

Multi-scale behavior modeling for pedestrian-centric spatial
planning

歩行者空間計画のためのマルチスケールな行動モデリング

by

Ken Hidaka

日高 健

A Doctor Thesis

博士論文

Submitted to

the Graduate School of Engineering, Nagoya University

on May 18, 2021

Thesis Supervisor: Toshiyuki Yamamoto 山本 俊行

Professor of Engineering

論文要旨

近年、自動車を中心とした街づくりから、人を中心とした街づくりへ空間を再構築しようとする取組みが進んでいる。質の高い都市空間は、経済的、社会的、健康的、環境的に利用者に高い価値をもたらすことが明らかになっており、人を中心とした街づくりは豊かな生活空間の実現、地域消費の拡大、観光客の増加や健康寿命の延伸など様々な地域課題の解決や新たな価値の創造につながると期待される。しかしながら、どのように街路空間の再構築・利活用を行えば良いのかという具体的な手順は明らかではなく、多くの自治体は模索をしているのが現状である。

一方、スマートフォンや個人単位のセンシングデータの普及を背景として、データ駆動型の空間計画が注目されている。国土交通省が推進する「スマート・プランニング」は、個人単位の行動データをもとに、施策実施の効果を予測した上で様々な施策を検討するデータ駆動型の新しい計画手法である。データに基づく空間設計は、ステークホルダー間のデータに裏付けされた客観的な共通認識の構築に役立ち、結果として、エビデンスに基づいた施策の決定 (Evidence-Based Policy Making; EBPM) につながると期待される。

しかしながら、現状のデータ駆動型の空間計画手法には以下に示す大きな課題がある。

1. 個人単位の詳細な移動軌跡データを十分に活かしていない
2. 歩行者の複雑な意思決定、回遊行動の特徴を十分に表現できていない
3. 広域からの来訪者数の推定は、四段階推計を前提としている

本研究では、これらの大きな課題に取り組み、解決を図ることで今後のデータ駆動型の空間計画のさらなる発展の一助となることを目的とするものである。

本論文は、以下の6つの章で構成されている。第1章は、序論であり、研究を行うに至る背景および、研究の目的、本論文の構成について説明を行った。

第2章では、既往研究レビューについて整理した。はじめに、歩行者行動モデルに関する既往研究について整理した。具体的には、経路選択モデルについて非目的地指向型の歩行者経路選択モデルについて紹介した後に、経路の列挙を必要としないリンクベース（再帰型や逐次型とも呼ばれる）の経路選択アプローチについて紹介した。また、歩行者を対象とした活動スケジューリングモデルについてもレビューを行った。さらには、GPSデータを用いた歩行者行動の空間表現についても紹介した。続いて、広域の移動行動生成モデルに関する既往研究についてもレビューを行った。

第3章では、上述の課題2で挙げた歩行者の複雑な意思決定のうちの、回遊行動に特徴的な行動軌跡の生成を可能とする2段階のアプローチを提案した。第一段階では、最大エントロピー逆強化学習法によって Point of Interest (POI) の効用関数と確率の方策を推定し、第二段階では、与えられた目的地と到着時間の制約の下で軌跡を生成する。この方法を用いることで、最短経路に代表される目的地指向型の行動軌跡のみならず、迂回や滞在、立ち寄りのような様々な行動軌跡の表現が可能となった。また、2種類の数値実験を通じて様々な行動軌跡の生成が可能であることを確認した。

第4章では、上述の課題2で挙げた歩行者の複雑な意思決定のうちの、活動選択や活動時間配分行動に着目し、これらを逐次的に行うことが可能な動的活動スケジューリングモデルを歩行者問題に適用した。本研究で扱う問題では、移動時間が活動時間に含まれるため、移動時間以上の時間を配分する必要がある。この問題を扱うことができるよう動的活

動スケジューリングモデルの拡張を行った。また、課題1で挙げた詳細な移動軌跡データの活用方法として、グリッドベースの空間表現方法を提案し、GPSデータから15mという詳細な空間解像度を持つデータへの前処理方法についても提案した。ここでは、道の駅で取得されたGPSデータをもとに、上記の方法で時空間離散化を行い、活動スケジューリングモデルの推定を行った。推定の結果、代表者の年齢や子どもの数といった来訪者グループの属性が活動選択や活動時間配分に与える影響が明らかになった。具体的には、子どもの数はゴーカートやアスレチック広場のような活動的なアクティビティの選択確率を高める一方で、レストランなどの選択確率を低くした。また、代表者の年齢が高いほど、レストランなどでの滞在時間が長くなる傾向にあった。さらに、モデルの推定の結果、早い時間帯ほど1つの活動の配分時間が短くなることが明らかになった。これは、もともと計画しているが未実行の活動が多いことによる時間的圧力が発生していることを示唆していると考えられる。

第5章では、課題3で挙げた広域からの来訪者の推定に関して、パーソントリップ調査のような大規模な交通調査の存在を前提としない新しい推定方法の提案を行った。提案方法では、国勢調査や生活時間調査などの一般に入手が容易で、プライバシー保護等の懸念もない集計データを融合し、統計的に矛盾のない移動行動パターンの生成を行う。提案方法は、携帯電話の基地局情報から得られる時間帯別の滞在人口と比較を行い、その精度を検証した。検証した結果は、どの時間帯に対しても国勢調査と検証データ間の当てはまりと同等以上の精度を示しており、提案手法が有用であることを示すことができた。提案方法は、金銭的、時間的なコストの大きい交通調査を一切必要としないため、財政面で苦心する小規模な自治体を含む日本全国全ての地域で安価かつ簡便に移動行動を生成することができる。この移動行動生成の情報に基づき、対象エリアの属性や時間帯の情報を含んだ来訪者数の推計が可能と考えられる。

第6章は、上記の成果の総括を行うとともに、今後の課題を示した。本論文では、歩行空間計画のためのマルチスケールな行動を扱うことができる枠組みを提案したが、全てを組み合わせた推計までは示すことが出来なかった。マルチスケールなモデルを全体で実施するツールとして整備していくことが、今後のデータ駆動型の空間計画の活用の拡がりに向けた最も重要な一歩となると考える。

Acknowledgements

はじめに、本研究を進め、本論文を完成させるにあたり、大変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。

名古屋大学未来材料・システム研究所の山本俊行教授には、本研究を進めるにあたり大変多くのご指導を賜りました。心より御礼申し上げます。

また、名古屋大学の三輪富生准教授、井料美帆准教授、広島大学の力石真准教授には、多くの貴重なご助言をご指導を賜りました。深く御礼申し上げます。

本研究を進めるにあたり、データの提供や研究のご助言を賜りました人間環境大学の薄井智貴教授に、深く感謝の意を表します。

名古屋大学の森川高行教授をはじめ、金森亮特任准教授、中村俊之特任准教授には本研究に対して有益なご助言を頂きました。深く感謝申し上げます。同じく名古屋大学の佐藤仁美特任准教授、田代むつみ特任講師にはゼミ等に関してご助言のみならず、様々なサポートを賜りました。深く御礼申し上げます。森川・山本・三輪研究室の研究スタッフ、学生の皆様にも、多くのご協力やご支援を頂きました。ここに感謝の意を表します。

名古屋大学の中村晋一郎准教授には、博士課程の学生生活のサポートを頂きました。深く感謝申し上げます。

職務につきながら、博士課程への通学を承認頂き、また研究の議論に加わって頂いた（株）豊田中央研究所の上司や同僚、その他関係者の皆様に厚く御礼申し上げます。

最後に、社会人博士課程への進学を受け入れ、常に温かく支えてくれた妻と子ども達に、心より感謝します。

Contents

1	序論	1
1.1	研究の背景	1
1.2	研究の目的	2
1.3	研究の構成	3
2	既往研究	5
2.1	はじめに	5
2.2	歩行者行動に関する既往研究	5
2.2.1	非目的地指向型の歩行者経路選択モデル	5
2.2.2	リンクベースの経路選択モデル	6
2.2.3	歩行者を対象とした活動スケジューリングモデル	6
2.2.4	GPS データを用いた歩行者の空間表現	6
2.3	広域の移動行動生成モデルに関する既往研究	7
3	歩行者の回遊行動モデリング	9
3.1	はじめに	9
3.2	準備	10
3.2.1	MDP による確率の方策の計算	10
3.2.2	最大エントロピー逆強化学習	11
3.3	時空間制約下の移動軌跡生成	12
3.4	数値実験	15
3.4.1	簡易的な環境での実験	15
3.4.1.1	実験設定	15
3.4.1.2	推定結果の検証	16
3.4.1.3	時空間制約下の生成軌跡の比較	16
3.4.2	現実を模擬した環境での実験	22
3.4.2.1	実験設定	22
3.4.2.2	推定結果の検証	23
3.4.2.3	時空間制約下の生成軌跡の比較	23
3.5	まとめ	26
4	歩行者の活動スケジューリングモデル	28
4.1	はじめに	28
4.2	データと方法	29
4.2.1	データ取得	29
4.2.2	データ処理方法	30
4.2.2.1	デノイジングとスムージング	30
4.2.2.2	離散化グリッドへの割り当て	31
4.2.2.3	エピソードの抽出	36
4.2.3	基礎分析	38
4.2.3.1	歩行速度	38
4.2.3.2	POI 訪問確率	40

4.2.4	活動スケジュールリングモデル	44
4.3	結果と考察	45
4.3.1	活動選択モデル	45
4.3.2	活動時間配分モデル	48
4.4	まとめ	50
5	広域の移動行動生成モデル	52
5.1	はじめに	52
5.2	移動行動生成モデル	53
5.2.1	モデルの概要	53
5.2.2	エージェントの生成	54
5.2.3	行為系列生成	54
5.2.3.1	1次のマルコフモデル	54
5.2.3.2	2次のマルコフモデル	58
5.2.4	目的地系列生成	61
5.3	行為系列生成モデルの推定とモデル選択	63
5.3.1	データ	63
5.3.2	行為遷移確率の推定	63
5.3.3	モデル選択の手順	64
5.3.4	行為遷移確率行列の推定結果	65
5.3.5	AICの計算方法	68
5.3.6	AICの比較	68
5.3.7	データ生成の尤度	69
5.4	モデルの適用	70
5.4.1	データセットと処理過程	70
5.4.2	対象地域	71
5.4.3	行為系列生成モデルの適用	71
5.4.4	目的地系列生成モデルの適用	72
5.4.5	推定結果の検証	72
5.5	統計データの時点更新	75
5.5.1	対象地域の選定	75
5.5.2	適用方法	77
5.5.2.1	仕事の魅力度	77
5.5.2.2	学業の魅力度	77
5.5.2.3	買物の魅力度	77
5.5.2.4	受診・療養の魅力度	78
5.5.3	滞在人口を用いた評価	81
5.5.3.1	評価データの概要	81
5.5.3.2	滞在人口分布の比較	81
5.6	まとめ	84
6	結論	85
6.1	本研究の成果	85
6.2	今後の課題	86
A	最大エントロピー逆強化学習の対数尤度関数の計算	87
	References	88

List of Figures

1.1	パーソントリップ調査の実施数の変化 ([1] をもとに作成)	2
1.2	歩行者の意思決定行動と本研究で扱う範囲	3
1.3	本研究で扱うマルチスケールな行動モデリングの概念図	4
3.1	時空間制約下における遷移確率の計算例	14
3.2	単純化された環境での実験	16
3.3	設定値から計算される報酬関数と状態価値関数	17
3.4	推定結果の検証	18
3.5	目的地に対する到着率	19
3.6	目的地を座標 (4,4) に設定した場合の生成軌跡の比較	20
3.7	目的地を座標 (4,0) に設定した場合の生成軌跡の比較	21
3.8	丹後王国を模擬した環境での実験 (地図は国土地理院発行のデジタルマップ 2500 を使用)	22
3.9	設定値から計算される報酬関数と状態価値関数	24
3.10	検証実験用に生成した軌跡 (地図は国土地理院発行のデジタルマップ 2500 を使用)	25
3.11	目的地を座標 (6, 12) とし, 到着時間制約を変えて生成した軌跡の比較 (地図は国土地理院発行のデジタルマップ 2500 を使用)	26
3.12	目的地を座標 (9, 9) とし, 到着時間制約を変えて生成した軌跡の比較 (地図は国土地理院発行のデジタルマップ 2500 を使用)	27
4.1	スムージング処理の概念図	31
4.2	スムージング処理の手順	31
4.3	平滑化処理の適用例 (黄色: BLE 受信機, 青: 処理前の GPS データ, 赤: スムージング処理後のデータ)	32
4.4	球面メルカトル法による空間表現	33
4.5	サンプリングレートと遷移確率の関係	33
4.6	対象としたネットワーク	34
4.7	空間割り当ての結果の例. 割り当ての結果は円で表され, 円の色は滞在時間を表す.	36
4.8	エピソードの抽出例	37
4.9	歩行速度 90%ile 値, 95%ile 値の平均値 (代表者の年齢)	39
4.10	歩行速度 90%ile 値, 95%ile 値の平均値 (グループ人数)	39
4.11	歩行速度 90%ile 値, 95%ile 値の平均値 (子ども数)	40
4.12	POI への訪問確率 (子どもの有無)	41
4.13	POI への訪問確率 (京都府在住)	41
4.14	POI への訪問確率 (レジャー目的)	42
4.15	POI への訪問確率 (食事目的)	42
4.16	POI への訪問確率 (買い物目的)	43
4.17	効用値の時間変化の例	47
4.18	活動選択確率の予測例 (現在位置: 七姫殿, エピソード番号: 1, 経過時間: 60 分, 残り時間割合: 2/3)	48
4.19	時間帯別の複合財の飽和パラメータ値	51

5.1	移動行動生成モデルの概要	53
5.2	遷移確率推定問題の例	55
5.3	遷移確率推定問題の解	55
5.4	2次のマルコフモデルにおける同時分布の再帰的關係	59
5.5	モデル選択のフロー	65
5.6	個票データから求めた 30-34 歳男性の遷移確率行列（白抜きはデータが存在しない箇所）	66
5.7	30-34 歳男性の遷移確率行列の推定結果	67
5.8	AIC の比較	68
5.9	スムージングの例（実線が元データ，破線がスムージング後）. 左から $\delta = 0.1, 0.01, 0.001$.	69
5.10	データ生成の平均対数尤度の比較	70
5.11	対象地域（CraftMap[2] をもとに作成）	72
5.12	生成された行為系列（空白は在宅）	73
5.13	モバイル空間統計と推計値のメッシュ人口比較（右下図のみモバイル空間統計 4 時台と国勢調査の比較）	74
5.14	モバイル空間統計と推計値の相関係数の時間変化（属性別）	75
5.15	対象地域（CraftMap[2] をもとに作成）	76
5.16	小売業計従業者数と年間商品販売額の関係	78
5.17	売場面積と年間商品販売額の関係	79
5.18	受診・療養の魅力度算出の考え方	79
5.19	常勤換算医師数と平均外来患者数の関係	80
5.20	平均外来患者数の実績値と推計値の比較（実績値は岡山医師研修支援機構 HP より [3]	80
5.21	潜在人口の空間分布の比較	82
5.22	潜在人口の比較	83

List of Tables

3.1	特徴とパラメータ設定値	23
3.2	推定されたパラメータと標準誤差	25
4.1	対象の POI	37
4.2	推定結果（活動選択モデル）	46
4.3	推定結果（活動時間配分モデル）	49
4.4	推定結果（飽和パラメータ他）	50
5.1	移動行動生成モデルに使用するデータ	53
5.2	取得したサンプルの数	63
5.3	社会生活基本調査の行為の定義（在宅/外出は筆者が加えたもの）	64
5.4	再定義した行為	64
5.5	校態別の生徒数算出方法	77
5.6	評価に使用したモバイル空間統計の諸元	81

Chapter 1

序論

1.1 研究の背景

近年、自動車を中心とした街づくりから、人を中心に据えた街づくりへ空間を再構築しようとする取組みが進んでいる [4]. 質の高い都市空間は、経済的、社会的、健康的、環境的に利用者に高い価値をもたらすことが明らかになっている [5]. 特に近年の実証研究では、街路や広場などの質の高い公共空間は、社会的・心理的な健康を促進し、幸福感や生きる活力に良い影響を与えることが示唆されている [6, 7]. こうした人を中心とした街づくりは豊かな生活空間の実現、地域消費の拡大、観光客の増加や健康寿命の延伸など様々な地域課題の解決や新たな価値の創造につながると考えられている. しかしながら、多くの自治体ではどのように街路空間の再構築・利活用を行えば良いのか模索しているのが現状である.

そうした中、近年のスマートフォンの利用者数の拡大や様々な個人単位のセンシングデータの普及を背景として、データ駆動型の空間計画が注目されている. 国土交通省が推進する「スマート・プランニング」は、個人単位の行動データをもとに、人の動きをシミュレーションし、施策実施の効果を予測した上で、施設配置や空間形成、交通施策を検討する計画手法である [8]. スマート・プランニングのようなデータに基づく空間設計によって、行政や民間事業者はデータに裏付けされた共通認識を持つことができ、エビデンスに基づいた施策の決定 (Evidence-Based Policy Making; EBPM) につながることを期待される.

スマート・プランニングでは、個人単位の行動データとして、スマートフォンや GPS ロガーを用いて被験者から取得する GPS データや、民間企業が提供する GPS データや Wi-Fi のログデータ等を用いて歩行者の回遊行動のシミュレーションを実施しながら施策や取組みを検討するとしている [8]. しかしながら、現状のスマート・プランニングの手法には以下に示すような大きく 3 つの課題があると考えられる.

