64] 藤田迪, 梶克彦, 河口信夫. Gaussian Mixture Model を用いた無線 LAN 位置推定手法. *情報処理学会論文誌*, Vol. 52, No. 3, pp. 1069–1081, 2011.
- [65] B. Ferris, D. Fox, and N. Lawrence. WiFi-SLAM Using Gaussian Process Latent Variable Models. In *20th International Joint Conference on Artificial Intelligence, IJCAI’07*, pp. 2480–2485, 2007.
- [66] D. Halperin, W. Hu, A. Sheth, and D. Wetherall. Tool Release: Gathering 802.11n Traces with Channel State Information. *SIGCOMM Computer Communication Review*, Vol. 41, No. 1, pp. 53–53, 2011.
- [67] X. Wang, L. Gao, S. Mao, and S. Pandey. DeepFi: Deep Learning for Indoor Fingerprinting using Channel State Information. In *IEEE Wireless Communications and Networking Conference (WCNC)*, pp. 1666–1671, 2015.
- [68] X. Wang, X. Wang, and S. Mao. CiFi: Deep Convolutional Neural Networks for Indoor Localization with 5 GHz Wi-Fi. In *IEEE International Conference on Communications (ICC)*, pp. 1–6, 2017.
- [69] M. Abbas, M. Elhamshary, H. Rizk, M. Torki, and M. Youssef. WiDeep: WiFi-based Accurate and Robust Indoor Localization System using Deep Learning. In *17th IEEE International Conference on Pervasive Computing and Communications (PerCom 2019)*, pp. 232–241, 2019.
- [70] M. T. Hoang, B. Yuen, X. Dong, T. Lu, R. Westendorp, and K. Reddy. Recurrent Neural Networks For Accurate RSSI Indoor Localization. In *arXiv:1903.11703*, pp. 1–10, 2019.
- [71] K. S. Kim, S. Lee, and K. Huang. A Scalable Deep Neural Network Architecture for Multi-building and Multi-floor Indoor Localization based on Wi-Fi Fingerprinting. *Big Data Analytics*, Vol. 3, No. 1, p. 4, Apr 2018.
- [72] Kyeong Soo Kim. Hybrid Building/Floor Classification and Location Coordinates Regression Using A Single-Input and Multi-Output Deep Neural Network for Large-Scale Indoor Localiza-

- tion Based on Wi-Fi Fingerprinting, 2018.
- [73] X. Li, S. Li, D. Zhang, J. Xiong, Y. Wang, and H. Mei. Dynamic-MUSIC: Accurate Device-Free Indoor Localization. In *2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, UbiComp '16, pp. 196–207, 2016.
- [74] X. Liu, J. Cao, S. Tang, and J. Wen. Wi-Sleep: Contactless Sleep Monitoring via WiFi Signals. In *2014 IEEE Real-Time Systems Symposium*, pp. 346–355, 2014.
- [75] R. Bruno, F. Delmastro, S. Giordano, E. Gregori, and S. Olariu. Design and Analysis of a Bluetooth-Based Indoor Localization System. In *Personal Wireless Communications*, pp. 711–725, Berlin, Heidelberg, 2003. Springer Berlin Heidelberg.
- [76] F. J. Gonzalez-Castano and J. Garcia-Reinoso. Bluetooth Location Networks. In *Global Telecommunications Conference, 2002. GLOBECOM '02. IEEE*, Vol. 1, pp. 233–237 vol.1, 2002.
- [77] D. Čabarkapa, I. Grujić, and P. Pavlović. Comparative analysis of the Bluetooth Low-Energy indoor positioning systems. In *2015 12th International Conference on Telecommunication in Modern Satellite, Cable and Broadcasting Services (TELSIKS)*, pp. 76–79, 2015.
- [78] K. E. Jeon, J. She, P. Soonsawad, and P. C. Ng. BLE Beacons for Internet of Things Applications: Survey, Challenges, and Opportunities. *IEEE Internet of Things Journal*, Vol. 5, No. 2, pp. 811–828, 2018.
- [79] R. Faragher and R. Harle. Location Fingerprinting with Bluetooth Low Energy Beacons. *IEEE journal on Selected Areas in Communications*, Vol. 33, No. 11, pp. 2418–2428, 2015.
- [80] Y. Wang, X. Yang, Y. Zhao, Y. Liu, and L. Cuthbert. Bluetooth Positioning Using RSSI and Triangulation Methods. In *IEEE 10th Consumer Communications and Networking Conference (CCNC)*, pp. 837–842, 2013.
- [81] F. Campaña, A. Pinargote, F. Domínguez, and E. Peláez. Towards an Indoor Navigation System using Bluetooth Low Energy Beacons. In *2017 IEEE Second Ecuador Technical Chapters Meeting (ETCM)*, pp. 1–6, 2017.
- [82] F. Zafari, I. Papapanagiotou, M. Devetsikiotis, and T. Hacker. An iBeacon based Proximity and Indoor Localization System, 2017.
- [83] P. Dickinson, G. Cielniak, O. Szymanczyk, and M. Mannion. Indoor Positioning of Shoppers using a Network of Bluetooth Low Energy Beacons. In *2016 International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, pp. 1–8, 2016.
- [84] R. Ayyalasomayajula, D. Vasisht, and D. Bharadia. BLoc: CSI-based Accurate Localization