1. 個人単位の詳細な移動軌跡データを十分に活かしきれていない
2. 歩行者の複雑な意思決定、回遊行動の特徴を十分に表現できていない
3. 広域からの来訪者数の推定は、四段階推計が前提となっている

課題 1 に関しては、GPS データ等の詳細な位置情報データを活用するにも関わらず、リンクレベルの経路選択が行われており、詳細な位置情報データを活かしきれていないという課題である. また、歩行者のネットワークが整備されているという前提があるが、実際は道路ネットワークほど整備が進んでいないという課題がある. 課題 2 に関しては、歩行者の意思決定は非常に複雑なことが知られており [9], その多くを捨象してしまっているという課題である. 特に歩行者の回遊行動については、買い物等における衝動的な立寄り [10] や目的地を明確に設定しないような散策的な行動があることが指摘されており [11], このような特徴が表現できていないという課題である. まちの活性度は滞在時間に比例することが指摘されてお

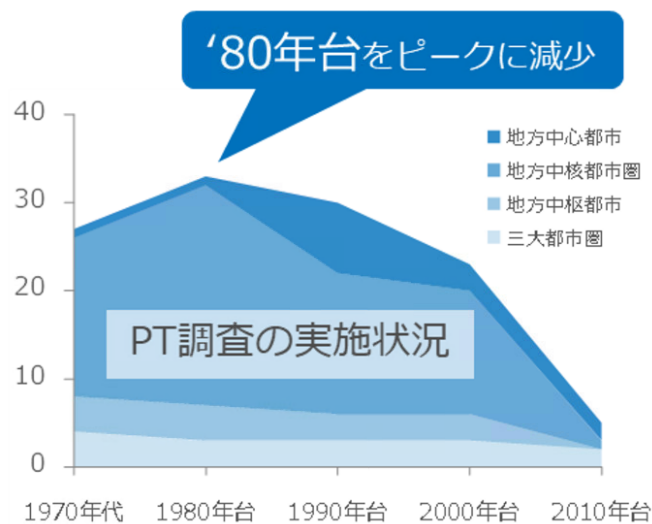


Figure 1.1: パーソントリップ調査の実施数の変化 ([1] をもとに作成)

り [12], 歩行者の複雑な意思決定を扱うことは、迂回や短い滞在といった歩行者の時間の使い方に関与するため非常に重要であると考えられる。最後の課題に関しては、四段階推計を前提とした場合、パーソントリップ調査等の大規模な交通調査が必要となる。パーソントリップ調査は金銭的・時間的コストが非常に大きいことから、大都市以外での実施数は近年減少傾向にあり (Figure 1.1), これを前提とした推計は多くの自治体にとっては困難となっている [1]。また、四段階推計は静的な予測方法であり、時間帯別の来訪者を推計するには適していない。さらに、トリップベースの手法であることから買い物等の特定の活動のための来訪者の推計には適していない問題もある。このように、広域の来訪者の推定に四段階推計を前提とすることには多くの課題がある。

1.2 研究の目的

前節で整理したように、近年のデータ駆動型の空間設計は人を中心とした街づくりのために有効な方法であると考えられるが、3つの大きな課題があった。本研究では、これらの3つの大きな課題に対して取り組み、新しい方法によってこれらの課題の解決を図ることを目的とする。

歩行者の複雑な意思決定は以下に示されるような3つのレベルに分けられることが知られている [9] :

- Strategic level (活動パターン)
- Tactical level (活動スケジューリング, 活動場所選択, 経路選択)
- Operational level (方向, 速度)

これまで提案されてきた多くの歩行者行動モデルは主に方向や速度の決定を行う Operational level を対象としており、Strategic や Tactical といった上位の意思決定を対象とした研究は十分に行われていない。また、これまでの研究の多くは、移動をコスト (負の効用) として捉えてきた。負の効用と捉える代表例は最短経路である。このような目的地指向型の移動軌跡の表現では、本研究で対象とするような歩行者の回遊行動の表現には不十分である。本研究では、目的地指向の移動軌跡のみならず、迂回や滞在などの回遊行動に特徴的な移動軌跡を生成可能な歩行者行動モデルを提案する。また、活動場所の選択など一部の意思決定行動に焦点を当てたモデルは提案されているものの、活動パターンの生成を含む上位の意思

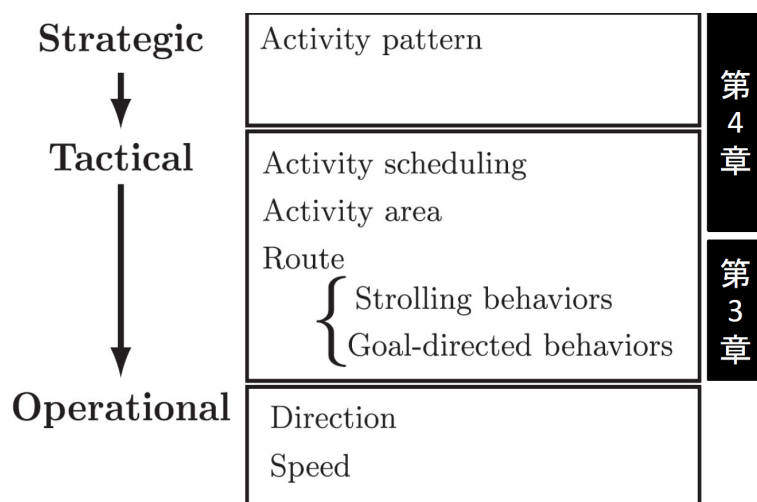


Figure 1.2: 歩行者の意思決定行動と本研究で扱う範囲

決定行動を統一的に表現したモデルはない。本研究では、このように Strategic から Tactical の上位の意思決定行動を対象とした歩行者行動モデルを新たに提案する (Figure 1.2)。

次に、個人単位の詳細な移動軌跡データの活用について本研究では、詳細な空間解像度を持つグリッドベースの空間表現を用いる。グリッドベースの空間表現は、一般的に Cellular Automata (CA) モデル [13] など用いられる方法であり、主に屋内環境のモデリングに用いられている。グリッドベースの空間表現は、自由度の高い歩行者の行動の記述を可能とする特徴を持つ。本研究では、GPS データから屋外環境でも 15 m グリッドの詳細な空間解像度を持つグリッドに離散化したデータの生成方法について提案する。

広域からの来訪者数の推定に関しては、各来訪者個人個人が持つ活動のパターンと時間の制約を表現できるアクティビティベースの手法が望ましい。各来訪者はここで規定される制約の下、エリア内の回遊を行うと考えることができる。また、先の課題に挙げたように大規模な交通調査などを前提としない方法が必要となる。本研究では、大規模な交通調査を一切必要とせず、個人単位の活動パターンを疑似的に生成する方法を提案する。

最後に、本研究で扱うマルチスケールな行動モデリングの概念図を Figure 1.3 に示す。

1.3 研究の構成

本研究は、以下のように構成される。

続く、第 2 章では既往研究の整理を行う。特に歩行者行動に関する既往研究として、非目的地指向型の歩行者経路選択モデル、リンクベースの経路選択モデルおよび、歩行者を対象とした活動スケジューリングモデルに焦点を当てたレビューを行う。また、GPS データを用いた歩行者の空間表現に関する既往研究についても概説し、さらには、広域の移動行動生成モデルに関する既往研究についてもレビューを行う。

第 3 章では、歩行者の回遊行動モデリングについて提案を行う。特に迂回や滞在などといった回遊行動に特徴的な移動軌跡を生成可能な歩行者行動モデルを提案する。提案手法は数値実験を通じてその有用性を確認する。

第 4 章では、歩行者の活動スケジューリングモデルについて提案を行う。特に Habib (2011) [14] によって提案された動的な活動スケジューリングモデルを歩行者の活動選択と活動時間配分に適用できるように拡張を行う。また、GPS データから詳細な空間解像度を持つグリッドに割り当てる方法について提案を行い、実際

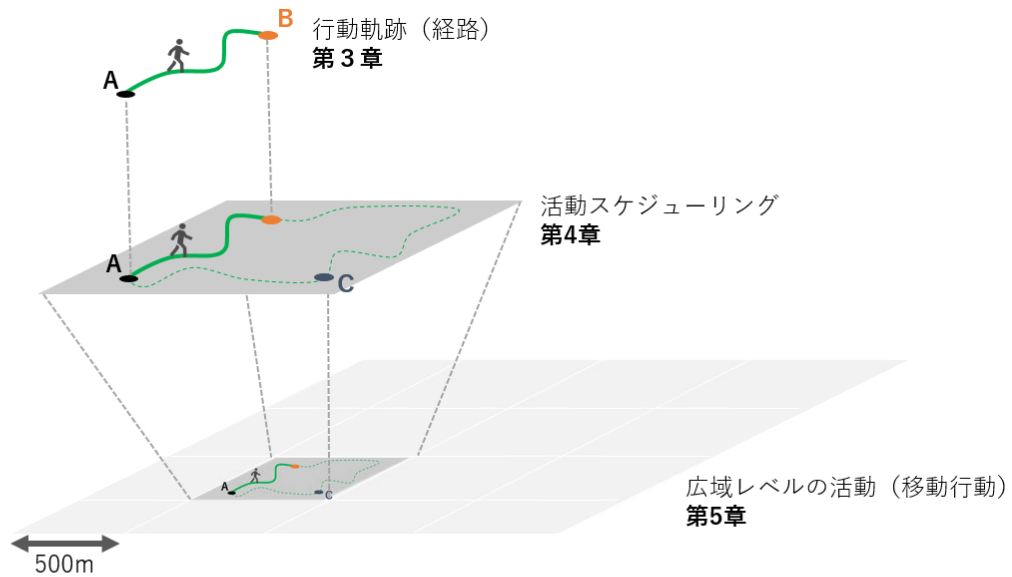


Figure 1.3: 本研究で扱うマルチスケールな行動モデリングの概念図

の GPS データに適用できることを確認する。時空間離散化を行ったデータを用いて活動スケジューリングモデルの推定を行い、その妥当性の検証を行う。

第5章では、広域の移動行動生成モデルの提案を行う。特に国勢調査や社会生活基本調査といった集計データのみを用いて非集計の疑似的な個票データの生成を行う方法を提案する。モデルは実際のデータに適用し、携帯電話の基地局の情報から生成されるデータとの比較により、検証を行う。

最後に第6章で、本研究で得られた成果を整理し、まとめを行う。また、本研究では取り組むことのできなかつた課題についても整理を行い、今後の展望を述べ、結びの言葉とする。

Chapter 2

既往研究

2.1 はじめに

本章では、既往研究の整理を行う。まず始めに2.2節では、歩行者行動モデルに関する既往研究について整理する。具体的には、経路選択モデルについて非目的地指向型の歩行者経路選択モデルについて紹介した後、経路の列挙を必要としないリンクベース（再帰型や逐次型とも呼ばれる）の経路選択アプローチについて紹介する。また、歩行者を対象とした活動スケジューリングモデルについてレビューを行う。さらには、GPSデータを用いた歩行者行動の空間表現について紹介する。続く2.3節では、広域の移動行動生成モデルに関する既往研究についてレビューを行う。

2.2 歩行者行動に関する既往研究

2.2.1 非目的地指向型の歩行者経路選択モデル

非目的地指向型の経路選択行動を対象とした研究として、視覚情報と歩行行動の関係を直接モデル化する手法が提案されている [15, 16]。このモデルでは、歩行行動は空間レイアウトの構成に関する事前処理された視認性グラフ情報に基づき決定される。しかしながら、探索行動に焦点を当てたモデルであるため、広いオープンスペースなどの特定の環境での利用には限界がある。これに対し、本研究の提案手法では、観察された軌跡から場所の魅力が直接学習することで、環境に制約されない行動方策を示すことが可能である。

視認性グラフを用いたモデルは静的な環境情報から行動を決定するモデルであったが、扇形の行動空間上で速度と方向を決定する動的な表現を持つモデルも提案されている [17, 18, 19]、さらに Wang ら (2014) は、同じく扇形の行動空間のモデルを用いて、歩行者の視野内にある魅力物の影響を考慮した探索行動モデルを提案している [20]。

別のアプローチとして、Borgers and Timmermans (1986) は、都市内のショッピングエリアにおける歩行者の買い物行動を、衝動的な立ち寄りを伴う逐次的な意思決定からなる計画的な旅行として表現するモデルを提案した [10]。しかしながら、これらのモデルは環境の魅力が歩行行動に与える影響のみを考慮しており、空間的な制約から生じる目的地指向型の行動と散策行動のトレードオフを考慮しておらず、また、近視眼的な行動を前提としている。提案手法では、割引率を導入することで、完全な情報を持った行動（例えば、[9]）から、近視眼的な行動（例えば、[20]）まで多様な表現が可能となる。

2.2.2 リンクベースの経路選択モデル

経路の明示的な列挙を必要としないリンクベースの経路選択モデルは、交通量配分の文脈で初めて提案された（例えば、[21, 22, 23]）。経路選択の文脈では、Fosgerau et al. (2013) が提案した Recursive logit (RL) モデル [24] に始まり、nested RL モデル [25]、generalized RL モデル [26]、discounted RL モデル [27] などのモデルへと発展してきた。RL モデルは、機械学習の文脈で提案された最大エントロピー逆強化学習 (Maximum entropy inverse reinforcement learning; MaxEnt IRL) [28] と同等のモデルであることが知られている [29]。これらのモデルの応用先としては、アクティビティベースモデル [30, 31]、サイクリストの経路選択 [32]、歩行者の経路選択 [33, 34] などがある。

リンクベースの経路選択モデルは、経路を明示的に列挙することなく、選択肢集合全体を考慮できるという利点がある。さらに、選択肢集合の mis-specification に関連するバイアスも生じない [35]。

2.2.3 歩行者を対象とした活動スケジューリングモデル

Hoogendoorn and Bovy (2004) は、効用最大化の概念に基づいた活動スケジューリングモデルを提案した [9]。ここでは動的計画法を用いて、経路の選択、活動エリアの選択、活動順序の決定を行っている。Liu et al. (2014) は、空港での活動選択をチェックイン前、保安検査前、搭乗前の3つの期間に分けて、Nested logit モデルを適用して活動スケジュールを生成している [36]。また、動的モデルを活動選択に適用し、多項ロジットモデルなどの静的モデルと比較した研究では、動的モデルは静的モデルより勝っており、さらに個人差を表現するランダム効果を導入したモデルが最も優れているという報告がされている [37, 38]。しかし、これらの研究では、活動の順番を決めることしかできず、活動時間の配分が考慮されていない。

Zhang (2009) は都心部における歩行者の活動時間配分と金銭消費をモデル化しているが、空間的な要素は考慮されていない [39]。本研究では、Habib (2011) [14] によって提案された逐次活動スケジューリングモデルを採用し、動的な活動選択と活動時間配分を同時に考慮する。Habib (2011) のモデルは、福山・羽藤 (2016) [40] の歩行者モデルに適用されている。このモデルは、歩行者の歩行パターンをリンクではなく 100~300m スケールの活動エリアに分割し、活動エリアの選択と時間配分を表現するために Habib (2011) のモデルを採用している。しかしながら、この研究では、大まかに分割された活動エリアを考慮しており、特定の施設に対する活動選択に焦点を当てた本研究のモデルとは異なる。本研究では、施設内の複数の POI (Point of Interest) に対して、15m スケールの解像度を持つ詳細な空間表現を用いて、活動選択と活動時間配分をモデル化している。

2.2.4 GPS データを用いた歩行者の空間表現

歩行者の GPS データを用いて行われた最近の研究で、Oyama and Hato (2018) は、歩行者の経路選択モデルのパラメータを、リンクごとに異なる GPS 測定誤差を推定しながら同時に推定する方法を提案した [41]。しかしながら、この研究では歩行者のネットワークが既知であることを前提としている。Kasemsuppakorn and Karimi (2013) は、歩行者ネットワークが道路ネットワークほど容易に入手できないことから、複数の GPS トレースを用いて歩行者ネットワークを自動生成する手法を提案した [42]。これらの研究の共通点は、リンクを用いて空間を表現している点にあるが、歩行者の自由度の高い行動を十分に表現できていないという問題がある。

一方、グリッドベース（もしくはセルベース）の空間表現は、より柔軟な歩行者の空間表現である。これらの表現の多くは、CA モデル（例えば、[13]）に代表されるように、主に屋内環境に用いられる。Asano et al. (2010) は、経路選択モデルのネットワーク表現としてグリッドベースの空間表現を用いている [43]。Xu et

al. (2018) は、グリッドベースの空間表現に対する屋内トラッキングアルゴリズムを提案している [44]. Ziebart et al. (2009) は、グリッドベースの空間表現を用いて、逆強化学習法によりロボットの経路計画のための歩行者の行動予測を行っている [34]. これらのモデルに見られるように、グリッドベースの空間表現を用いた研究の多くは、屋内環境に焦点を当てている. 実際の GPS データに基づいてグリッドベースの空間表現を行った例外的な研究として、Sarjala (2019) は、空間解像度 20m のグリッドベースの空間表現を用いて、歩行者と自転車の通勤時の移動に対する建築環境の影響を調べている [45]. しかしながら、この研究では GPS ポイントを各ポイントを含むグリッドに割り当てるだけであり、ノイズが含まれる場合のポイントの割り当てまで考慮されていない. 一方で本研究では、GPS の観測が困難な屋内環境の場合でも、軌跡全体の尤もらしさを考慮し、統合的な位置を割り当てる方法を提案する.

2.3 広域の移動行動生成モデルに関する既往研究

人の移動行動の理解の研究は、主に都市圏における移動需要の予測を目的として長年に渡り行われてきた. 歴史的には集計型の交通需要推定手法である四段階推計法が大きな役割を担い、その後、移動が個人の活動から派生するとの考え方に基づくアクティビティベースモデルの登場によって、世帯や個人単位での移動行動理解へと進んでいった.

アクティビティベースモデルの中にも、効用最大化によるもの [46, 47, 48], ルールベースのもの [49, 50], 数理計画問題を用いたもの [51] など様々な手法が既に提案されている. こうした分析手法は、人の移動行動の理解に対して多大な貢献を果たしてきた一方で、パーソントリップ調査を始めとした大規模な交通調査に基づく個人の詳細な移動記録を必要とする. しかしながら、前述のようにパーソントリップ調査は三大都市圏や地方中枢都市圏、政令市などでは継続的に行われているものの、時間的・金銭的なコストの大きさなどの理由から継続的な実施ができていない都市圏も多く、近年では調査を実施していない都市も多く見られる [1].

他方、スマートフォンの利用数の拡大に伴い、個人の位置情報データを用いた人の移動行動理解の研究も盛んになっている. 例えば、GPS を利用したもの [52, 53, 54], SNS のチェックイン情報を利用したもの [55, 56], 不特定多数の携帯電話の通信履歴を利用したもの [57, 58, 59] などがその代表例である. しかしながら、個人の位置情報データの活用はその可能性を大きく期待される一方で、個人情報保護の観点から活用は限定的にならざるを得ない課題がある.

このような状況のなか、携帯電話の GPS 情報や基地局情報を集計化処理して作成される人口統計情報が注目を集めている. Ge and Fukuda (2016) は、プライバシーを侵害しない集約化された携帯電話の情報を用いて勤務地・通学先に関する OD 行列を更新する手法を提案している [60]. また、清家らは、携帯電話の基地局情報から作成される人口統計情報を用いて、土地利用、公園・緑地、交通、拠点振興の四分野に対して活用可能性の検証を行っている [61]. そこでは、時間帯別の人口把握、高頻度性、広域性の観点で有用性を確認する一方で、目的別の滞在人口が把握できないことや、移動手段や経路が把握できないことを課題・留意点に挙げている.

以上のように、携帯電話から得られる人口統計情報では、人の移動目的や移動手段などの把握が困難であるという課題がある. また、これらはいくまでも、ある時間断面の人口に集約がされており、そこでは OD のような移動に関する情報は一切失われている.