- for BLE Tags. In *14th International Conference on Emerging Networking EXperiments and Technologies (CoNEXT '18)*, pp. 126–138, 2018.
- [85] C. Xiao, D. Yang, Z. Chen, and G. Tan. 3-D BLE Indoor Localization Based on Denoising Autoencoder. *IEEE Access*, Vol. 5, pp. 12751–12760, 2017.
- [86] J. Powar, C. Gao, and R. Harle. Assessing the Impact of Multi-Channel BLE Beacons on Fingerprint-based Positioning. In *2017 International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, pp. 1–8, 2017.
- [87] X. Wu, R. Shen, L. Fu, X. Tian, P. Liu, and X. Wang. iBILL: Using iBeacon and Inertial Sensors for Accurate Indoor Localization in Large Open Areas. *IEEE Access*, Vol. 5, pp. 14589–14599, 2017.
- [88] K. Komai, M. Fujimoto, Y. Arakawa, H. Suwa, Y. Kashimoto, and K. Yasumoto. Beacon-Based Multi-Person Activity Monitoring System for Day Care Center. In *2016 IEEE International Conference on Pervasive Computing and Communication Workshops (PerCom Workshops)*, pp. 1–6, 2016.
- [89] JAL × NRI、空港旅客業務の先進化に向け、iBeacon およびスマートウォッチを活用した実証実験を開始. <http://press.jal.co.jp/ja/release/201407/002085.html>. 2020年10月参照.
- [90] 三鷹市のイベントにて Beacon を使用したスタンプラリーを実施 | 株式会社スイッチスマイルのプレスリリース. <https://prtnews.jp/main/html/rd/p/000000020.000023122.html>. 2020年10月参照.
- [91] A. Ito, H. Hatano, M. Fujii, M. Sato, Y. Watanabe, Y. Hiramatsu, F. Sato, and A. Sasaki. A Trial of Navigation System using BLE Beacon for Sightseeing in Traditional Area of Nikko. In *2015 IEEE International Conference on Vehicular Electronics and Safety (ICVES)*, pp. 170–175, 2015.
- [92] 国内空港初！成田空港高精度屋内ナビゲーションアプリ NariNAVI（ナリナビ）をリリース！ <https://prtnews.jp/main/html/rd/p/000000280.000004762.html>. 2020年10月参照.
- [93] P. C. Ng, J. She, and S. Park. Notify-and-Interact: A Beacon-Smartphone Interaction for User Engagement in Galleries. In *2017 IEEE International Conference on Multimedia and Expo (ICME)*, pp. 1069–1074, 2017.
- [94] RTLS powered by Quuppa. <https://quuppa.com/>. (2020年10月閲覧).