本研究で提案する方法では、国勢調査や社会生活基本調査のような個人情報を一切含まない集計データに着目し、これらを統合することにより疑似的な人の移動行動データを生成する. この疑似データは、年齢、性別、居住エリア、1日の行動スケジュール、1日の滞在地の情報を持つ多数の疑似的な個人（エージェント）から構成される. これらのエージェントは集計データの統計的な性質を保証するよう

に確率的な移動行動モデルを用いて生成される。既存研究においても、アクティビティベースドモデルの適用によって多数のエージェントを生成し、都市圏規模での移動需要を推定する研究 [62, 63] も存在するが、モデルの推定にあたっては大規模な非集計の交通行動調査が用いられており、データ収集の点で課題がある。

Chapter 3

歩行者の回遊行動モデリング

3.1 はじめに

第1章にて述べたように、スマート・プランニングを始めとする既存のデータ駆動型の空間設計手法では、歩行者の複雑な意思決定、特に回遊行動の特徴を十分に表現できていないという課題があった。歩行者の意思決定行動のモデリングに関する研究という観点からも、既存の研究の多くは歩行者の進む方向や速度を決定する Operational なレベルの意思決定モデルの開発に捧げられており [64, 13, 17], Tactical なレベルの意思決定行動モデルの開発は十分ではない。Tactical なレベルの意思決定に関する研究には、避難状況における出口選択を検討したもの [65, 66, 67] や、平常時の施設内の経路選択問題 [43, 68] を扱ったものがある。これらは、施設内の構造的制約の下での意思決定問題であり、オープンスペースのような屋外環境での意思決定問題ではない。

本章では、特に歩行者の軌跡に関する Tactical レベルの意思決定に焦点を当てる。Hoogendoorn and Bovy (2004)[9] は、歩行者が主観的効用を最大化するという仮定のもと、規範的な歩行者行動理論を提案した。このモデルは、経路選択、活動エリア選択、活動スケジューリングを網羅し、効用最大化によってそれらを同時に最適化するものであった。

一方で近年、膨大な軌跡データが利用可能となってきていることを背景として、データ駆動型のアプローチが期待されている。データ駆動型アプローチの一つである逆強化学習は、観測された歩行者の軌跡から POI に関する報酬関数を推論する強力なツールである。この手法では、任意の POI の空間分布を持つオープンスペースの魅力に基づいて軌跡を生成することができる。Ziebart ら (2009)[34] は、逆強化学習をロボットの経路計画のための歩行者の行動予測に適用した。このモデルは、歩行者の意思決定の不確実性を考慮して、歩行者の行動を確率的に予測する。Kitani ら (2012)[33] は、Ziebart ら (2009)[34] の研究を拡張し、視覚に基づく物理的シーンの特徴を取り入れることで歩行者の行動を予測した。これらのモデルは任意の POI 分布に対する軌道を生成するための有効なアプローチであるものの、目的地指向型の行動しか生成できない。そのため、このモデルでは、新しい休憩スペースの提供や路上商店の開設など、人々が立ち寄りやすくなるような空間計画を予測するには十分でない。これは、モデルが経路上の効用として負の値しか想定していないことに起因する。正の効用を仮定すると、同じ状態を続けることで効用を無限に増大させることができる。この事実は、正の効用を扱うには時間的な制約が必要であることを示唆している。このことから様々な軌跡を表現するためには、時間制約のある正効用の仮定が必要となる。

本章では、任意の POI の空間的な分布に対して様々な軌跡を生成するための2段階のアプローチを提案する。第一段階では、逆強化学習により POI の効用関数と確率的方策を推定し、第二段階では、与えられた目的地と到着時間の制約の下で軌跡を生成する。

本研究で提案するモデルは、歩行者の流れを再現できる従来のシミュレーショ

ンモデル（例えば、[13, 69, 70]）とは異なる。我々のモデルでは、他の歩行者や障害物との局所的な相互作用ではなく、歩行者が何を魅力的または価値があると感じているかといった環境の知覚に主眼を置いている。そのため、花の美しさを楽しんだり、大道芸に惹かれたりといった主観的な要素の影響を定量的に明らかにできる。魅力を定量的に把握することで、新たな歩行空間整備の指針を導き出すことができ、より魅力的な空間整備に貢献することができる。また、本モデルは他の歩行者や障害物との局所的な相互作用を含まないため、従来の歩行者モデルと補完的に利用することができる。

本章での貢献は以下のようにまとめられる。

- 任意の POI の空間分布に対して、目的地指向の軌跡のみならず、迂回や滞在を含む軌跡を生成する新しい手法を開発した。本手法では、従来のように累積移動コストを最小化するのではなく、目的地への到着時間に関する制約の下で歩行者の累積効用を最大化する軌道を生成する。この手法は、賑わいのある公共空間を設計する際に、POI の空間的な分布の影響を評価するのに役立つ。
- 時空間制約を満たす軌跡を見つける効率的な計算方法を開発した。歩行者軌跡の状態遷移確率は、forward-backward アルゴリズムと行列演算を用いて効率的に計算できると結論付けた。
- 提案した手法が時空間制約を満たす軌道を効率的に生成することを、オープンスペースを対象とした 2 種類の規模の異なる数値実験により示した。

本章の構成は以下の通りである。第 2 節では、モデルの第一段階を説明する。特に、効用関数を推論するための逆強化学習について説明し、この逆強化学習を用いて、効用関数と確率的方策を推定する方法を説明する。第 3 節では、時空間制約の下で軌跡を生成する方法を提案する。第 4 節では、モデルの特性を確認するために 2 種類の規模の異なる数値実験を行う。最後に、第 5 節で結論と今後の課題を述べる。

3.2 準備

提案モデルは主に二段階で構成される。第一段階では、与えられたデモンストレーションの軌跡と環境のモデルを入力して、報酬関数と確率的方策を推定する。ここでは、Ziebart ら (2009)[34] が提案した確率的なマルコフ意思決定過程 (Markov decision process; MDP) に基づいて、最大エントロピー逆強化学習を実行する。第二段階では、推定された報酬関数と確率的政策に基づいて、目的地と到着時間の制約下で軌跡を生成する。本節では、確率的方策を結果に持つ MDP と、最大エントロピー逆強化学習を紹介する。以下では、期間不定での報酬和を考える infinite horizon 問題を扱うが、有限の期間を扱う finite horizon 問題についても適用可能である。

3.2.1 MDP による確率的方策の計算

MDP は、状態集合 \mathcal{S} 、行動の集合 \mathcal{A} 、行動の遷移モデル $\mathcal{T} : \mathcal{S} \times \mathcal{A} \rightarrow \mathcal{A}$ 、報酬関数 $\mathcal{R} : \mathcal{S} \times \mathcal{A} \rightarrow \mathbb{R}$ の要素の組 $\langle \mathcal{S}, \mathcal{A}, \mathcal{T}, \mathcal{R} \rangle$ で構成される。

ここで、以下に表される状態価値関数 $V(s)$ と行動価値関数 $Q(s, a)$ を導入する。

$$V(s) = \mathbb{E} \left[\sum_{k=0}^{\infty} \gamma^k R(s_{t+k+1}, a_{t+k+1}) \middle| s_t = s \right], \quad (3.1)$$

$$Q(s, a) = \mathbb{E} \left[\sum_{k=0}^{\infty} \gamma^k R(s_{t+k+1}, a_{t+k+1}) \middle| s_t = s, a_t = a \right]. \quad (3.2)$$

ここで、 $\gamma \in [0, 1]$ は割引率である。報酬和を最大化する最適な方策 $\pi^* : \mathcal{S} \rightarrow \mathcal{A}$ は、以下の Bellman 最適方程式を解くことで得られる。

$$Q^*(s, a) = R(s, a) + \gamma V^*(\mathcal{T}(s, a)), \quad (3.3)$$

$$V^*(s) = \max_{a \in \mathcal{A}} Q^*(s, a). \quad (3.4)$$

したがって、最適な方策は $\pi^* = \operatorname{argmax}_{a \in \mathcal{A}} Q^*(s, a)$ となる。

しかしながら、意思決定には不確実性が伴うため、歩行者は必ずしも最適な軌跡をとるとは限らない。Ziebart ら (2009)[34] は、意思決定に関わる不確実性を捉えるために Bellman 方程式の最大値関数を log-sum 関数に置き換えた。

$$Q^\approx(s, a) = R(s, a) + \gamma V^\approx(\mathcal{T}(s, a)), \quad (3.5)$$

$$V^\approx(s) = \log \sum_{a \in \mathcal{A}} \exp \{Q^\approx(s, a)\} \quad (3.6)$$

この場合、確率的な方策 $p(s|a)$ は以下に示される logit 関数で表現される。

$$V^\approx(s) = \log \sum_{a \in \mathcal{A}} \exp \{Q^\approx(s, a)\} \quad (3.7)$$

3.2.2 最大エントロピー逆強化学習

本節では、Ziebart ら (2008)[28] が提案した最大エントロピー逆強化学習について説明する。観測された軌跡 ζ_i は、状態と行動のシーケンスであり、 $\zeta_i = \{(s, a)\}$ である。ここでは、観測された軌跡の集合 $\{\zeta_i\}$ は、全て同じ OD を持つと仮定する。逆強化学習では、観測された軌跡の集合 $\{\zeta_i\}$ に適合する報酬関数を推論する。また、報酬関数 $R(s)$ は k 次元の特徴量 \mathbf{f}_s に対し線形であると仮定し、 $R(s) = \boldsymbol{\theta}^\top \mathbf{f}_s$ とした。ここで $\boldsymbol{\theta} \in \mathbb{R}^k$ は報酬のパラメータであり、 $^\top$ は転置を表す。軌跡により得られる報酬 $R(\zeta_i)$ は、その軌跡に含まれる状態の報酬の総和で表される。すなわち、 $R(\zeta_i) = \sum_{s \in \zeta_i} \boldsymbol{\theta}^\top \mathbf{f}_s$ である。最大エントロピーの原理より、観測された軌跡 $P(\zeta_i|\boldsymbol{\theta})$ が得られる確率は次のようになる。

$$P(\zeta_i|\boldsymbol{\theta}) = \frac{\exp \{R(\zeta_i)\}}{\sum_{\zeta \in Z} \exp \{R(\zeta)\}} \quad (3.8)$$

ここで Z は、与えられた初期位置に対するすべての可能な経路集合である。パラメータ $\boldsymbol{\theta}$ は、経路集合 $\{\zeta_i\}$ に対する対数尤度 $L(\boldsymbol{\theta}) = \sum_i \log P(\zeta_i|\boldsymbol{\theta})$ を最大化することにより決定される。

$$\boldsymbol{\theta}^* = \operatorname{argmax}_{\boldsymbol{\theta}} \sum_i \log P(\zeta_i|\boldsymbol{\theta}) \quad (3.9)$$

$$= \operatorname{argmax}_{\boldsymbol{\theta}} \sum_i \left\{ \left(\sum_{s \in \zeta_i} \boldsymbol{\theta}^\top \mathbf{f}_s \right) - V^\approx(s_{t=0}) \right\} \quad (3.10)$$

ここで、 $s_{t=0}$ は軌跡 ζ_i の初期位置を表している。式 (3.10) の詳細な導出については Appendix A を参照されたい。上式は凸関数であり、最適解は勾配法を用いた最適化手法によって得られる。

上述の対数尤度関数の勾配は以下のよう求めることができる。

$$\nabla_{\theta} L = \frac{1}{|\zeta|} \sum_i \sum_{s \in \zeta_i} \mathbf{f}_s - \mathbb{E}_{P_{\theta}(\zeta)}[\mathbf{f}_s] \quad (3.11)$$

ここで、 $|\zeta|$ は観測された軌跡の数を表すので、この式は観測された軌跡の特徴量と期待される特徴量の差を表している。パラメータの推定は、最適な方策 $\pi(a|s)$ を価値反復によって解き、式 (3.11) を用いた勾配最適化によって更新するという2つのステップで反復的に実行される。

3.3 時空間制約下の移動軌跡生成

ここでは、時空間制約の下で様々な軌道を生成する手法について説明する。

軌跡 ζ は、状態の集合から構成される、すなわち、 $\zeta = \{s_0, s_1, \dots\}$ である。初期の状態 s_0 、所与の目的地 s_g と到着時刻制約 T_{arvl} が所与の条件の下、次の状態への遷移確率 $P(s_{t+1}|s_t, s_{T_{\text{arvl}}})$ が得られれば、状態を逐次的にサンプリングすることができる。以下では、forward-backward アルゴリズムを用いてこの確率を導出する。また、状態遷移行列の乗算を用いることで効率的に確率を算出できることを示す。

確率の方策 $\pi(a|s)$ は、観測された軌跡の集合 ζ_i から、3.2.1-3.2.2 節で説明した方法で得られる。本節では、時空間制約を考慮した軌道の生成モデルについて説明する。

初期位置 s_{init} が所与の下での状態 s_t の確率分布を $\alpha(s_t) \equiv P(s_t|s_0)$ とし、また、状態 s_t の条件の下、到着時間制約 T_{arvl} で目的地 s_g に到達する確率を $\beta(s_t) \equiv P(s_{T_{\text{arvl}}}|s_t)$ とする。 $\alpha(s_t)$ 、 $\beta(s_t)$ の再帰的關係は以下の関係で表される。

$$\alpha(s_t) = \sum_{s_{t-1}} P(s_t|s_{t-1})P(s_{t-1}|s_0) \quad (3.12)$$

$$= \sum_{s_{t-1}} P(s_t|s_{t-1})\alpha(s_{t-1}) \quad (3.13)$$

$$\beta(s_t) = \sum_{s_{t+1}} P(s_{T_{\text{arvl}}}|s_{t+1})P(s_{t+1}|s_t) \quad (3.14)$$

$$= \sum_{s_{t+1}} P(s_{T_{\text{arvl}}}|s_{t+1})\beta(s_{t+1}) \quad (3.15)$$

ここで、 $\alpha(s_0)$ 、 $\beta(s_{T_{\text{arvl}}})$ はそれぞれ初期位置 s_{init} と目的地 s_g に対応しており、

$$\alpha(s_0) = \begin{cases} 1 & \text{if } s_0 = s_{\text{init}} \\ 0 & \text{otherwise} \end{cases} \quad (3.16)$$

$$\beta(s_{T_{\text{arvl}}}) = \begin{cases} 1 & \text{if } s_{T_{\text{arvl}}} = s_g \\ 0 & \text{otherwise} \end{cases} \quad (3.17)$$

遷移確率 $P(s_{t+1}|s_t)$ は以下の式で表すことができる。

$$P(s_{t+1}|s_t) = \sum_{a_t} P(s_{t+1}|s_t, a_t)\pi(a_t|s_t) \quad (3.18)$$

ここで、 $P(s_{t+1}|s_t, a_t)$ は確率の方策により、状態 s_t から状態 s_{t+1} に遷移する確率である。

時空間制約下における遷移確率 $P(s_{t+1}|s_t, s_{T_{\text{arvl}}})$ は、ベイズの定理により以下の関係が導出される。

$$P(s_{t+1}|s_t, s_{T_{\text{arvl}}}) = \frac{P(s_{t+1}, s_{T_{\text{arvl}}}|s_t)}{P(s_{T_{\text{arvl}}}|s_t)} \quad (3.19)$$

$$= \frac{P(s_{T_{\text{arvl}}}|s_{t+1})P(s_{t+1}|s_t)}{P(s_{T_{\text{arvl}}}|s_t)} \quad (3.20)$$

$$= \frac{\beta(s_{t+1})}{\beta(s_t)} P(s_{t+1}|s_t) \quad (3.21)$$

したがって、時空間制約下での遷移確率は、元の遷移確率 $P(s_{t+1}|s_t)$ に、時刻 t と時刻 $t+1$ で目的地に到達する確率の比を乗じることで求めることができる。

さらに、 $P(s_t|s_0, s_{T_{\text{arvl}}})$ で示される時空間制約下での時刻 t における状態の確率分布は、以下のようにして得られる。

$$P(s_t|s_0, s_{T_{\text{arvl}}}) = \frac{P(s_{T_{\text{arvl}}}|s_0, s_t)P(s_0, s_t)}{P(s_0, s_{T_{\text{arvl}}})} \quad (3.22)$$

$$= \frac{P(s_{T_{\text{arvl}}}|s_t)P(s_t|s_0)P(s_0)}{P(s_0, s_{T_{\text{arvl}}})} \quad (3.23)$$

$$= \frac{P(s_{T_{\text{arvl}}}|s_t)P(s_t|s_0)}{P(s_{T_{\text{arvl}}}|s_0)} \quad (3.24)$$

$$= \frac{\alpha(s_t)\beta(s_t)}{\beta(s_0)} \quad (3.25)$$

したがって、 $P(s_t|s_0, s_{T_{\text{arvl}}})$ は $\alpha(s_t)$ と $\beta(s_t)$ の積に比例する。

$\alpha(s_t)$ と $\beta(s_t)$ は行列演算によって容易に求めることができる。いま、 N 個の要素からなる集合を考え、さらに以下に示す $N \times N$ 次元の遷移確率行列 M を考える。

$$M = \begin{pmatrix} P(s^{(1)}|s^{(1)}) & P(s^{(1)}|s^{(2)}) & \dots & P(s^{(1)}|s^{(N)}) \\ P(s^{(2)}|s^{(1)}) & P(s^{(2)}|s^{(2)}) & \dots & P(s^{(2)}|s^{(N)}) \\ \vdots & \vdots & \ddots & \vdots \\ P(s^{(N)}|s^{(1)}) & P(s^{(N)}|s^{(2)}) & \dots & P(s^{(N)}|s^{(N)}) \end{pmatrix} \quad (3.26)$$

各要素の定義は式 (3.18) に既に示されている。このとき $\alpha(s_t)$ と $\beta(s_t)$ はそれぞれ以下のように表現できる。

$$\alpha(s_t) = M^t \alpha(s_0) \quad (3.27)$$

$$\beta(s_t) = \left(M^T\right)^{T_{\text{arvl}}-t} \beta(s_{T_{\text{arvl}}}) \quad (3.28)$$

ただし、 M^t は遷移確率行列 M の t 乗を表している。

本節の最後に、時空間制約を考慮した軌跡生成について、Figure 3.1 の例を用いて説明を行う。 $t=0$ における初期位置を $s^{(1)}$ 、時刻 $t=3$ での目的地を $s^{(3)}$ とする制約条件の下、軌跡の生成を行う。この例では、制約条件を満たす軌跡は3つ、すなわち

1. $\zeta_1 : s^{(1)} \rightarrow s^{(1)} \rightarrow s^{(2)} \rightarrow s^{(3)}$
2. $\zeta_1 : s^{(1)} \rightarrow s^{(2)} \rightarrow s^{(2)} \rightarrow s^{(3)}$
3. $\zeta_1 : s^{(1)} \rightarrow s^{(2)} \rightarrow s^{(3)} \rightarrow s^{(3)}$




Figure 3.1: 時空間制約下における遷移確率の計算例

である.

確率的方策により, 各軌跡が生成される確率は

1. $\zeta_1 : \frac{1}{4} \times \frac{3}{4} \times \frac{2}{3} = \frac{1}{8}$
2. $\zeta_2 : \frac{3}{4} \times \frac{1}{3} \times \frac{2}{3} = \frac{1}{6}$
3. $\zeta_3 : \frac{3}{4} \times \frac{2}{3} \times \frac{1}{2} = \frac{1}{4}$

したがって, 与えられた時空間制約の下で各軌跡が選択される確率は, それぞれ $P(\zeta_1) = 3/13$, $P(\zeta_2) = 4/13$, $P(\zeta_3) = 6/13$ となる. Figure 3.1 の例のような単純なネットワークでは, 軌跡を簡単に列挙することができるが, ネットワークが複雑になると, 軌跡の列挙が困難になる. 提案手法を用いることで, 制約条件を満たす遷移確率 $P(s_{t+1}|s_t, s_{T_{arvl}})$ や確率分布 $P(s_t|s_0, s_{T_{arvl}})$ を効率的に求めることができる.

Figure 3.1b と 3.1c は, 式 (3.13) と式 (3.15) で評価した $\alpha(s_t)$ と $\beta(s_t)$ の結果をそれぞれ示している. また, 計算された遷移確率 $P(s_{t+1}|s_t, s_{T_{arvl}})$ と確率分布 $P(s_t|s_0, s_{T_{arvl}})$ を Figure 3.1d に示す. 例えば, 初期位置 $s^{(1)}$ から最初に状態 $s^{(2)}$ を選択する確率は, 式 (3.21) より

$$P(s_1 = s^{(2)}|s_0 = s^{(1)}) = \frac{5/9}{13/24} \cdot \frac{3}{4} = \frac{10}{13} \quad (3.29)$$

と得ることができる. これは, 軌跡 ζ_2 と ζ_3 の選択確率の合計と一致する. さらに, 状態 $s^{(2)}$ から $s^{(3)}$ を選択する確率は,

$$P(s_2 = s^{(3)}|s_1 = s^{(2)}) = \frac{1/2}{5/9} \cdot \frac{2}{3} = \frac{3}{5} \quad (3.30)$$

となり, これは軌跡 ζ_2 , ζ_3 から軌跡 ζ_3 を選択する確率と一致する. Figure 3.1d に示されるように, 初期位置と目的地から到達できないノードの状態確率は 0 であり, 時空間制約を満たすノードのみが正の値を持つことが確認できる.

3.4 数値実験

本節では, 提案モデルの検証実験を行い, 規模の異なる 2 つの数値実験を通して提案モデルの特性を明らかにする.

3.4.1 簡易的な環境での実験

まず始めに, 単純化された環境での実験を通して提案モデルの特性を明らかにする.

3.4.1.1 実験設定

ここでは, 5×5 のグリッドに離散化された単純な環境を考える. 実験環境は, Figure 3.2 に示すように, 歩道, 芝生, 桜の木, POI の 4 つの特徴から構成されていると仮定する. また, 行動空間 $\mathcal{A}(s)$ は, 8 方位と滞在の全 9 種類であり, 定義されたエリアの外への行動はできないものとする.

歩道, 芝生, 桜の木, POI の特徴をそれぞれ f_{ww} , f_{gr} , f_{ch} , f_{POI} と表記する. 歩道, 芝生, POI は, 対応する特徴がグリッドに存在するかどうかを表すダミー変数として扱う, すなわち, $f_{ww}, f_{gr}, f_{POI} \in \{0, 1\}$ とする. 桜の木からの報酬は, 遠くからでも見て楽しむことで得られると仮定した. 桜の木の特徴は, $f_{ch} = \exp\{-\min|d(s, s_{ch})|\}$ と表されるものとする. ただし, $\min|d(s, s_{ch})|$ は桜の木のあるグリッドまでの最短距離を表す.