-
- [95] Bluetooth Technology Website: Core Specifications. <https://www.bluetooth.com/specifications/bluetooth-core-specification>. 2020 年 10 月 参照.
- [96] Raspberry Pi. <https://www.raspberrypi.org/>. 2018 年 1 月 参照.
- [97] BlueZ. <http://www.bluez.org>. 2018 年 1 月 参照.
- [98] fluentd. <http://www.fluentd.org/>. 2018 年 1 月 参照.
- [99] 施設貸出のご案内 | 日本科学未来館 (Miraikan). <https://www.miraikan.jst.go.jp/visit/facility-rental/>. (2020 年 12 月閲覧).
- [100] G 空間 EXPO | Facebook. https://www.facebook.com/GEXPO2014/photos/?ref=page_internal. (2020 年 12 月閲覧).
- [101] G 空間 EXPO2016 開催報告書. <https://g-expo.jp/2016/common/pdf/report.pdf>. (2020 年 11 月閲覧).
- [102] LBT-UAN05C2. <http://www2.elecom.co.jp/products/LBT-UAN05C2.html>. 2018 年 1 月 参照.
- [103] USB-BT40LE. <http://www.iodata.jp/product/interface/bluetooth/usb-bt40le/index.htm>. 2018 年 1 月 参照.
- [104] BT-Micro4. <https://www.planex.co.jp/products/bt-micro4/>. 2018 年 1 月 参照.
- [105] MM-BTUD44. <https://www.sanwa.co.jp/product/syohin.asp?code=MM-BTUD44>. 2018 年 1 月 参照.
- [106] Sebastian Thrun, Wolfram Burgard, and Dieter Fox. *Probabilistic Robotics (Intelligent Robotics and Autonomous Agents)*. The MIT Press, 2005.
- [107] K. He, X. Zhang, S. Ren, and J. Sun. Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification. *2015 IEEE International Conference on Computer Vision (ICCV)*, pp. 1026–1034, 2015.

研究業績

本論文に関する業績

学術論文

浦野健太, 廣井慧, 梶克彦, 河口信夫

配布型 BLE タグとタンデムスキャナを用いた屋内位置推定手法
情報処理学会論文誌, Vol.60 No.1, pp.58–75, 2019

Kenta Urano, Kei Hiroi, Takuro Yonezawa, Nobuo Kawaguchi

An End-to-End BLE Indoor Localization Method Using LSTM

Journal of Information Processing, Vol.29, 12 pages, 2021

(in press; will be published in Jan 2021)

国際会議論文 (査読あり)

Kenta Urano, Katsuhiko Kaji, Kei Hiroi, Nobuo Kawaguchi

A Location Estimation Method using BLE Tags Distributed Among Participants of a Large-Scale Exhibition

International Conference on Mobile and Ubiquitous Systems: Computing Networking and Services (MobiQuitous), pp.124–129, 2016

Kenta Urano, Katsuhiko Kaji, Kei Hiroi, Nobuo Kawaguchi

A Location Estimation Method using Mobile BLE Tags with Tandem Scanners

ACM International Joint Conference on Pervasive and Ubiquitous Computing Workshops (UbiComp),

pp.577–586, 2017

Kenta Urano, Kei Hiroi, Takuro Yonezawa, Nobuo Kawaguchi

Poster: Basic Study of BLE Indoor Localization using LSTM-based Neural Network

ACM International Conference on Mobile Systems, Applications, and Services (MobiSys), pp.558–559, 2019

Kenta Urano, Kei Hiroi, Takuro Yonezawa, Nobuo Kawaguchi

An End-to-End BLE Indoor Location Estimation Method using LSTM

International Conference on Mobile Computing and Ubiquitous Networking (ICMU), pp.1–7, 2019
(Best Paper Award)

研究会における発表 (査読なし)

浦野健太, 廣井慧, 梶克彦, 河口信夫

大規模展示会における来場者分析のための配布型 BLE タグを用いた位置推定手法
マルチメディア、分散協調とモバイルシンポジウム (DICOMO), pp.1236–1243, 2016

浦野健太, 廣井慧, 河口信夫

配布型 BLE タグを用いた IoT 位置トラッキングシステムの構築 -タンデム BLE スキャナを用いた
人流計測に関する基礎的検討-
HCG シンポジウム, pp.56–60, 2016

浦野健太, 廣井慧, 河口信夫

IoT 位置トラッキングシステムの構築を目的とした実環境におけるタンデム BLE スキャナの受信
性能評価
情報処理学会第 79 回全国大会, pp.3-317–3-318, 2017

浦野健太, 廣井慧, 梶克彦, 河口信夫

タンデムスキャナを用いた配布型 BLE タグ位置推定手法
マルチメディア、分散協調とモバイルシンポジウム (DICOMO), pp.1598–1606, 2017

浦野健太, 廣井慧, 米澤拓郎, 河口信夫

LSTM を用いた大規模イベント向け BLE 屋内位置推定手法の検討

第 91 回 MBL 研究会, pp.1-7, 2019 (優秀発表)