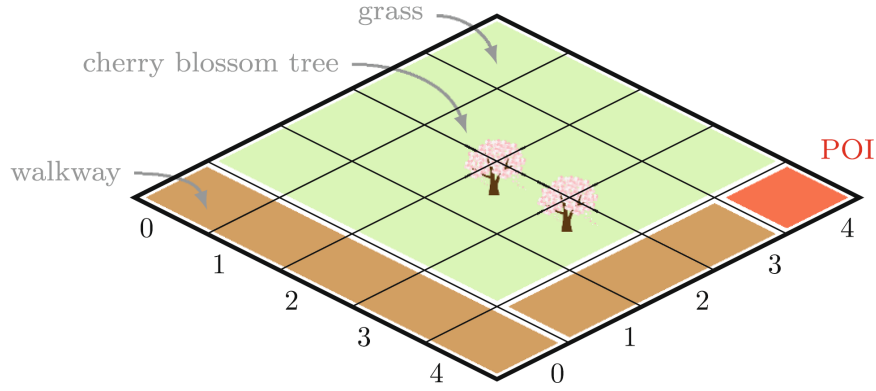


Figure 3.2: 単純化された環境での実験

歩道、芝生、POIの間には排他的な関係があり、 $f_{ww} + f_{gr} + f_{POI} = 1$ と表される。この依存関係から推定すべきパラメータは、この3つの特徴量のうちの2つとなる。ここでは、歩道とPOIを選ぶこととする。

推定するパラメータの設定値は $[\theta_{ww}, \theta_{ch}, \theta_{POI}]^T = [3, 3, 6]^T$ に設定した。ただし、 θ_{ww} , θ_{ch} , θ_{POI} はそれぞれ歩道、桜の木、POIのパラメータを表す。 θ_{ww} と θ_{POI} は θ_{gr} からの相対値である。したがって、生成される軌跡は芝生よりも歩道とPOIを通過する傾向にあると考えられる。

上記のパラメータ設定値と割引率を0.9に設定して算出された報酬関数と状態価値関数を Figure 3.3 に示す。

3.4.1.2 推定結果の検証

本節では、前節で示した設定を用いて検証を行う。全ての軌道の初期位置は座標 $(0, 0)$ であると仮定する。ここでは、軌跡の数が異なる4つのケース ($N = 10, 50, 100, 1000$) を比較する。また、観測時間が異なる4つのケース ($T = 5, 7, 10, 20$) を比較する。

結果を Figure 3.4 に示す。図中の丸は、パラメータの推定値を表し、線の色に対応する幅は標準誤差を表している。推定に用いる軌跡の数が増えると、推定値が安定する（観測時間に関わらず、変動が小さくなる）ことが分かる。初期位置から最も遠い位置にあるPOIの標準誤差は、到達した軌跡の数が増えたため、観測時間の増加とともに大幅に減少した。 $N = 10$, $T = 5$ の場合は、POIに到達した軌跡がなかったため、推定は失敗となった。


3.4.1.3 時空間制約下の生成軌跡の比較

本節では、複数の条件で生成された軌跡の比較を行う。使用するパラメータは、3.4.1.1節の設定値と同じであり、 $[\theta_{ww}, \theta_{ch}, \theta_{POI}]^T = [3, 3, 6]^T$ である。以下では、2つの目的地


- 座標 $(4, 4)$: 最も状態価値が高いグリッド
- 座標 $(4, 0)$: 最も状態価値が低いグリッド

及び、時間制約

- 時間制約なし ($T_{arvl} = \infty$)
- $T_{arvl} = 4$ (最短経路のみ), 7, 10, 15, 20



(a) 報酬関数



(b) 状態価値関数

Figure 3.3: 設定値から計算される報酬関数と状態価値関数

の条件の下で実験を行った。

始めに、目的地に時刻 t までに到着した割合を到着率と定義し、時間制約間での到着率の違いを比較する。到着率関数は、シグモイド曲線のような特徴的な S 字型の曲線を描くことが期待される。極端な例として、最短経路しか通らない $T_{arvl} = 4$ の場合、到着率関数は Heaviside ステップ関数のようになる。

実験で得られた目的地への到着率を図 6 に示す。図 6a の場合、目的地は状態価値関数の値が最も高いため、制約がなくても到着率は 0.89 となった。時空間制約がある場合には、目的地指向の行動により、時間制約よりも早く目的地に到着するという結果が得られた。一方、図 6b の場合、目的地は状態価値関数の値が最も低

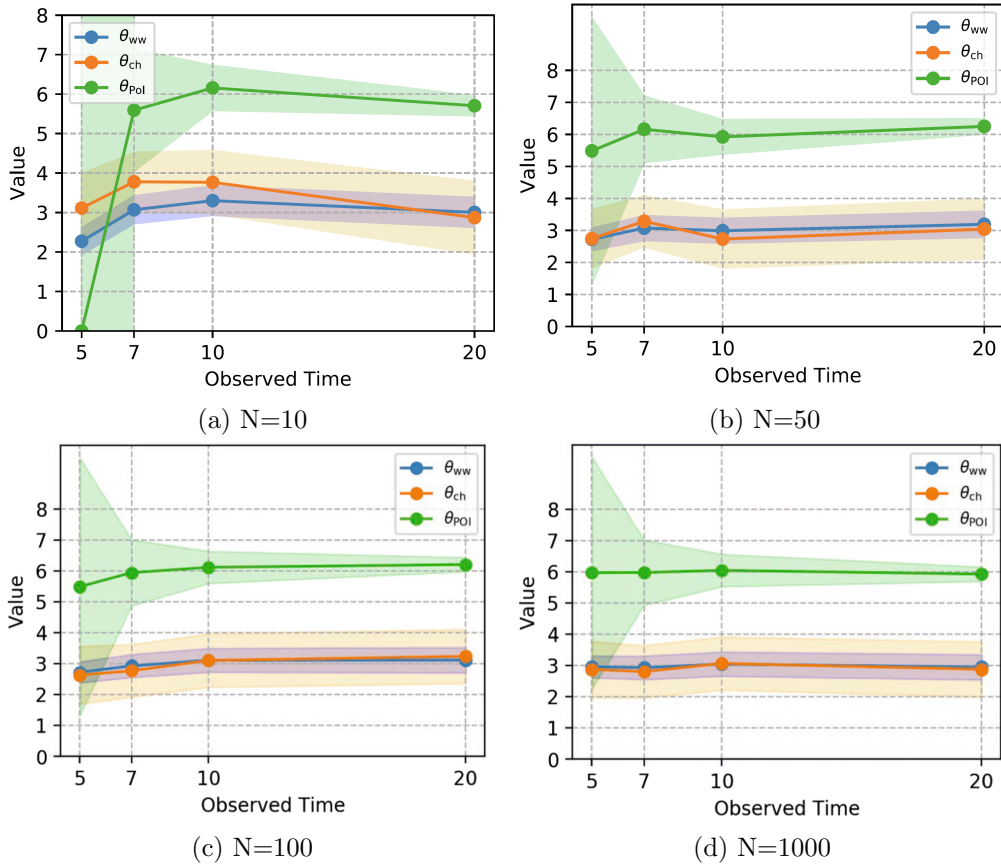



Figure 3.4: 推定結果の検証

いため、制約がない場合には到着率はほぼ0のままであるが、時空間制約がある場合には、目的地に到着時間制約丁度に到着する散策型の行動が生成された。


以下では、時間的制約が軌跡生成に与える影響を視覚化し、時間的な余裕の増加によってどのような種類の軌跡が生成されるかを調べる。Figure 3.6 と Figure 3.7 は、それぞれ座標 (4, 4) と (4, 0) を目的地とする軌跡の比較である。ここで比較する時間制約は、 $T_{arvl} = 4, 7, 15$ の3種類である。図中のリンクの太さは、状態遷移確率の時間的な累積和を表し、ノードの大きさは滞在確率の時間的な累積和を表している。

Figure 3.6a の場合、目的地に到着する解が1つしかないため、目的地に直接向かう軌跡が生成される。一方で Figure 3.7a の場合、複数の最短経路が存在するが、最も報酬の高い経路が最も確率の高い経路として生成されている。 $T_{arvl} = 7$ の場合は、時間的な余裕が大きくなることで、様々な軌跡が生成されることが確認できる。Figure 3.6b と Figure 3.7b の違いは、Figure 3.6b では目的地指向型の行動（時間制限よりも早く到着する）であるのに対し、Figure 3.7b では初期位置での滞在行動が見られる。時間的な余裕がさらに大きくなった場合、Figure 3.6c は目的地指向型の行動（Figure 3.6b のように目的地に向かって報酬を得る）を示しているが、Figure 3.7c はより多くの報酬を得るために大きく迂回する軌道を生成している。

本節の数値実験により、目的地での報酬の大きさに応じて、生成される軌道の種類が異なることが明らかになった。目的地の報酬が高い場合には目的地指向型の行動が生成され、目的地での報酬が低い場合には、途中で高い報酬を得るための散策型の行動が生成される。




(a) 座標 (4,4)

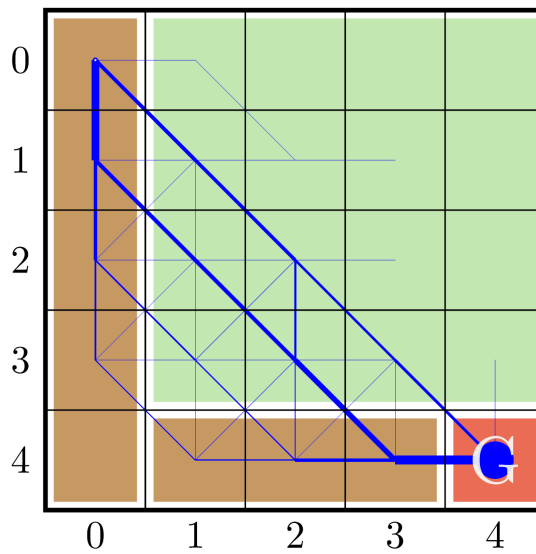


(b) 座標 (4,0)


Figure 3.5: 目的地に対する到着率



(a) $T_{\text{arvl}} = 4$




(b) $T_{\text{arvl}} = 7$

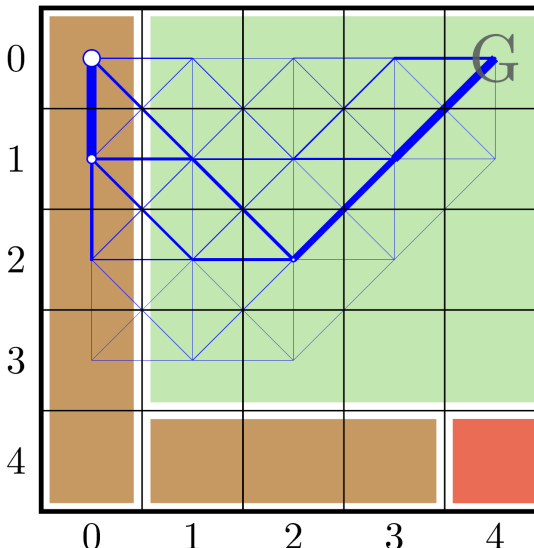


(c) $T_{\text{arvl}} = 15$


Figure 3.6: 目的地を座標 (4,4) に設定した場合の生成軌跡の比較



(a) $T_{arvl} = 4$



(b) $T_{arvl} = 7$



(c) $T_{arvl} = 15$

Figure 3.7: 目的地を座標 (4,0) に設定した場合の生成軌跡の比較

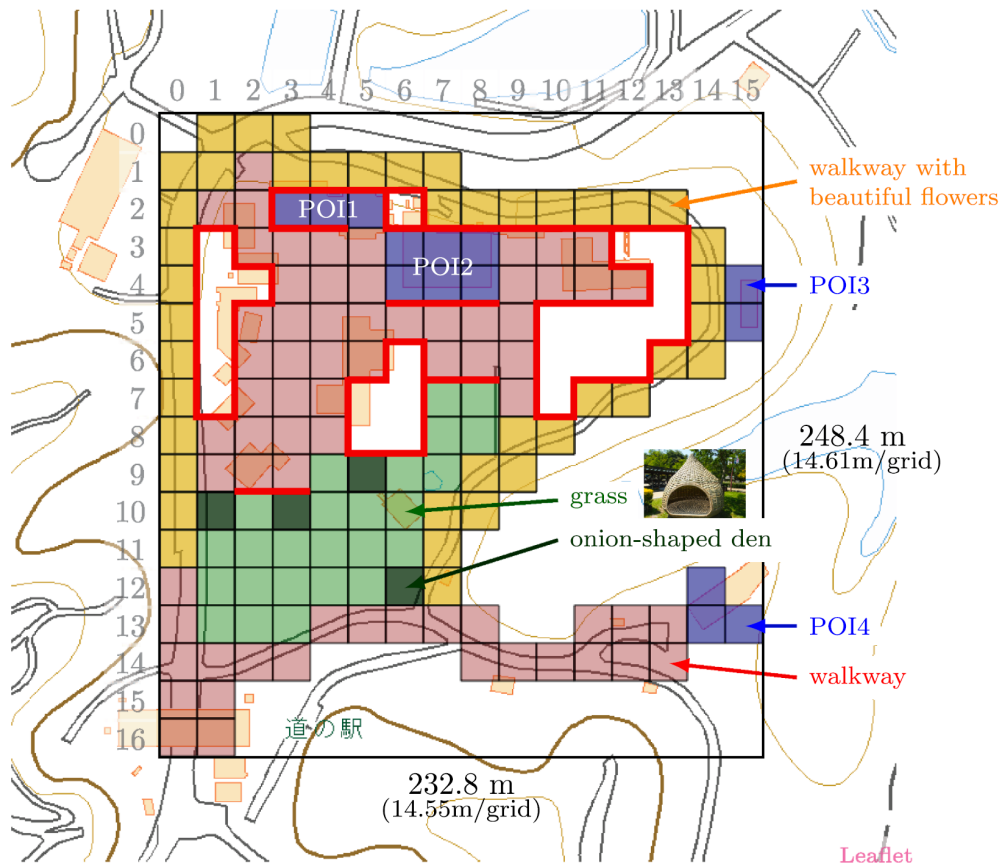


Figure 3.8: 丹後王国を模擬した環境での実験（地図は国土地理院発行のデジタルマップ2500を使用）

3.4.2 現実を模擬した環境での実験

本節では、より複雑で現実的な設定において検証実験を行い、提案モデルの特性を明らかにする。

3.4.2.1 実験設定

より現実的な環境で検証を行うため、具体的な施設環境を選定し、モデル化した。本研究では、西日本最大級の道の駅である「丹後王国¹」を対象とした。丹後王国は、約34haの広大な敷地を持ち、園内にはレストランやホテル、ゴーカート、動物広場など様々な施設を持ち、子供から大人まで楽しめる屋外施設である。

実験では、Figure 3.8に示す東西約230m、南北約250mの範囲を対象とし、16×17のグリッドに離散化を行った。各グリッドの大きさは一辺が約14.5mとなっている。そのうち、従業員の仕事場や畑、山の斜面など、訪問者が立ち入ることができない場所を除いたグリッドの数は152となった。また、壁などの障害物によって歩行者が隣のグリッドに移動できないグリッドを、図中の赤線で示すように設定した。

実験環境は、主に歩道、芝生、POIで構成される。歩道の一部には花が咲いており、その近くを通ることで高い効用が得られると仮定した。芝生の一部には図中に示されるような玉ねぎの形をした休憩スペースがあり、これも考慮している。また、丹後王国にある多くのPOIのうち、本節では単純化のために図中に示す4つのPOIのみを対象とした。Table 3.1に検討したすべての特徴と、パラメータの設定値を示す。

¹<http://tango-kingdom-howto.com/en/about/index.html>.

Table 3.1: 特徴とパラメータ設定値

Features	Feature symbols	Feature types	Parameter symbols	Parameter values
歩道	f_{ww}	ダミー	θ_{ww}	0.2
芝生	f_{gr}	ダミー	θ_{gr}	0
花	f_{flw}	距離減衰	θ_{flw}	0.8
玉ねぎ型休憩 スペース	f_{den}	設置数	θ_{den}	0.2
POI1	f_{POI1}	ダミー	θ_{POI1}	2.5
POI2	f_{POI2}	ダミー	θ_{POI2}	2.0
POI3	f_{POI3}	ダミー	θ_{POI3}	3.0
POI4	f_{POI4}	ダミー	θ_{POI4}	3.5

ここでは、実験で考慮した特徴量の詳細について説明する。歩道、芝生、POIの特徴量をそれぞれ f_{ww} , f_{gr} , f_{POI1} , f_{POI2} , f_{POI3} , f_{POI4} と表記する。歩道、芝生、POIは、それぞれがグリッドに存在するかどうかを表すダミー変数として扱う、すなわち、 $f_{ww}, f_{gr}, f_{POI1}, f_{POI2}, f_{POI3}, f_{POI4} \in \{0, 1\}$ である。歩道、芝生、POIの間には排他的な関係がある、すなわち、 $f_{ww} + f_{gr} + f_{POI1} + f_{POI2} + f_{POI3} + f_{POI4} = 1$ である。この依存関係より、推定すべきパラメータは、この6つの特徴のうちの5つとなる。ここでは芝生のパラメータ値を0に設定し、芝生以外のパラメータの推定を行う。また、玉ねぎ型の休憩スペースから得られる報酬は、グリッド内の休憩スペースの設置数に比例すると仮定した。加えて、花は、遠くからでも見て楽しむことで報酬が得られると仮定し、 $\exp\{-0.2 * \min |d(s, s_{flower})|\}$ で表される距離減衰関数を用いた。ただし、障害物によって花が見えない場合は、効用が得られないと仮定した。前回の実験と同様に、割引率は0.9と設定した。パラメータは人為的に設定したものであり、その値はTable 3.1に示される通りである。設定されたパラメータ値をもとに計算された報酬関数と状態値関数をFigure 3.9に示す。

上記の設定で1000本の軌跡を生成し、その1000本の人工的な軌跡を観測値としてパラメータが再現できるかどうか検証を行った。軌跡の観測時間は50に設定した。軌跡の初期位置は北と南の2か所においてそれぞれ20%と80%の割合で乱数を用いて生成した。検証テストで収集した軌跡をFigure 3.10に示す。

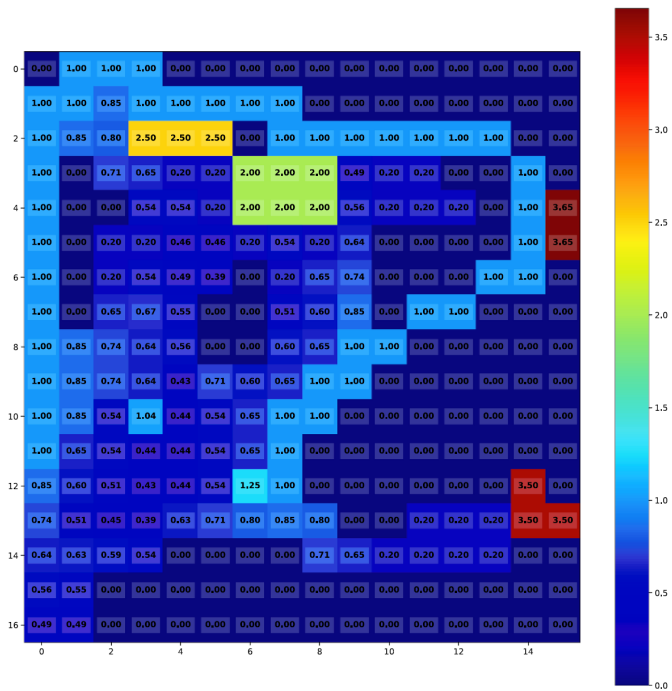
3.4.2.2 推定結果の検証

1000件の人工軌跡をもとにパラメータ推定を行い、設定したパラメータが再現できるかどうかを検証した。推定されたパラメータとその標準誤差は、Table 3.2に示すとおりである。このテストでは、複雑な例でもモデルが良好な推定ができることが確認された。


3.4.2.3 時空間制約下の生成軌跡の比較

本節では、いくつかの時空間制約の下で生成された軌道の比較を行い、提案モデルの特徴を調べる。使用するパラメータは、Table 3.2に示す設定値に基づいている。ここでは、初期位置を施設の北西部に位置する座標(1,0)とし、2つの目的地、座標(6,12)と(9,9)を設定した。比較を行う到着時間制約は、 $T_{arvl} = 13, 20, 50, 100$ で、 $T_{arvl} = 13$ は最短経路のみが許容される。

結果をFigure 3.11及び、Figure 3.12に示す。いずれの場合も、 $T_{arvl} = 13$ の場合は最短経路しか認められていないため、1つの経路しか確認することができないが(Figure 3.11a, 3.12a)、到着時間の制約が大きくなると、別の経路を取ることができるようになる。Figure 3.11bでは、花のある歩道を通る西側の迂回路が生成されている。一方、Figure 3.12bでは、途中で北と南の2種類の道を通って



(a) 報酬関数



(b) 状態価値関数

Figure 3.9: 設定値から計算される報酬関数と状態価値関数




Figure 3.10: 検証実験用に生成した軌跡（地図は国土地理院発行のデジタルマップ 2500 を使用）

Table 3.2: 推定されたパラメータと標準誤差

Features	Setting values	Estimated values	Standard errors
歩道	0.2	0.206	0.330
芝生	0	-	-
花	0.8	0.778	0.354
玉ねぎ型休憩スペース	0.2	0.213	0.322
POI1	2.5	2.469	0.661
POI2	2.0	1.981	0.265
POI3	3.0	3.008	0.921
POI4	3.5	3.485	0.900

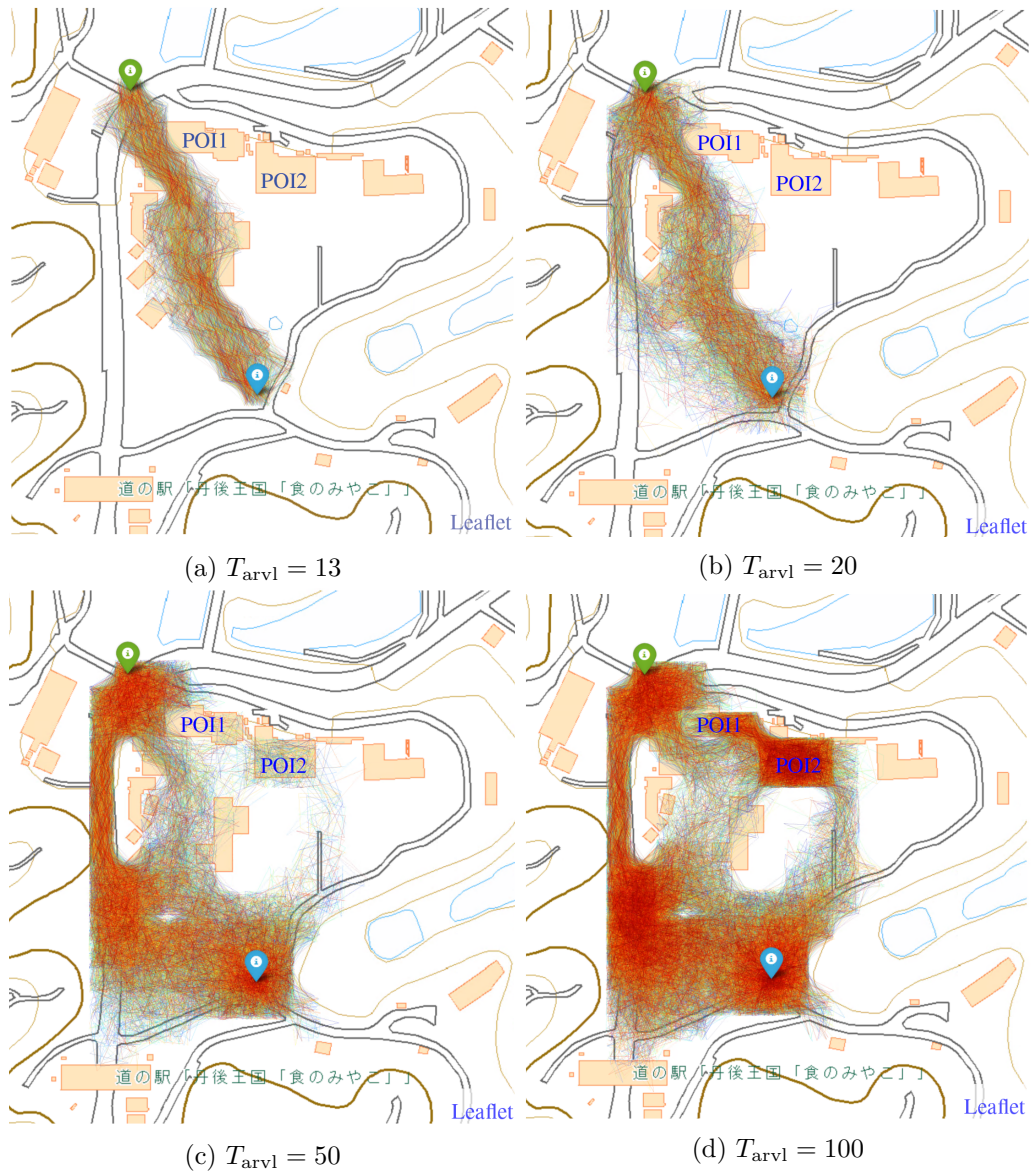


Figure 3.11: 目的地を座標 (6, 12) とし、到着時間制約を変えて生成した軌跡の比較 (地図は国土地理院発行のデジタルマップ 2500 を使用)

いる。さらに、到着時間の制約が大きくなると、どちらのケースでも経路が多様化し、POI1 や POI2 などの高い報酬の得られるエリアでの滞在を含む経路が増えていく。

以上のことから、より複雑で現実的な実験環境では、迂回や滞在を含む様々な軌跡が生成されることが確認された。

3.5 まとめ

本章では、任意の POI の空間分布に対して様々な軌跡を生成するために、2 段階のアプローチを提案した。第一段階では、逆強化学習によって POI の報酬関数と確率の方策を推定し、第二段階では、与えられた目的地と到着時間の制約の下で軌跡を生成する。本手法は、逆強化学習の枠組みを拡張して、様々な軌跡を生成するものである。本章では、2 種類の環境を対象に、目的地と到着時間の制約の下で、目的地指向型の行動だけでなく、迂回や滞在をする行動を生成することを数値的に示した。

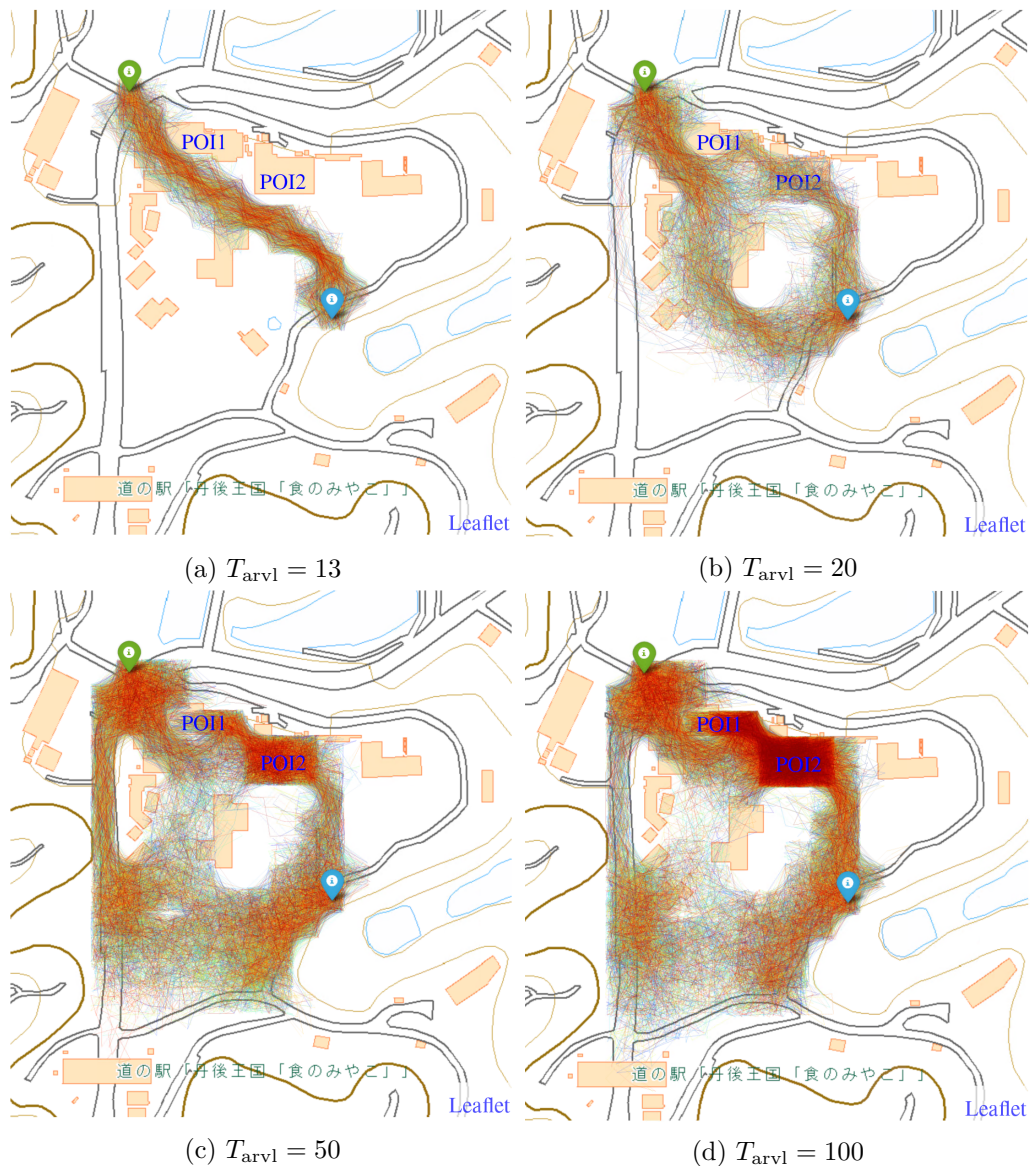


Figure 3.12: 目的地を座標(9,9)とし, 到着時間制約を変えて生成した軌跡の比較 (地図は国土地理院発行のデジタルマップ 2500 を使用)

本章の方法の課題として, 目的地と到着時間の制約を決定する方法を示していないことが挙げられる. 目的地の決定と到着時刻の決定には, 異なるレベルの意思決定が必要となるため, この問題は困難である. 軌跡上の効用が目的地の決定に影響を与え, 目的地の効用が軌跡の決定に影響を与えるという, 異なるレベルの意思決定の相互依存関係がこの問題を難しくしている. この問題を解決するための有望なアプローチの1つは, 動的活動スケジューリングモデルを使用することである [14]. 活動を逐次的に選択することで, 問題がより簡単になる可能性がある. 続く, 第4章では動的活動スケジューリングモデルによる活動選択と活動時間配分の意思決定行動のモデリングを行う.

Chapter 4

歩行者の活動スケジューリングモデル

4.1 はじめに

第3章では、歩行者の Tactical なレベルの意思決定、とりわけ行動軌跡に焦点を当てたモデル化を行った。具体的には、一般的に用いられているような目的地指向型の行動軌跡のみならず、迂回や滞在も含むような様々な行動軌跡の表現が可能なモデルを提案した。また、移動の正の効用と時空間制約によって散策的な行動が生成できることを数値実験により示した。しかしながら、このモデルでは目的地や到着時間の制約を決定することができないため、別途、これらを決定するモデルが必要となる課題があった。そこで、本章では、歩行者の活動スケジューリングに着目したモデル化を行う。

歩行者の活動スケジューリング行動を理解することは、街路などの都市空間の商業的価値を高めるために非常に重要である。これは、活動のスケジューリング行動が活動の選択のみならず、活動時間の配分（滞在）も含んでおり、これらがまちの活性度へ大きく影響を与えると考えられるからである。活動スケジューリングモデルは、予め決められたルールに基づいてアクティビティを決定するルールベースのモデルと、効用最大化の概念に基づいて活動を決定する効用最大化モデルの2種類に大別できる [71]。効用最大化モデルはミクロ経済学に基づいており、歩行者モデルに関わらず、数学的な厳密さから一般的なアクティビティベースのモデルに最も適している。効用最大化モデルに基づく活動スケジューリングモデルの応用例としては、Nested logit モデル ベースの活動選択モデル [36] や動的活動選択モデル [38, 37] などが挙げられる。

歩行者の活動選択は明示的に行われない場合がある。この特徴は、歩くという行為が活動の目的になっている場合や、買い物や観光などの活動に見られる特徴である [72]。このような行動は、人々があらかじめ目的地を決めずに旅程を組み、その途中で魅力的な場所を探索する行動として理解できる [11]。このような歩行者の行動を記述する数少ない試みとして、目的地の選択、経路の選択、都心のショッピングエリアでの衝動的な立ち寄りを組み合わせたモデルがある [10]。また、ランダム効果を考慮した動的モデルを行動選択に適用すると、多項ロジットモデルなどの静的モデルよりも優れた結果が得られることが最近のいくつかの研究で示されている [38, 37]。しかしながら、これらの研究では活動の順番を決めることはできても、活動時間の配分については考慮されていない。本章では、歩行者の活動スケジューリングに関する問題を解決するために、動的活動スケジューリングモデル [14] の適用を試みる。特に、このモデルでは、移動時間のように必要な時間を時間配分で保証することが困難であった。そこで、提案モデルでは、この最小必要時間を扱うことができるよう拡張を行う。

一般的に、歩行者ネットワークは道路ネットワークのように容易に利用できず、これも歩行者の活動を扱う上での大きな問題となっている [42]。また、本研究で検討する屋外環境には、芝生広場やプラザなどのオープンスペースがあり、これらの空間を従来のリンク表現で表現することは困難である。そこで、提案手法では、詳

細な空間解像度のグリッド（1マス15mグリッド，10秒サンプリング）を用いた空間表現を採用することで，オープンスペースの表現を可能にしている．さらに，前章で説明した行動軌跡の生成モデルと組み合わせることにより，前述の歩行者特有の行動を適切に表現することができると考えられる．

本章における貢献を以下にまとめる．

- 歩行者の複雑な行動を表現するため，GPSデータを2次元のグリッドベースの空間表現に高空間分解能で離散化する処理方法を提案する．
- 動的活動スケジューリングモデルを用いて，屋外施設での活動選択と時間配分に基づく来訪者の意思決定行動を明らかにする．

本章で提案するモデルは，GPSデータに基づいて来場者の行動選択や時間配分に関する意思決定行動を明らかにすることで，魅力的で賑わいのある空間を創出するデータ駆動型の空間デザインに応用できると考えられる．

本章の構成は以下の通りである．第2節では，データ取得及び処理方法，活動スケジューリングモデルについて詳述する．続く第3節では，結果と考察について述べ，最後に第4節にて本章を総括し，課題と展望を述べる．

4.2 データと方法

本節では，まず，GPSデータの取得実験について説明する．その後，提案するデータ処理方法について詳細に説明する．具体的には，ノイズや欠損のあるGPSデータを15mという高い空間分解能で2次元のグリッドベースの空間表現に離散化する処理方法を提案する．そして，離散化されたデータからPOIでの滞在時間に関する情報を抽出し，この情報に基づき，動的活動スケジューリングモデルを推定する．

4.2.1 データ取得

本研究では，西日本最大級の道の駅である「丹後王国」を対象とする．丹後王国の敷地面積は約34haである．園内にはレストランやゴーカート，動物広場など様々な施設があり，子供から大人まで楽しめる屋外施設となっている．

データの収集は2015年8月22日と8月23日の計2日間に渡って行われた．実験は，丹後王国を訪れた人たちの協力の下，Bluetooth Low Energy (BLE) 送信機とGPSロガーを被験者に配布し，本来の予定通りに園内を自由に散策してもらった．加えて，簡単なアンケートも配布し，代表者の年齢や性別，グループ構成，訪問回数，居住地，訪問目的などの調査を行った．実験では，2日間で合計277組の来場者からデータを取得できた．

今回使用したGPSロガーには，Mobile Action Technologies社製の「i-gotUgt-600」を用いた．このGPSロガーは，SiRF IVチップセットを採用し，水平方向の位置精度が2.5m (2D RMS¹)である．BLE受信機は，園内の計12箇所に設置されており，BLE送信機が発する電波を受信すると，受信機の位置，時刻，筐体識別番号，電波強度がサーバーに記録される．

BLEとGPSの比較分析 [73] では，BLEとGPSの両方が来場者の活動・移動行動に関する正確な情報を取得できたとした一方で，障害物のない広い空間など特定の条件ではBLEの信号がより遠くまで届くため，誤検知や精度の低下が見られたとしている．GPSを用いる提案手法では，そのような場所でも優れた効果を発揮するとともに，建物内など観測記録の取得が困難な状況でも，全体の軌跡の情報をもとに滞在情報を抽出することができる．次節では，データの処理方法について詳細の説明を行う．

¹distance root mean square の略

4.2.2 データ処理方法

本節では、GPS データを時空間的に離散化する方法と、エピソードと呼ばれる滞在に関する情報を抽出する方法について説明する。GPS データの時空間離散化は、以下の2つのステップで行われる。

1. デノイジングとスムージング
2. グリッドへの割り当て

次節では、これらのステップについて詳細を説明する。

4.2.2.1 デノイジングとスムージング

GPS データを取り扱うにあたり、以下に示す3つの問題がある。

- 屋内や山間部など特定の場所での大きなノイズ
- GPS 特有の測定誤差
- データの欠損、または等間隔でないデータ

本研究では、これらの問題を解決するために、近年でも様々な研究 [74, 75] に適用されており、固定区間平滑化の代表的な手法の一つである RTS (Rauch-Tung-Striebal) スムーザーを使用する [76]。ある時点 k における推定値 \mathbf{x}_k の平滑化分布 $p(\mathbf{x}_k|\mathbf{y}_{1:T})$ は、観測値を \mathbf{y}_k 、データの最終時点 T までの観測値を $\mathbf{y}_{1:T}$ を用いて


$$p(\mathbf{x}_k|\mathbf{y}_{1:T}) = p(\mathbf{x}_k|\mathbf{y}_{1:k}) \int \left[\frac{p(\mathbf{x}_{k+1}|\mathbf{x}_k)p(\mathbf{x}_{k+1}|\mathbf{y}_{1:T})}{p(\mathbf{x}_{k+1}|\mathbf{y}_{1:k})} \right] d\mathbf{x}_{k+1}. \quad (4.1)$$

と表すことができる。したがって、全ての予測ステップ $p(\mathbf{x}_{k+1}|\mathbf{y}_{1:k})$ 及び、フィルタステップ $p(\mathbf{x}_k|\mathbf{y}_{1:k})$ を計算した後に、 $p(\mathbf{x}_T|\mathbf{y}_{1:T})$ を出発点として、後ろ向きに遡りながら平滑化分布を求めることができる。本研究では、以下に示す単純な物理システムをシステムモデルとして用いる。


$$\begin{pmatrix} x_k \\ \dot{x}_k \\ \ddot{x}_k \\ y_k \\ \dot{y}_k \\ \ddot{y}_k \end{pmatrix} = \begin{pmatrix} 1 & \Delta t & \Delta t^2/2 & 0 & 0 & 0 \\ 0 & 1 & \Delta t & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & \Delta t & \Delta t^2/2 \\ 0 & 0 & 0 & 0 & 1 & \Delta t \\ 0 & 0 & 0 & 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} x_{k-1} \\ \dot{x}_{k-1} \\ \ddot{x}_{k-1} \\ y_{k-1} \\ \dot{y}_{k-1} \\ \ddot{y}_{k-1} \end{pmatrix} \quad (4.2)$$