浦野健太, 廣井慧, 米澤拓郎, 河口信夫

ニューラルネットワークを用いた大規模イベント向け BLE 屋内位置推定の比較評価

マルチメディア、分散協調とモバイルシンポジウム (DICOMO), pp.29-35, 2019

その他業績 (共著含む)

学術論文

松山 仁, 浦野 健太, 廣井 慧, 梶 克彦, 米澤 拓郎, 河口 信夫

社交ダンスの動作特性を考慮した マルチモーダルセンサによるダンスフィガー認識

情報処理学会論文誌, Vol.61 No.10, pp.1591-1604, 2020

国際会議論文 (査読あり)

Katsuhiko Kaji, Kohei Kanagu, Kazuya Murao, Nobuhiko Nishio, Kenta Urano, Hirokazu Iida, Nobuo Kawaguchi

Multi-Algorithm On-Site Evaluation System for PDR Challenge

International Conference on Mobile Computing and Ubiquitous Networking (ICMU), pp.110-115, 2016

Kenta Urano, Kei Hiroi, Shinpei Kato, Nozomi Komagata, Nobuo Kawaguchi

Road Surface Condition Inspection Using a Laser Scanner Mounted on an Autonomous Driving Car

International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops), pp.826-831, 2019

Takuto Yoshida, Junto Nozaki, Kenta Urano, Kei Hiroi, Takuro Yonezawa, Nobuo Kawaguchi

Poster: Gait Dependency of Smartphone Walking Speed Estimation using Deep Learning

ACM International Conference on Mobile Systems, Applications, and Services (MobiSys), pp.641–642, 2019

Takuto Yoshida, Junto Nozaki, Kenta Urano, Kei Hiroi, Katsuhiko Kaji, Takuro Yonezawa, Nobuo Kawaguchi

Sampling Rate Dependency in Pedestrian Walking Speed Estimation using DualCNN-LSTM

ACM International Joint Conference on Pervasive and Ubiquitous Computing Workshops (UbiComp), pp.862–868, 2019

研究会における発表 (査読なし)

浦野健太, 廣井慧, 加藤真平, 駒形望, 河口信夫

自動運転車のレーザセンサを利用した路面性状調査

マルチメディア、分散協調とモバイルシンポジウム (DICOMO), pp.264–269, 2018 (優秀プレゼンテーション賞)

浦野健太, 松山仁, 湯木悠太, 野崎惇登, 廣井慧, 梶克彦, 河口信夫

ランダムフォレストとルールベース処理を用いた大規模スマートフォンデータに対する行動認識

HCG シンポジウム, pp.1–6, 2018

浦野 健太, 廣井 慧, 米澤 拓郎, 河口 信夫

ドキドキをセンシングして可視化する LED ライティングデバイスの検討

研究報告モバイルコンピューティングとパーベイシブシステム研究会 (MBL), 2019 (ポスターセッション)

浦野 健太, 廣井 慧, 米澤 拓郎, 河口 信夫

ドキドキをセンシングして可視化する LED ライティングデバイス

マルチメディア、分散協調とモバイルシンポジウム (DICOMO), pp.1616–1622, 2020 (野口賞・優勝)

その他

Kotaro Hananouchi, Junto Nozaki, Kenta Urano, Kei Hiroi, Nobuo Kawaguchi

Trajectory Estimation Using PDR and Simulation of Human-Like Movement

Indoor Positioning and Indoor Navigation (IPIN), Competition track.4, 2017 (2nd place)

Hitoshi Matsuyama, Kenta Urano, Kei Hiroi, Katsuhiko Kaji, Nobuo Kawaguchi

Short Segment Random Forest with Post Processing using Label Constraint for SHL Recognition Challenge

Sussex-Huawei Locomotion Challenge, 2018

Takuto Yoshida, Kenta Urano

Walking Speed Estimation using Deep Learning based PDR

Indoor Positioning and Indoor Navigation (IPIN), Competition track.5, 2019 (Restaurant 1st place, Manufacturing 2nd place)

付録 A

Bluetooth Low Energy による通信の概要

Bluetooth Low Energy (BLE) についてまとめる。BLE は Bluetooth 規格の一部で、バージョン 4.0 で追加された、低速なかわりに低消費電力で動作する仕様となっている。

A.1 Bluetooth 規格の概要・歴史

Bluetooth は近距離にあるデバイス同士で上昇をやり取りするために使用される規格である。免許不要の 2.4GHz 帯の 2400MHz から 2483.5MHz を利用して通信を行うもので、PC とマウスやキーボードなどの接続や、スマートフォンとスマートウォッチ間の接続、ゲーム機とコントローラの接続などに利用されている。同じく 2.4GHz 帯を使う無線 LAN はインターネットへの接続や高速データ通信に利用されており、低データレートの通信を行う Bluetooth とは棲み分けがなされている。仕様は Bluetooth SIG (Special Interest Group) によって管理されており、バージョン 5.2 が発表されている。1994 年にエリクソン社が開発を始めた無線通信規格が源流となっており、1998 年に Bluetooth SIG が発足、1999 年にバージョン 1.0 がアナウンスされた。

仕様はバージョン更新のたびに拡張されており、幅広い用途に対応するようになっている。当初は 1Mbps だったデータレートは、バージョン 2.0 の EDR (Enhanced Data Rate) で 3Mbps まで高速化され、バージョン 3.0 では最大 24Mbps まで拡張された。BLE はバージョン 4.0 で追加された仕様だが、バージョン 3.0 までとは直接の互換性を有さないため、バージョン 4.0 以前のはクラシックとして区別されている。

Bluetooth では、様々な機器を簡単に接続できるようにプロファイルが決められている。たとえば GAP (Generic Access Profile) というプロファイルをベースに、音楽再生向けの A2DP (Advanced Audio Distribution Profile) や、通話関連の機能を担う HFP (Hands-Free Profile) などが利用されて

表 A.1: クラシック Bluetooth の登場時期とデータレート

バージョン	策定期間	データレート
1.0	1999 年	1Mbps (BR; GFSK)
2.0	2004 年	2Mbps (EDR; $\pi/4$ DQPSK) 3Mbps (EDR; 8DPSK)
3.0	2009 年	24Mbps (無線 LAN の下位層を使用)

いる。また、BLE では GATT (Generic Attribute Profile) でどのようなデータをやりとりするかを定義している。

A.1.1 クラシック Bluetooth

クラシック Bluetooth は、Bluetooth 規格のうちバージョン 4.0 より古いものを総称する呼称となっている。79 のチャンネルが定義されており、チャンネルホッピングを行いながら通信を行う (FHSS; Frequency Hopping Spread Spectrum)。接続方式はスター型となっており、ある親デバイス (マスタ) は 7 台の子デバイス (スレーブ) と接続可能である。接続前にはペアリングが必要で、一度ペアリングすると以降は自動的に接続が可能である。

バージョンごとにデータレートとが異なっており、もっとも遅いデータレートは GFSK (Gaussian Frequency Shift Keying) を用いる、1Mbps の BR (Basic Rate) となっている。バージョン 2.0 では EDR (Enhanced Data Rate) と呼ばれる高速なモードがオプション仕様として定義され、 $\pi/4$ DQPSK (Differential Quadruple Phase Shift Keying) を用いた 2Mbps の通信および 8DPSK (Differential Phase Shift Keying) による 3Mbps の通信が利用できるようになった。さらに、バージョン 3 では無線 LAN のデータリンク層と物理層を利用した 24Mbps の通信モード (HS; High Speed) が追加された。各バージョンの登場時期・データレートをまとめて、表 A.1 に示す。

また、デバイスが利用可能な電力や、要求する通信範囲に応じてクラスが定義されている。クラスごとに許される最大送信電力と、想定される最大通信距離を表 A.2 に示す。

A.1.2 Bluetooth Low Energy

データリンク層の仕様

データリンク層の動作はステートマシンの形を取り、Bluetooth バージョン 4.0 では 5 つの状態が定義されている。バージョン 5.2 時点では 2 つの状態が追加され、7 つの状態を取れる。状