ここで、 x と y はそれぞれ GPS の経度と緯度の推定値であり、 Δt はシステムモデルで想定されるサンプリングレートを示す。また、GPS のサンプリングレートとは別に、 Δt を設定することができる。データ間隔が不規則な場合や、データが欠落している場合 (Figure 4.6) でも、間隔を短く指定することで、等間隔でリサンプリングされた推定値を得ることができる。今回取得したデータの場合、5秒のサンプリング間隔でデータを取得しているが、データによってはデータ欠損などの理由で4秒や30秒の間隔になることもある。平滑化処理を行うことで、5秒や10秒などの所望の間隔でデータを取得することができる。

上記の平滑化手法は、GPS 固有の測定誤差を解消することはできるが、屋内や山間部など特定の場所で発生する大きなノイズには使用できない。さらに、欠損データの時間間隔が大きい場合 (例えば、1分)、推定値が非常に不正確になる可能性がある。そこで、平滑化処理の前に大きな外れ値を除去し、データの補間を行った (Figure 4.2)。前後のデータポイントと比較して移動速度が速い (10km/h 以上) データポイントや、前後のデータポイントから 30m 以上移動したデータポイント



(a) 処理前の GPS データ



(b) スムージング処理後のデータ

Figure 4.1: スムージング処理の概念図

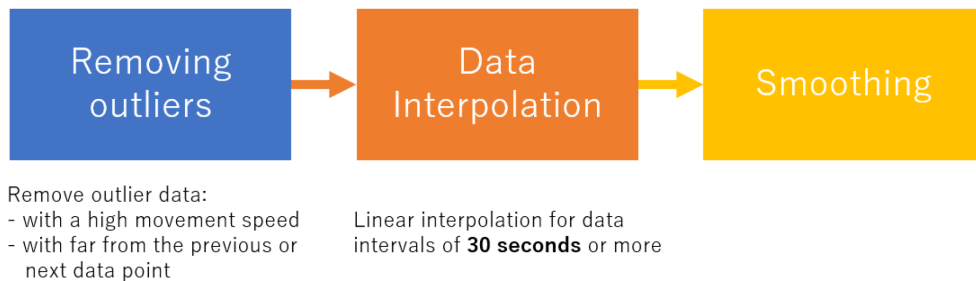


Figure 4.2: スムージング処理の手順

に対して、異常値除去処理を行う。その後、30 秒以上のデータ間隔で線形補間を行う。スムージング処理の適用例を Figure 4.3 に示す。Figure 4.3 の赤線で示した平滑化処理後のデータを見ると、大きな誤差があることが分かる。大きな外れ値が取り除かれ、同じ場所（図では中央の右側）に留まっていることが確認できる。

4.2.2.2 離散化グリッドへの割り当て

本節では、離散化されたグリッドへ割り当てる方法について説明を行う。離散化されたグリッドベースの空間表現には、Web 地図アプリケーションのデファクトスタンダードである球面メルカトル図法（Web メルカトル、Google Web メルカトルとも呼ばれる）に基づくピクセル座標を用いる。

球面メルカトル図法による地図タイリングシステムでは、南北緯 85.0511 度までを一辺 256 ピクセルの正方形の画像で表現する（ズームレベル 0）。ズームレベルを

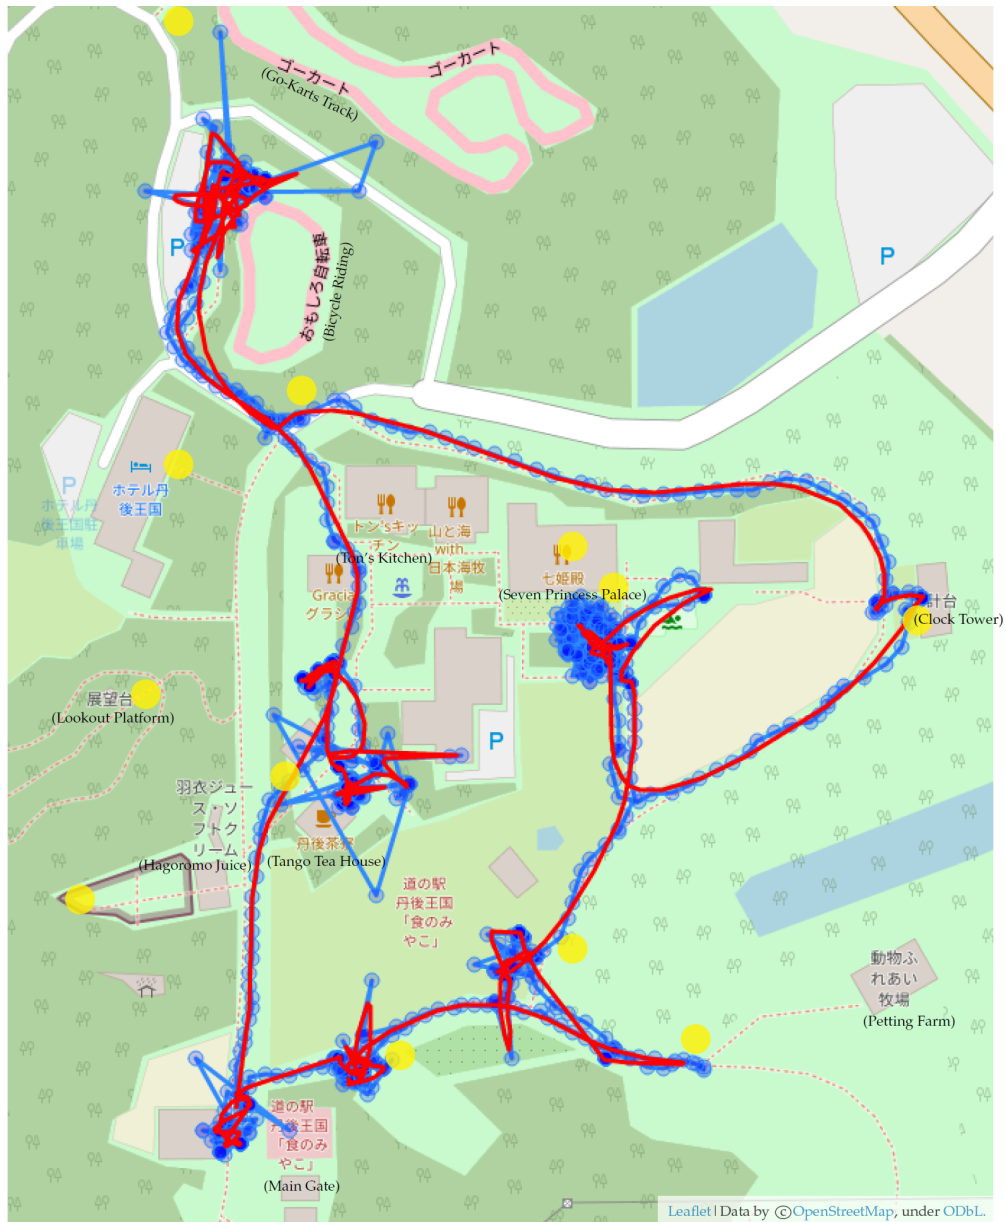


Figure 4.3: 平滑化処理の適用例 (黄色：BLE 受信機, 青：処理前の GPS データ, 赤：スムージング処理後のデータ)

1段階上げると、同じエリアの世界地図が2倍の大きさの正方形の画像で表現される。ズームレベル1の地図は、一辺が256ピクセルの正方形の画像4枚で表現され、この世界地図を分割した画像をタイルと呼ぶ。このタイルに座標番号 (x, y) を割り当てることで、ズームレベル z での指定位置を含むタイルを (x, y, z) と一意に定義することができる。球面メルカトル図法を用いた空間表現の例を Figure 4.4 に示す。ズームレベル z のピクセル数は $2^{z+8} \times 2^{z+8}$ であり、このピクセル座標を用いて離散化された空間表現が生成される。

離散化するグリッドの大きさは、施設内の建物の大きさやデータの精度を考慮し、約15mとした。このグリッドサイズに適したサンプリングレートにリサンプリングすることにより、マルコフ決定過程 (MDP) などの逐次的意思決定過程のモデルの適用が容易になる。

次に、サンプリングレートを決定するため、サンプリングレートをそれぞれ5秒、10秒、15秒に変更し、同じグリッドに留まる確率、隣接する8グリッドに遷移する確率、2グリッド先の16グリッドに遷移する確率を算出した。理想的には、

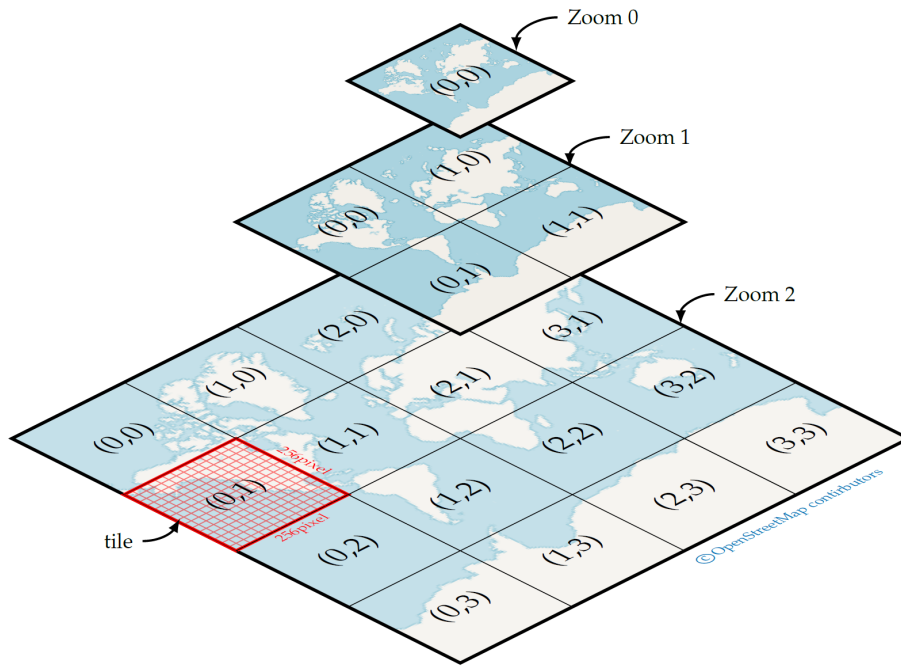


Figure 4.4: 球面メルカトル法による空間表現





Figure 4.5: サンプリングレートと遷移確率の関係


隣接するグリッドへの遷移確率を最大にしつつ、2つ先のグリッドへの遷移確率を最小にするのが良いと考えられる。これにより、経路選択のためのグリッドベースの表現（第3章の方法や文献 [43]）との整合性が確保される。サンプリングレートを10秒にした場合、隣接するグリッドへの遷移確率が約23%になるのに対し、2つ先のグリッドへの遷移は約0.08%に抑制された（Figure 4.5）。以上の分析から10秒のサンプリングレートを採用し、以下で行う分析に用いることとした。

続いて、リサンプリング後のデータの各位置座標が含まれる数をグリッドごとにカウントし、カウント数の少ないグリッドや、従業員用の敷地や山間地、畑などアクセスができないグリッドを除いたネットワークを作成した。その結果、対象となるグリッドの総数は255個となった（Figure 4.6a）。また、建物の入り口ではない場所など、遷移ができないと考えられる場所については、グリッド間の遷移ができないように設定を行った。例として、Figure 4.6bの黄色の線で示すように、隣接するグリッドでも遷移しないように制限を行った。

しかしながら、リサンプリングされた位置情報をそのままグリッドに割り当て



(a) 対象としたネットワーク (図中の数字が POI 番号)



(b) 遷移できないグリッドの設定例

Figure 4.6: 対象としたネットワーク

るだけでは不十分である。なぜなら、物理的に不可能な軌跡を許容してしまうからである。先に説明したように、ネットワークは物理的に不可能な遷移を除外するように作成されている。各データ点は、この定義されたネットワークに沿って、全体的に尤もらしい系列を見つけることで、適切なグリッドに割り当てることができる。

グリッドの中心位置 \mathbf{x}_i と n 番目のデータの時刻 t における位置 \mathbf{x}_{nt} を用いて、対象とするグリッド i の尤度 $d(\mathbf{x}_i, \mathbf{x}_{nt})$ を

$$d(\mathbf{x}_i, \mathbf{x}_{nt}) = A \cdot \exp\left(-\frac{|\mathbf{x}_i - \mathbf{x}_{nt}|^2}{\sigma^2}\right), \quad (4.3)$$

と表す。ただし、 A は規格化定数、 σ はグリッドサイズの半分に設定した。

求めたいグリッドの系列は、以下の問題を解くことで得られる。

$$\operatorname{argmax} \prod_t d(\mathbf{x}_i, \mathbf{x}_{nt}). \quad (4.4)$$

上式は対数を取っても結果が変わらないので、代わりに次の式を最大化することができる。

$$\operatorname{argmax} \sum_t \log \{d(\mathbf{x}_i, \mathbf{x}_{nt})\}. \quad (4.5)$$

式 (4.3) より、 $\log \{d(\mathbf{x}_i, \mathbf{x}_{nt})\}$ は以下のように求めることができる。

$$\log \{d(\mathbf{x}_i, \mathbf{x}_{nt})\} = -\left\{ \frac{(x_i - x_{nt})^2}{\sigma_x^2} + \frac{(y_i - y_{nt})^2}{\sigma_y^2} \right\}. \quad (4.6)$$

したがって、グリッド間の接続に関するネットワーク制約のもとでは式 (4.6) の中括弧内の二乗和を最小にすることで、対数尤度を最大にするグリッドの系列を得ることができる。

上記の最大化問題は、動的計画法を用いて解くことができる。時刻 t にグリッド i に割り当てられた系列の最大値 $S_t(\mathbf{x}_i)$ は、時刻 $t+1$ にグリッド j に割り当てられた系列の最大値 $S_{t+1}(\mathbf{x}_j)$ を用いて、以下のように記述することができる。

$$S_t(\mathbf{x}_i) = \max [\log \{d(\mathbf{x}_i, \mathbf{x}_{nt})\} + \Delta_{\mathbf{x}_i \mathbf{x}_j} S_{t+1}(\mathbf{x}_j)], \quad (4.7)$$

ここで、 $\Delta_{\mathbf{x}_i \mathbf{x}_j}$ はグリッド i - j 間の接続を表し、以下のように与えられる。

$$\Delta_{\mathbf{x}_i \mathbf{x}_j} = \begin{cases} 1 & \text{if } i-j \text{ is connected} \\ \infty & \text{otherwise} \end{cases}. \quad (4.8)$$

この空間割り当ての方法は、グリッド間の接続の関係性を利用しているため、1ステップで隣接するグリッドにのみ移動することを保証することができる。このように、2つのグリッドへの遷移が観測された約0.08%のデータに対しても、この空間割り当ての方法を用いることで、隣接するグリッドへの遷移へ補正することができる。空間割り当ての結果を Figure 4.7 に示す。




Figure 4.7: 空間割り当ての結果の例。割り当ての結果は円で表され、円の色は滞在時間を表す。

4.2.2.3 エピソードの抽出

前節では、GPS データから得られた位置情報を離散化するプロセスを説明した。本節では、時空間離散化されたデータから滞在行動を抽出する方法について説明を行う。エピソードは、ある POI での滞在が終了してから次の POI での滞在が終了するまでの時間と定義する。来訪者グループごとのデータは、複数のエピソードから構成される。各エピソードには、目的地である POI までの移動時間も含まれることに注意されたい。エピソードを抽出するためには、対象となる POI を設定する必要がある。本研究では、Table 4.1 に示す 19 の POI を対象とする。表中の番号は Figure 4.6a に示されている番号に対応している。

エピソード抽出の最初のステップは、Figure 4.6a に示した POI 位置への訪問を離散化処理後のデータに基づいて判断することである。その後、POI の位置から外れてもすぐに復帰する滞在を連続する一つの滞在とみなす。上記の処理後に、滞在時間が 3 分以内の滞在が削除される。Figure 4.8 に上記の処理で得られた結果の一例を示す (-1 は POI 以外の位置を示す)。灰色の線が元の POI 滞在を、橙色の線が処理後の POI 滞在を示している。さらに、定義にしたがい、ある滞在が終了してから次の滞在が終了するまでの時間をエピソードとして抽出する。エピソード 1 のように、同じ POI を再び訪問するエピソードは、1 つのエピソードにまとめられる。この例では、合計 5 つのエピソードが抽出されている。

Table 4.1: 対象の POI

No.	Name	Types	Description
0	昆虫館	Activities	世界中のクワガタやカブトムシの展示
1	ゴーカート	Attractions	
2	おもしろ自転車	Attractions	ユニークな自転車
3	小町スコーラ	Activities	パンやアイスクリームの手作り体験教室
4	西利	Shopping	漬物屋
5	安寿ベーカリー	Shopping	ベーカリーショップ
6	Gracia	Foods	レストラン
7	丹後茶寮	Foods	和カフェ
8	見晴台	Activities	
9	羽衣ジュース	Foods	ソフトクリームとジュースバー
10	小さな動物園	Activities	羊やヤギ, ウサギ, リクガメとのふれあい
11	トン's キッチン	Foods	BBQ レストラン
12	七姫殿	Foods	フードコート
13	インモーション	Attractions	次世代型立乗電動モビリティの試乗体験
14	アスレチック広場	Attractions	子ども向けアスレチック広場
15	時計台	Activities	
16	動物ふれあい広場	Activities	羊やポニーとのふれあい, 乗馬体験
17	芝すべり	Attractions	全長 48 m の芝すべり
18	メインゲート	Shopping	土産店や農産物売りが併設された入口

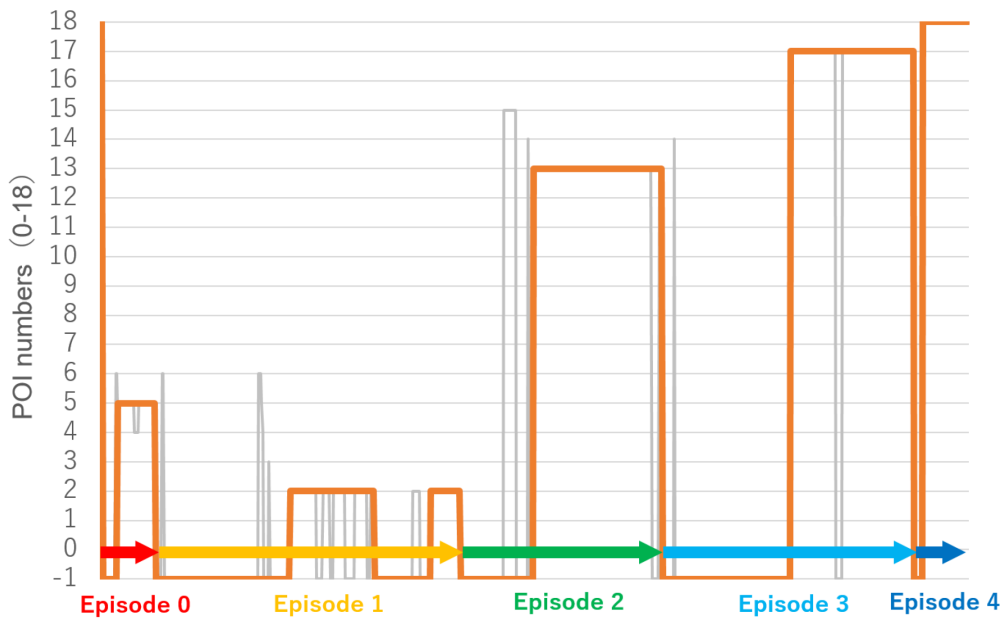


Figure 4.8: エピソードの抽出例

4.2.3 基礎分析

本節では、前節で説明した GPS データに対する前処理の結果について基礎的な分析を行うことでその妥当性を検討する。はじめに、スムージング処理した位置情報から歩行速度を算出し、グループの属性ごとに比較を試みる。次に、前節で抽出したエピソードの情報から各 POI への訪問確率を算出し、アンケートで収集した基本属性や訪問目的などの情報による影響について基礎的な分析を行う。