表 A.2: クラシック Bluetooth のパワークラス

クラス	送信電力 (上限値)	想定最大距離
1	100mW (+20dBm)	100m
2	2.5mW (+4dBm)	10m
3	1mW (+0dBm)	1m

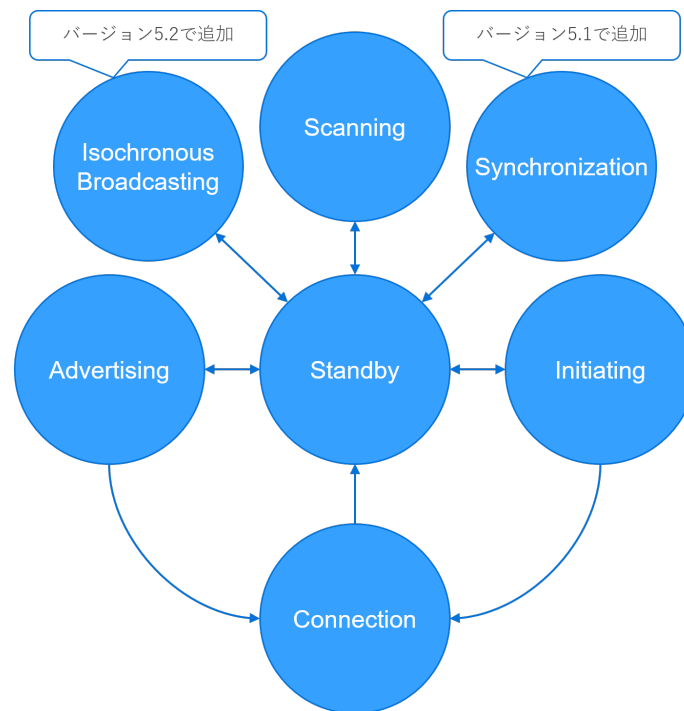


図 A.1: BLE のデータリンク層状態マシン

状態の遷移を図 A.1 に示す。状態マシンは同時に 1 つの状態のみを取れる (ただし、ひとつのデータリンク層が複数の状態マシンを持つことも可能)。データリンク層は必ず Advertising か Scanning の状態をサポートする必要がある。本研究で利用する BLE デバイスはビーコンとスキャナであるため、このうち Advertising と Scanning の状態が利用される。

Standby 状態は他のどの状態からでも入れる状態であり、この状態ではパケットの送受信は行われない。Advertising 状態にあるデバイスは、アドバタイジングチャンネルにパケットを送信する。また、この状態ではアドバタイジングパケットの監視や応答も行う可能性がある。この状態になっているデバイスはアドバタイザーであり、接続待ちのデバイスや、ブロードキャストのみ行う BLE ビーコンが該当する。Scanning 状態のデバイスはアドバタイジングチャンネルを監視し、アドバタ




図 A.2: LE 1M/LE 2M のパケットフォーマット

イジングパケットを探す。この状態のデバイスはスキャナと呼ばれ、周囲のデバイスを検索しているスマートフォンや、ブロードキャストパケットを収集するゲートウェイが該当する。Initiating 状態では、別のデバイスとの接続を開始するためにアドバタイジングチャンネルを監視し、アドバタイジングパケットに応答する。Connection 状態は Advertising もしくは Initiating から入れる状態で、他のデバイスとの接続が確立した状態となる。この状態にあるデバイスには先述のマスター・スレーブの役割が定義される。Initiating 状態から遷移したデバイスはマスターに、Advertising 状態からの遷移ではスレーブになる。Synchronization 状態はバージョン 5.1 で追加された状態で、特定のデバイスが発する周期的なパケットからなる一連のアドバタイジングを受信する。Isochronous Broadcasting 状態はバージョン 5.2 で追加された状態で、等時転送を行う場合に使う。

データレート

LE 1M(および LE 2M) の物理層で使われるパケットフォーマットは次の図 A.2 のとおりである (LE Coded では別のフォーマットとなるが、ここでは省略する)。このうち、必須フィールドは Preamble から CRC までとなっている。プリアンブルは LE 1M モードで 1 オクテット、LE 2M モードで 2 オクテットが割り当てられる (0 と 1 が交互に並ぶもので、アクセスアドレスの頭のビットと逆のビットで終わるように設定される)。アクセスアドレスは続く PDU (Protocol Data Unit) に合わせて指定がある場合と、ルールに従って決定される場合がある。本研究で用いるアドバタイジングチャンネルに送信を行う場合は固定の値で、0x8E89BED6 が設定される。PDU が実際のペイロードとなっており、送られるチャンネルの性質 (アドバタイジング、データなど) によってルールが決まる。PDU の最大長はバージョン 4.0 で 39 オクテットとなっていたが、4.2 で 257 オクテットまでに拡張され、5.1 からは 258 オクテットになった。また、PDU の型に応じて利用できるオクテット長に追加の制限が生じることがある。CRC は 24 ビットの長さとなっており、エラー訂正に利用される。

以上より、最短のパケットは LE 1M モードの 10 オクテットで、最長は LE 2M モードの 267 オクテットとなる。LE 1M モードではビットレートが 1Mbps のため、1つのパケットがチャンネルを