4.2.3.1 歩行速度

はじめに、スムージング処理を行った位置情報のデータから歩行速度を算出し、アンケートで収集したグループの属性ごとの比較を行う。歩行速度の算出では、エピソード抽出により POI に滞在していると思われるデータを除いた移動中のデータのみを用いて、歩行速度の 90%ile 値、95%ile 値を算出した。さらに、アンケートで収集したグループの属性（代表者の年齢、グループの人数、子どもの数）による歩行速度の違いをそれぞれの属性の平均値を算出し、比較した。

結果を Figure 4.9~4.11 にそれぞれ示す。代表者の年齢別では、20-50 代では歩行速度の違いはほとんど見られなかったが、10 代では速く、60 代以上では遅くなる傾向が見て取れた (Figure 4.9)。グループの人数別では、2-5 人のグループの速度はほとんど変わらなかったが、1 人では速く、6 人以上のグループになると遅くなる傾向が見て取れた (Figure 4.10)。子どもの数別では、それほど大きな違いは見られなかったものの、子どもがいる方が、いない場合に比べて遅くなる傾向が見て取れた (Figure 4.11)。若い世代で歩行速度が速く、高齢世代では遅い傾向や、グループ人数が増えると歩行速度が遅くなる傾向は既存研究 [77, 78] による調査結果とも整合している。今回の結果は、全体でも 0.98 m/s とこれまで報告されている歩行速度（平均 1.34m/s）[79] より遅い結果となったが、余暇目的での歩行や、ショッピングエリアでの歩行速度は遅くなることや [78]、歩行以外のデータも含まれていることがその要因として考えられる。

いずれの属性に関しても歩行速度の 95%ile 値が 1.2m/s 以下におさまる程度であり、したがって、15m グリッドに対して 10 秒サンプリングに設定したことはこの結果からも妥当であるということが確認できた。




Figure 4.9: 歩行速度 90%ile 値, 95%ile 値の平均値 (代表者の年齢)




Figure 4.10: 歩行速度 90%ile 値, 95%ile 値の平均値 (グループ人数)




Figure 4.11: 歩行速度 90%ile 値, 95%ile 値の平均値 (子どもの数)

4.2.3.2 POI 訪問確率

ここでは、アンケートで収集した基本属性として子どもの有無、京都府在住か否かの2つについて、また、訪問目的としてそれぞれレジャー、食事、買い物目的と回答したかどうかについて POI への訪問確率への影響を分析する。

まず初めに、子どもの有無と POI への訪問確率を Figure 4.12 に示す。図に示されるように子どもの有無は POI への訪問確率へ大きな影響を与えている様子が確認できる。特にゴーカート (POI1)、おもしろ自転車 (POI2)、アスレチック (POI14)、芝すべり (POI17) などのアトラクションの訪問確率が大きく増加する様子が確認できた。また、京都府在住か否か (Figure 4.13) を見ると、子どもの有無ほどの違いは見られないものの、昆虫館 (POI0) の訪問確率は2倍程度、おもしろ自転車 (POI2) や Gracia (POI6) では半分程度となっており、一部の POI で訪問確率に違いが見られた。

続いて、訪問目的と抽出された訪問確率の関係を調べる。まず、レジャー目的と回答したグループについては、子どもの有無と同様にゴーカート (POI1)、おもしろ自転車 (POI2)、アスレチック (POI14)、芝すべり (POI17) などのアトラクションの訪問確率が増加する様子が確認され、整合的な結果が得られていることが確認できた (Figure 4.14)。食事目的と回答したグループについては、レストラン (POI6, POI11) やフードコート (POI12) での訪問確率が2倍程度に増加しており、こちらも回答との整合的な結果が得られていることが確認できた (Figure 4.15)。買い物目的と回答したグループについては、西利 (POI4) や安寿ベーカリー (POI5)、メインゲート (POI18) において訪問確率に大きな差は見られなかった (Figure 4.16)。この理由としては、西利や安寿ベーカリーはそれぞれ漬物やパンの専門的な店であり対象者が限定されること、土産店などがあるメインゲートは買物の有無に関わらず必ず立ち寄る場所であることが原因と考えられる。

ここでは、アンケートの回答と GPS データから抽出した POI の訪問確率の関係を見てきた。結果は、買い物目的については大きな違いが確認できなかったものの、残りの基本属性や訪問目的は訪問確率に大きく影響していることが確認され、前節で提案した情報の抽出方法の妥当性が確認できた。次節では、活動スケジュールリングモデルについて詳細を説明する。




Figure 4.12: POI への訪問確率 (子どもの有無)




Figure 4.13: POI への訪問確率 (京都府在住)




Figure 4.14: POI への訪問確率 (レジャー目的)




Figure 4.15: POI への訪問確率 (食事目的)




Figure 4.16: POI への訪問確率 (買い物目的)

4.2.4 活動スケジュールリングモデル

本節では、動的活動スケジュールリングモデルを詳細に説明し、その後、モデルの拡張について説明する。動的活動スケジュールリングモデルは、活動選択モデルと活動時間配分モデルの同時確率を計算する離散-連続モデルである。スケジュールリングプロセスをモデル化し、動的なスケジュールリングプロセスから活動パターンを求める。

活動選択モデルは、一般的な多項ロジットモデルを用いた離散選択モデルである。活動 j の決定論的効用を V_j とし、その選択確率は次のように表される。

$$\Pr(\varepsilon_n < (V_j - V_n + \varepsilon_j)) = \frac{\exp(V_j)}{\exp(V_j) + \sum_{n \neq j} \exp(V_n)}. \quad (4.9)$$

活動時間配分モデルでは、実行する活動 j と、複合財として考える残りの全ての活動 c との間の配分を考える。活動の時間配分の確率は、以下の累積分布関数で表される。

$$\Pr(\varepsilon'_c < (V'_j - V'_c + \varepsilon'_j)) = \left[1 + \exp\left(\frac{-(V'_c - V'_j)}{\sigma}\right) \right]^{-1}, \quad (4.10)$$

ここで、 σ はスケールパラメータであり、 V'_j と V'_c は、それぞれ活動 j と複合財 c の効用を表す。 V'_j と V'_c は、それぞれ以下の式で与えられる。

$$V'_j = \psi_j z_j + (\alpha_j - 1) \ln(t_j), \quad (4.11)$$

$$V'_c = (\alpha_c - 1) \ln(t_c), \quad (4.12)$$

ここで、 z_j は説明変数、 ψ_j はその係数、 α_j と α_c はそれぞれ活動 j と複合財 c の飽和パラメータで、時間に関する限界効用の逓減を表す。このモデルでは、時間 t_j が活動 j に割り当てられる確率は次のように表される。

$$\Pr(t = t_j) = \left(\frac{1 - \alpha_j}{t_j} + \frac{1 - \alpha_c}{t_c} \right) \cdot \frac{1}{\sigma} \exp\left(\frac{-(V'_c - V'_j)}{\sigma}\right) \cdot \left[1 + \exp\left(\frac{-(V'_c - V'_j)}{\sigma}\right) \right]^{-2}, \quad (4.13)$$

Habib (2011) の活動スケジュールリングモデルでは、活動選択と活動時間配分の同時確率は、以下に与えられる二変量正規分布で表される。

$$\Pr(t = t_j \cap \varepsilon \leq J_1(\varepsilon_j)), \quad (4.14)$$

$$= \Pr(t = t_j) \times \Phi\left(\frac{J_1(\varepsilon_j) - \rho J_2(\varepsilon'_j)}{\sqrt{1 - \rho^2}}\right), \quad (4.15)$$

ここで、 Φ は標準正規分布の累積分布関数であり、 $J_1(\varepsilon_j)$ と $J_2(\varepsilon'_j)$ は標準正規分布の累積分布の逆関数である Φ^{-1} を介して標準正規分布の誤差分布に変換を行う。

$$J_1(\varepsilon_j) = \Phi^{-1}[(\varepsilon_n - \varepsilon_j) < (V_j - V_n)] \quad (4.16)$$

$$J_2(\varepsilon'_j) = \Phi^{-1}[(\varepsilon'_j - \varepsilon'_c) < (V'_c - V'_j)]. \quad (4.17)$$

活動選択と活動時間配分の相関関係は、相関係数 ρ で表される。

本研究では、活動スケジューリングモデルを推定するための各 POI の活動時間にエピソードという概念を使用している。これは、前の活動が終わってから次の活動が終わるまでの時間を表しており、活動場所までの移動時間も含んでいる、活動場所までの移動時間が含まれているということは、活動時間のなかには、少なくとも 2 つの活動場所間の最短所要時間が含まれる必要がある。そこで、活動場所 i と j の間の最短所要時間を導入し、これを t_{ij} と表記する。このとき、式 (4.13) および式 (4.11) は、以下のように表すことができる。

$$\Pr(t = t_j) = \left(\frac{1 - \alpha_j}{t_j - t_{ij}} + \frac{1 - \alpha_c}{t_c} \right) \cdot \frac{1}{\sigma} \exp \left(\frac{-(V'_c - V'_j)}{\sigma} \right), \quad (4.18)$$

$$\cdot \left[1 + \exp \left(\frac{-(V'_c - V'_j)}{\sigma} \right) \right]^{-2},$$

$$V'_j = \psi_j z_j + (\alpha_j - 1) \ln(t_j - t_{ij}). \quad (4.19)$$

この概念は、Van Nostrand ら (2013) の最小必要時間 (Minimum required time) の概念 [80] と同一の考え方である。

4.3 結果と考察

今回の分析では、GPS データが正確に取得できなかったデータを除き、推定に使用する GPS 観測データは 262 件となった。エピソードの総数は 1042 件となり、1 グループあたりの平均エピソード数は約 4 となった。

推定では、施設での総滞在時間は外生的に与えられると仮定した。また、総滞在時間はデータの開始時刻からデータの終了時刻までの間であるとみなした。

推定は、関連する可能性のあるすべてのパラメータを含んだモデルで開始した。パラメータ推定を行い、 t -値が低いパラメータを削除していった。モデルの適合性の指標として、調整済み尤度比を評価し、その値が最も高いモデルを採用した。初期尤度は、Habib(2011) にならい、ベースライン効用と飽和パラメータを一定としたモデルを用いて計算した。初期のパラメータ数は 478 であったが、最終的なパラメータ数は 102 となった。また、初期尤度は -9990.16、最終尤度は -7489.72 であった。修正済み尤度比は 0.240 となった (Table 4.4)。

以降の節では、推定結果について詳しく説明する。

4.3.1 活動選択モデル

活動選択モデルの推定結果を Table 4.2 に示す。「測定開始からの経過時間の対数」の推定値は、アスレチック広場とメインゲートを除くすべてのパラメータで負の値となった。これは、多くの POI において、滞在の後半になると選択確率が低下することを示している。メインゲートは常に最後の POI である。メインゲートの推定値は、「測定開始からの経過時間の対数」では正 (0.301)、「残り時間の割合」では負 (-3.849) となっており、これらの要素が組み合わさり、時間が総滞在時間に近づくにつれて選択確率が高くなる。これにより時間的圧力が表現され、総合的な結果が得られることが実証された。

時間に関する説明変数の効果を示すために、滞在時間を 3 時間と仮定した場合の効用関数値の変化を Figure 4.17 に示した。メインゲートの効用値は、 $t = 0$ の時点では極めて小さいが、時間の経過とともに増加し、120 分後 (残り時間の 1/3)

Table 4.2: 推定結果 (活動選択モデル)

Variables	Name of POI	Type of POI	POI number	Parameters	t-values
選択肢固有定数 (ASC)					
	見晴台	Activities	8	-0.576	-1.97
エピソード番号					
	ゴーカート	Attractions	1	-0.144	-1.63
	Gracia	Foods	6	0.350	2.29
	羽衣ジュース	Foods	9	-0.236	-1.94
	トン's キッチン	Foods	11	-0.153	-1.77
	アスレチック広場	Attractions	14	-0.113	-1.09
	芝すべり	Attractions	17	0.176	1.56
12-15 時					
	七姫殿	Foods	12	0.346	1.67
	動物ふれあい広場	Activities	16	0.576	2.81
15 時以降					
	安寿ベーカリー	Shopping	5	-0.691	-1.52
	トン's キッチン	Foods	11	-1.161	-1.77
測定開始からの経過時間の対数 (10 秒単位)					
	おもしろ自転車	Attractions	2	-0.137	-2.99
	西利	Shopping	4	-0.518	-7.57
	安寿ベーカリー	Shopping	5	-0.150	-3.89
	Gracia	Foods	6	-0.329	-3.45
	丹後茶寮	Foods	7	-0.177	-2.14
	羽衣ジュース	Foods	9	-0.121	-2.48
	七姫殿	Foods	12	-0.102	-2.47
	アスレチック広場	Attractions	14	0.101	1.31
	時計台	Activities	15	-0.193	-1.37
	芝すべり	Attractions	17	-0.188	-2.42
	メインゲート	Shopping	18	0.301	5.33
代表者の性別 (男性=1, 女性=0)					
	ゴーカート	Attractions	1	0.549	2.26
	動物ぶち広場	Activities	10	0.331	2.00
代表者の年齢/10					
	小町スコーラ	Activities	3	-0.848	-6.34
	丹後茶寮	Foods	7	-0.108	-1.37
	七姫殿	Foods	12	0.231	4.12
	インモーション	Attractions	13	-0.220	-4.55
	アスレチック広場	Attractions	14	-0.346	-3.55
	時計台	Activities	15	-0.344	-1.16
	芝すべり	Attractions	17	-0.243	-2.93
	メインゲート	Shopping	18	0.330	3.78
子どもの数					
	ゴーカート	Attractions	1	0.264	2.60
	おもしろ自転車	Attractions	2	0.223	1.56
	Gracia	Foods	6	-0.537	-2.20
	丹後茶寮	Foods	7	-0.315	-1.21
	見晴台	Activities	8	-0.455	-1.92
	トン's キッチン	Foods	11	-0.457	-2.81
	七姫殿	Foods	12	-0.121	-1.44
	アスレチック広場	Attractions	14	0.289	2.73
	動物ふれあい広場	Activities	16	-0.182	-1.54
	芝すべり	Attractions	17	0.370	2.77
	メインゲート	Shopping	18	-0.187	-1.59
既に訪問したか (短期の立寄り含む)					
	動物ぶち広場	Activities	10	-0.891	-2.53
前の活動からの距離 (最短ステップ数)					
	共通	-	-	-0.098	-11.68
残り時間の割合 (残り時間/総滞在時間)					
	おもしろ自転車	Attractions	2	0.636	1.80
	安寿ベーカリー	Shopping	5	0.329	1.60
	メインゲート	Shopping	18	-3.849	-8.48
京都府在住					
	おもしろ自転車	Attractions	2	-0.645	-1.95
	Gracia	Foods	6	-1.125	-1.93





Figure 4.17: 効用値の時間変化の例

において全ての POI の中で最大となる。実際には、意思決定の場所や訪問者の属性など、他の説明変数の影響を受けるため、ここまで単純ではないものの、後半になるとメインゲートが選択されやすく、帰宅する確率が高くなる時間的圧力の表現ができています。


訪問者グループの属性を考慮すると、代表者の性別が男性の場合、「ゴーカート」と「動物ぷち広場」の効用が高いことが分かる。また、代表者の年齢が上がるにつれ、フードコート（七姫殿）やメインゲートの効用が高まる一方で、手作り体験（小町スコラ）や、「インモーション」「アスレチック広場」「芝すべり」などの一部のアトラクションの効用が低下することが分かった。加えて、子どもの人数が多いほど、「ゴーカート」「おもしろ自転車」「アスレチック広場」「芝すべり」などのアトラクションの効用が高く、一方でレストランやカフェ（「Gracia」「丹後茶寮」「トン's キッチン」）や「見晴台」などは選ばれにくくなることが分かった。フードコート（七姫殿）も推定値が負となったが、他のレストランやカフェに比べて値が小さく、影響が小さい傾向にあった。推定結果は、4.2.3 節で行った子どもの有無と訪問確率の関係（Figure 4.12）とも整合的な結果が得られていることが確認できた。京都府在住についても、4.2.3 節で行った京都府在住と訪問確率の関係（Figure 4.13）と同様に、「おもしろ自転車」と「Gracia」の訪問確率が減少する様子が確認できた。これらの結果からも、活動スケジューリングモデルの推定の妥当性が確認できた。

また、活動場所までの距離も選択に大きく影響することが分かった。1 グリッド（約 15m）ごとに -0.098 効用が減るため、最も POI 間の距離がある昆虫館と動物ふれあい牧場（28 グリッド、約 420m）では、-2.744 減少することになる。

Figure 4.18 は、推定結果を用いて活動選択確率を予測した例を示す。エピソード番号は 1、現在地は七姫殿（POI12）、経過時間は 60 分、残り時間の割合は 2/3（120 分）と仮定している。グループの属性の違いによる選択確率の違いを明らかにするため、Figure 4.18a の代表者として 60 代女性（子供なし）を、Figure 4.18b の代表者を 30 代男性（子供 2 人）と仮定した。予測結果は、60 代女性の場合、最も確率の高い選択肢は「メインゲート」、「トン's キッチン」、「動物ふれあい牧場」の順となった。また、30 代男性の場合には、「動物プち広場」、「アスレチック広場」、



(a) 代表者：60代女性（子どもなし）



(b) 代表者：30代男性（子ども2人）

Figure 4.18: 活動選択確率の予測例（現在位置：七姫殿，エピソード番号：1，経過時間：60分，残り時間割合：2/3）

「ゴーカート」の順に選択確率が高くなった。属性の違いが活動の選択確率に大きく影響していることが分かる。また、子どもがいる場合は、特にアトラクションの効用が高くなっており、前述のように、これらの活動を選択する確率が大きく上昇する様子が確認された。

4.3.2 活動時間配分モデル

活動時間配分モデルの推定結果を Table 4.3 と Table 4.4 に示す。Table 4.3 に示したベースライン効用では、以下のような特徴が見られた。正午から午後3時までのランチタイムでは、「トン'sキッチン」や「七姫殿」などの昼食場所で正の値が記録され、滞在時間が長くなる傾向にあった。また、測定開始からの経過時間は、「七姫殿」を除くすべての POI でプラスの値を示しており、活動の後半に各 POI の効

Table 4.3: 推定結果 (活動時間配分モデル)

Variables	Name of POI	Type of POI	POI number	Parameters	t-values
エピソード番号					
	昆虫館	Activities	0	0.313	1.28
	インモーション	Attractions	13	0.352	2.74
	時計台	Activities	15	0.778	1.59
	動物ふれあい広場	Activities	16	0.212	1.50
12-15 時					
	トン's キッチン	Foods	11	0.859	1.83
	七姫殿	Foods	12	1.105	2.34
測定開始からの経過時間の対数 (10 秒単位)					
	ゴーカート	Attractions	1	0.418	3.81
	おもしろ自転車	Attractions	2	0.272	2.44
	安寿ベーカリー	Shopping	5	0.232	2.31
	動物ふれあい広場	Activities	10	0.283	3.86
	トン's キッチン	Foods	11	0.224	1.16
	七姫殿	Foods	12	-0.244	-3.51
	アスレチック広場	Attractions	14	0.312	3.24
	動物ふれあい広場	Activities	16	0.173	1.57
	芝すべり	Attractions	17	0.221	2.06
	メインゲート	Shopping	18	0.399	3.74
代表者の年齢/10					
	トン's キッチン	Foods	11	0.662	2.81
	七姫殿	Foods	12	0.141	1.22
子どもの数					
	動物ふれあい広場	Activities	10	-0.463	-2.12
	メインゲート	Shopping	18	-0.156	-1.59
前の活動からの距離 (最短ステップ数)					
	Common	-	-	0.053	5.15

用が高まっていることが分かる。これは、後半に滞在時間を多く残す傾向があることを示している。さらに、代表者の年齢層に関するパラメータ値は、「トン's キッチン」と「七姫殿」で正の値を示した。これは、年齢が高いほどこれらの POI でより多くの時間を過ごす傾向があることを示している。次の活動場所までの距離について、推定値は正の値となり、活動時間の中に移動時間を含めていることと整合する結果となった。