表 A.3: BLE のデータレート

物理層	変調	符号化による冗長化 (ヘッダ/ペイロード)	データレート
LE 1M	1Msym/s GFSK	なし	1Mbps
LE 2M	2Msym/s GFSK	なし	2Mbps
LE Coded	1Msym/s GFSK	S=8 / S=2	125kbps
		S=8 / S=8	500kbps

表 A.4: BLE のパワークラス (バージョン 5.2 時点)

クラス	最大送信電力	最小送信電力
1	100mW (+20dBm)	10mW (+10dBm)
1.5	10mW (+10dBm)	0.01mW (-20dBm)
2	2.5mW (+4dBm)	0.01mW (-20dBm)
3	1mW (+0dBm)	0.01mW (-20dBm)

専有する時間は 80 マイクロ秒から 2128 マイクロ秒で、LE 2M モードでは 2Mbps のため 44 マイクロ秒から 1068 マイクロ秒となる。また、バージョン 4.0 時点の PDU 上限である 39 オクテットを使うと、転送にかかる時間は 376 マイクロ秒となる。

データレートはバージョン 4.0 では 1Mbps (LE 1M モード) となっていたが、バージョン 5.0 以降で仕様が拡張され、高速な 2Mbps の動作モード (LE 2M モード) と、低速なかわりに冗長性を上げる 500kbps および 125kbps のモード (LE Coded) がオプションとして追加された。無線の仕様を単純化するため、変調方式はいずれも GFSK のみとなっている。LE 2M モードはシンボルレートの変更で実現されている。LE 1M および LE 2M モードでは、シンボルレートとデータレートが一致するため、1 ビットの転送にはそれぞれ 1 マイクロ秒および 0.5 マイクロ秒となる。また、LE Coded モードでは前方誤り訂正とビットパターンマッピングを用いて、冗長性を確保している。これらの仕様を表 A.3 にまとめる。

パワークラス

送信電力に関する仕様はバージョン 4 以降で拡張が施され、バージョン 5.2 時点では 4 つのパワークラスが定義されている。バージョン 5.2 時点のパワークラスについて、表 A.4 にまとめる。バージョン 4.0 における基準値は、表 A.4 におけるクラス 1.5 に相当する。

表 A.5: PDU Type の一覧

PDU Type	PDU 名称	対象チャネル	物理層		
			LE 1M	LE 2M	LE Coded
0b0000	ADV_IND	Primary	●		
0b0001	ADV_DIRECT_IND	Primary	●		
0b0010	ADV_NONCONN_IND	Primary	●		
0b0011	SCAN_REQ	Primary	●		
	AUX_SCAN_REQ	Secondary	●	●	●
0b0100	SCAN_RSP	Primary	●		
0b0101	CONNECT_IND	Primary	●		
	AUX_CONNECT_IND	Secondary	●	●	●
0b0110	ADV_SCAN_IND	Primary	●		
0b0111	ADV_EXT_IND	Primary	●		●
	AUX_ADV_IND	Secondary	●	●	●
	AUX_SCAN_RSP	Secondary	●	●	●
	AUX_SYNC_IND	Periodic	●	●	●
	ADV_CHAIN_IND	Secondary and Periodic	●	●	●
0b1000	ADV_CONNECT_RSP	Secondary	●	●	●
other	今後のために予約				

アドバタイジング仕様

Bluetooth 5.2 時点で利用できる PDU Type が転送モードごとに異なる。物理アドバタイジングチャネルで使われる PDU Type の一覧は表 A.5 のとおりである。

物理アドバタイジングチャネルを流れる PDU のうち、アドバタイジング PDU と呼ばれるのは次のとおりとなる。

- ADV_IND
- ADV_DIRECT_IND
- ADV_NONCONN_IND
- ADV_SCAN_IND
- ADV_EXT_IND

- AUX_ADV_IND
- AUX_SYNC_IND
- AUX_SYNC_IND

これらの PDU は Advertising 状態のデバイスから送信され、Scanning もしくは Initiating 状態のデバイスで受信される。ADV_IND から ADV_SCAN_IND までの PDU は Bluetooth バージョン 4.0 からあるもので、legacy advertising PDU として扱われ、legacy advertising event となる。残りのものはバージョン 5.0 から追加されたもので、extended advertising PDU となる。