Table 4.4 に示される飽和パラメータでは、値が小さいほど限界効用の減少が大きくなり、滞在期間が短くなる。「ゴーカート」、「西利」、「安寿ベーカリー」で小さな値が得られており、予想通りの結果となった。これは、「ゴーカート」は1周するのに必要な時間が短いこと、「西利」と「安寿ベーカリー」は滞在時間の短い小規模な店であることから、予想によく合致している。また、残りの活動時間に寄与する複合財の飽和パラメータを時間帯別に比較したところ (Fig 4.19)、午前中に比較的大きな値を示し、後半になると減少する傾向が見られた。この結果は、活動スケジュールリングの早い時間帯における時間的圧力の存在を示唆している。活動スケジュールリングにおける時間的圧力は、活動計画から生じると考えられる。早い時間帯には、計画されているが未実行の活動が多いことによる時間的圧力が発生し、より短い活動時間になると考えられる。

Table 4.4: 推定結果（飽和パラメータ他）

Variables	Name of POI	Type of POI	POI number	Parameters	Standard Errors
飽和パラメータ (POI)					
	昆虫館	Activities	0	-0.984	0.116
	ゴーカート	Attractions	1	-1.371	0.140
	おもしろ自転車	Attractions	2	-0.840	0.121
	小町スコーラ	Activities	3	-0.773	0.083
	西利	Shopping	4	-1.075	0.148
	安寿ペーカリー	Shopping	5	-1.041	0.122
	Gracia	Foods	6	-0.667	0.127
	丹後茶寮	Foods	7	-0.815	0.082
	見晴台	Activities	8	-0.842	0.115
	羽衣ジュース	Foods	9	-0.845	0.057
	動物ぶち広場	Activities	10	-0.861	0.108
	トン's キッチン	Foods	11	-0.919	0.216
	七姫殿	Foods	12	-0.367	0.087
	インモーション	Attractions	13	-0.993	0.086
	アスレチック広場	Attractions	14	-1.070	0.119
	時計台	Activities	15	-0.984	0.366
	動物ふれあい広場	Activities	16	-0.920	0.092
	芝すべり	Attractions	17	-0.616	0.100
	メインゲート	Shopping	18	0.195	0.169
飽和パラメータ (複合財)					
	9 AM to 9:59 AM	-	-	-0.094	0.073
	10 AM to 10:59 AM	-	-	0.010	0.060
	11 AM to 11:59 AM	-	-	-0.120	0.045
	12 noon to 12:59 noon	-	-	-0.054	0.048
	1 PM to 1:59 PM	-	-	-0.109	0.055
	2 PM to 2:59 PM	-	-	-0.143	0.049
	3 PM to 3:59 PM	-	-	-0.295	0.069
	4 PM to 4:59 PM	-	-	-0.217	0.100
	5 PM to 5:59 PM	-	-	-0.308	0.412
	6 PM to 6:59 PM	-	-	-0.188	0.311
	スケールパラメータ σ			1.060	0.040
	相関係数 ρ			-0.350	0.062
	Log likelihood of constant-only model			-9990.16	
	Log likelihood of full model			-7489.72	
	修正済み ρ^2			0.240	

4.4 まとめ

本章では、ノイズや欠損のある GPS データを 15m という高い空間分解能を持つ 2 次元のグリッドベースの空間表現に離散化する処理方法を提案した。また、離散化されたデータから POI の滞在に関する情報を抽出し、この情報に基づいて、活動選択モデルと活動時間配分モデルからなる動的活動スケジューリングモデルの推定を行った。

活動選択モデルの推定では、代表者の年齢や子どもの数などのグループ属性が、アスレチックなどの屋外活動を選択する確率に大きく影響することが分かった。また、メインゲートを選択する確率は、滞在后半になるほど高くなり、時間的な圧力の影響が確認された。活動時間配分モデルの推定結果によると、レストランやフードコートでの滞在時間は、昼食時に長くなる傾向があり、年齢が高いほど滞在




Figure 4.19: 時間帯別の複合財の飽和パラメータ値

時間が長くなる傾向が確認された。さらに、複合財の飽和パラメータの時間変化から、早い時間帯に時間的な圧力が存在することが示唆された。この時間的な圧力は、計画されているがまだ実行されていない活動から発生するものと考えられる。

歩行者の GPS データから活動選択のみならず、活動時間配分の推定を行った先行研究はない。そのため、本研究は、たとえ単一の施設におけるアクティビティの分析であっても、文献に大きく貢献していると考えられる。特に、この本手法は、センシングデータに基づく公共空間設計のための新しいアプローチとなりうる。また、本分析の枠組みを用いることで、新たに計画された空間内の POI の来訪者数の予測を行うことができる。

本章のモデルでは、屋外施設での滞在時間は外生的に与えられているが、本来、滞在時間は基本的に不明であるため、次章で述べるような都市スケールのアクティビティベースモデルを用いて来訪者の属性や総滞在時間を求めることができる。さらに、本章における時空間離散化手法は、前章で紹介した再帰型経路選択モデルにも適用できる。これらを組み合わせることで、歩行者の複雑な意思決定行動を統合的にモデル化することができる。

次章では、施設の来訪者の属性や滞在時間を求めるための、広域の行動生成モデルを提案する。

Chapter 5

広域の移動行動生成モデル

5.1 はじめに

前章までは、特定の施設内における歩行者の複雑な意思決定行動のモデリングについて説明を行ってきた。前章で提案した動的活動スケジューリングモデルでは、逐次的に活動選択と活動時間配分を行うことで、結果として施設内の活動スケジュールを生成するモデルであった。前章のモデルは、来訪者の属性や総滞在時間が既知であることを前提としてきたが、本章では、広域の移動行動生成モデルについて提案を行う。特に、本章で提案するモデルは、国勢調査や社会生活基本調査などの入手が容易な集計データのみを用いることを前提とし、パーソントリップ調査に代表されるような大規模な交通調査を一切必要としない。また、個人情報を含まないためプライバシー保護の問題も起こらない。

本章で提案するモデルは、複数の集計データを統合することにより、疑似的な人の移動行動データを生成する方法である。この疑似データは、年齢、性別、居住エリア、1日の行動スケジュール、1日の滞在場所の情報を持つ多数の疑似的な個人（エージェント）から構成される。これらのエージェントは入力となる集計データの統計的な性質を保証するように、確率的な移動行動モデルを用いて生成される。提案手法により生成された移動行動データは、携帯電話基地局情報から作成される人口統計情報との比較検証により、その有効性を確認される。

本章の主な貢献は以下の3つに要約される。

- 大規模な交通調査を必要とせず、一般に入手が容易な集計データのみから人の移動行動を生成する新しい手法を提案する。
- 集計データの統計値を保証するようにエージェントを生成する手法を提案する。
- 提案手法による疑似移動行動データを携帯電話の基地局情報から得られる人口統計情報と比較することで精度を検証する。

本手法の特徴は、前述のように、国勢調査などの公的機関が公開するいわゆるオープンデータや市販されている統計データのみを用いて人の移動行動を生成することができる点にある。使用するデータはいずれも日本全国をカバーするものであり、そのため、全国どこの自治体に関しても移動行動生成データの生成が可能である。これまで時間的・金銭的コストの面からパーソントリップ調査などの調査が難しかった自治体についても安価かつ簡便に都市内の移動行動データを生成することが可能となり、交通政策の立案などに役立てると考えられる。

本章の構成は以下の通りである。続く第2節では、提案する移動行動生成モデルについてその技術的詳細を説明する。第3節では、提案したモデルの一部である行為系列生成のモデル選択を Web アンケートで取得した実データを用いて行う。第4節では、携帯電話の基地局情報から得られるデータを用いて滞在人口の推定精度について評価を行う。第5節では、集計データの課題となる更新頻度について、

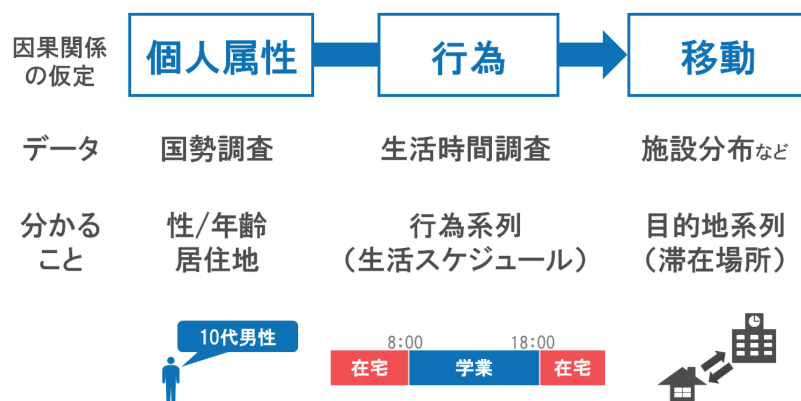


Figure 5.1: 移動行動生成モデルの概要

Table 5.1: 移動行動生成モデルに使用するデータ

必要なデータ	具体例
属性別の居住地分布	国勢調査
生活時間（行為者率）	社会生活基本調査, NHK 生活時間調査など
行為別の魅力度指標（例えば、施設数、従業員数、生徒数、店舗面積など）	経済センサス, 商業統計, 店舗統計データなど
平均移動距離	アンケートなど

より更新頻度の高い別の公開情報をもとに推計する方法について提案する。最後に第6節にて、まとめと今後の課題について述べる。

5.2 移動行動生成モデル

5.2.1 モデルの概要

本章で提案する移動行動の生成モデルは以下の因果関係の仮定を根底においている。すなわち、個人の属性（年齢・性別）が行為を規定し、行為が移動を規定するというものである（Figure 5.1）。例えば、エージェントに10代男性という個人属性が付与されれば、その属性に対応する1日の行為は日中に学業を行うことであり、さらに、その学業を行う場所はといえば学校となる。このように、本手法は移動が行為（活動）の派生需要として決まるアクティビティベースのモデルの考え方を踏襲している。

Figure 5.1 に示される通り、エージェントに付与されるすべての情報は3つのステップを経て生成される。

1. 居住地エリア、性別、年齢層の付与
2. 個人属性を入力として、1日の行為系列を付与
3. 行為系列を入力として、各行為に対応した目的地を付与

本手法を適用する上で必要となるデータを Table 5.1 にまとめた。表を見て分かるように基本的に集計データのみを必要としている。ただし、現状では目的地系列生成の際には平均移動距離が必要であり、これらを公的な統計データ等から得ることができない場合にはアンケート等を利用して推計する必要がある。

以下の節では、それぞれのステップについて詳述する。

5.2.2 エージェントの生成

国勢調査の500m（もしくは1km）メッシュの属性（性別、年齢層）別の人口に基づき、居住地メッシュと性別、年齢層を持つエージェントを人口と同数生成する。

5.2.3 行為系列生成

行為系列は、1日の各時間帯における行為の時系列であり、1日の行動（活動）スケジュールを表すものである。ここでは、性別、年齢層を入力として各時間帯の行為を確率的に付与する方法を説明する。本節では、2つの行為系列生成モデルを提案する。これらのモデルの比較・選択は後の節にて行う。

5.2.3.1 1次のマルコフモデル

各時間帯における行為間の遷移確率が既知であれば、乱数を用いて行為系列を生成することが可能である。例えば、行為間に1次のマルコフ性を仮定すると、時刻 t において行為 j を選んだ人が、時刻 $t+1$ において行為 i を選択する確率 $P^{(t)}(i \leftarrow j)$ は、行為遷移確率行列 $A^{(t)}$ の ij 要素そのもの、つまり、

$$P^{(t)}(i \leftarrow j) = a_{ij}^{(t)} \quad (5.1)$$

と表現できる。

家庭の電力需要予測モデルに関する研究の中には、生活スケジュールを生成し、生成された行為に対応する家電の電力消費量から家庭の電力需要プロファイルを生成するアプローチも多く存在する [81]。こうした生活スケジュール生成モデルの中にはマルコフ遷移を用いたものも多くあるが、そのほとんどは、遷移確率行列を生活時間調査の個票データから得られる相対頻度を用いて推計している [82]。これに対して、本研究では個々の生活時間調査データの代わりに生活時間調査の集計データを用いる。

国内における生活時間調査の集計データには、NHKの国民生活時間調査 [83] や総務省の社会生活基本調査 [84] などがある。これらの生活時間調査データは主に2つのデータから構成されている。1つは、「時間帯別行為者率」であり、これはある時刻に該当行為をしている人の割合を指す。もう1つは、「1日の行為者率」であり、これは1日の中で該当行為を少しでもした人の割合を指すものである。行為間の遷移確率をデータから直接得ることはできないため、以下では、この2種類のデータを使用して遷移確率を推定する方法を提案する。

いま時刻 t 、 $t+1$ における行為者率のベクトルをそれぞれ $\mathbf{y}^{(t)}$ 、 $\mathbf{y}^{(t+1)}$ とする。この2つのベクトルの次元（行為の種類）が n のとき、推定すべき遷移確率行列 $A^{(t)}$ の要素は、 $n \times n$ 次元となるため、 n 個の連立方程式：

$$\mathbf{y}^{(t+1)} = \mathbf{A}^{(t)} \mathbf{y}^{(t)} \quad (5.2)$$

から $A^{(t)}$ を求めることは一般にできない。

以下では、問題の構造の詳細の理解のために、Figure 5.2 に示される単純化した問題を考える。いま、行為の集合が「在宅」と「仕事」の2つのみからなり、時間帯も「 $t=1$ 」と「 $t=2$ 」の2つの時間帯のみから構成されるとする。行為者率ベクトルが $\mathbf{y}^{(1)} = [0.5, 0.5]^t$ 、 $\mathbf{y}^{(2)} = [0.5, 0.5]^t$ と与えられたときに、遷移確率行列 $A^{(1)}$ がどのように推定されるかを考える。この問題の代表的な解には例えば、Figure 5.3 に示されるように

1. 全てのエージェントが行為を変更しない
2. 半数のエージェントが行為を変更する
3. 全てのエージェントが行為を変更する

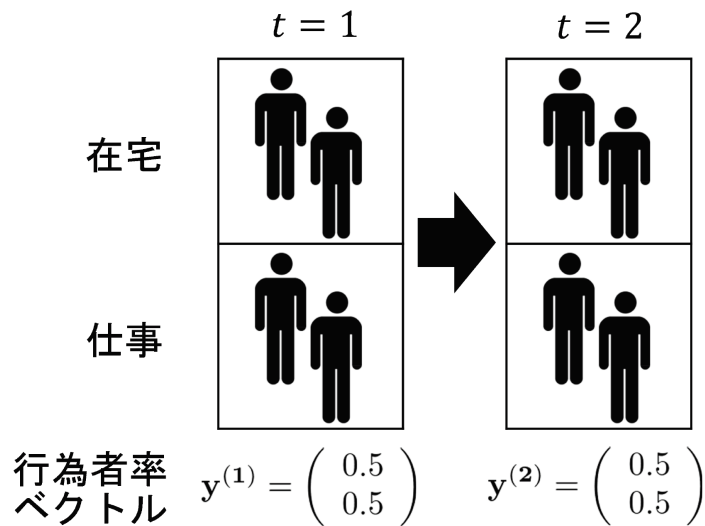


Figure 5.2: 遷移確率推定問題の例

が含まれる。これらの解はすべて異なる遷移確率行列に対応している。例えば、解1は対角行列に対応する。

この解の中で尤もらしい解を見つけるためには、与えられた時間帯別の行為者率のみでは不十分である。そこで、生活時間調査データから取得できるもう一つのデータである1日の行為者率を利用する。

いま、行為 i の1日の行為者率を $P_i^{(day)}$ と書き表す。1日の行為者率は定義より該当行為を1回でも行った確率なので、以下のように計算ができる。

	$t = 1$	$t = 2$	遷移確率行列 $A^{(1)}$	1日の行為者率
解1		$\begin{pmatrix} 1.0 & 0.0 \\ 0.0 & 1.0 \end{pmatrix}$	$P_{在宅}^{(day)} = 0.5$ $P_{仕事}^{(day)} = 0.5$	
解2		$\begin{pmatrix} 0.5 & 0.5 \\ 0.5 & 0.5 \end{pmatrix}$	$P_{在宅}^{(day)} = 0.75$ $P_{仕事}^{(day)} = 0.75$	
解3		$\begin{pmatrix} 0.0 & 1.0 \\ 1.0 & 0.0 \end{pmatrix}$	$P_{在宅}^{(day)} = 1.0$ $P_{仕事}^{(day)} = 1.0$	

Figure 5.3: 遷移確率推定問題の解

$$P_i^{(\text{day})} = a_{ii}y_i + a_{ij}y_j + a_{ji}y_i \quad \forall i \neq j. \quad (5.3)$$

ただし、 y_i は行為者率のベクトル \mathbf{y} の i 番目の要素を表している。ここで、解1の場合の在宅の1日の行為者率を計算すると

$$P_{\text{在宅}}^{(\text{day})} = 1.0 \cdot 0.5 + 0.0 \cdot 0.5 + 0.0 \cdot 0.5 \quad (5.4)$$

$$= 0.5 \quad (5.5)$$

と求めることができる。解2の場合にも同様に計算すると

$$P_{\text{在宅}}^{(\text{day})} = 0.5 \cdot 0.5 + 0.5 \cdot 0.5 + 0.5 \cdot 0.5 \quad (5.6)$$

$$= 0.75 \quad (5.7)$$

となる。

このようにそれぞれの解の1日の行為者率を計算すると、異なる値が得られる。したがって、これらの解は、同じ時間帯別行為者率を満たす解ではあるが、1日の行為者率によって区別が可能である。すなわち、生活時間調査データから得られる1日の行為者率に最も近い解を選ぶことで、一番現実に近い遷移確率が得られるということを意味している。

しかしながら、時間帯別行為者率の制約を満たす解は無数にあることから、解の候補全てを列挙し、その1日の行為者率を比較することは現実的ではない。そこで、この問題を最適化問題として定式化し、遷移確率行列の要素よりも少ないパラメータを調整することで1日の行為者率を満たす解を探索する。

いま、以下のような最適化問題を考える。

$$\text{minimize} \quad \sum_{i,j} \beta_{ij} a_{ij}^{(t)2} \quad (5.8)$$

$$\text{subject to} \quad \sum_i a_{ij}^{(t)} = 1 \quad (5.9)$$

$$a_{ij}^{(t)} > 0 \quad \forall i, j \quad (5.10)$$

$$y_i^{(t+1)} - \sum_j a_{ij}^{(t)} y_j^{(t)} = 0 \quad (5.11)$$

ここで、 β_{ij} は遷移確率行列の各要素に対する重みを表す。また、式(5.9)と(5.10)は遷移確率行列が満たすべき性質を表しており、式(5.11)は各時間帯における行為者率を保証するための条件になっている。式(5.8)は $\beta_{ij} = 1$ のとき、Tsallis エントロピー [85] として知られる拡張されたエントロピーの一種であるとみなすことができる。

Tsallis エントロピーは、以下の式で定義される。

$$S_q = \frac{1 - \sum_i a_i^q}{q - 1}, \quad (5.12)$$

ここで、 q は正の実数で、entropic index と呼ばれる。この式は $q \rightarrow 1$ の極限で、Shannon エントロピーとして知られる

$$S_1 = - \sum_i a_i \ln a_i \quad (5.13)$$

が得られる。また、 $q = 2$ の場合、以下の式が得られる。

$$S_2 = 1 - \sum_i a_i^2. \quad (5.14)$$

S_2 の最大化は、 $\sum_i a_i^2$ の最小化と等価なので、式(5.8)は拡張されたエントロピー最大化を行っていると考えられる。確率の2乗和で与えられるこの指標は、経済学の分野では企業の競争状態を表す指標として(Herfindahl-Hirschman index[86])、生態学の分野では種の多様性を計る指標(Simpson diversity index[87])として知られている。

以上のことから、式(5.8)–(5.11)は、確率が満たすべき性質と各時間帯別の行為者率を制約条件としたエントロピー最大化問題となっている。したがって、Shannonエントロピーから類推しても分かるように不確実性が高い解、すなわち、等確率な解ほど得られやすい。これに対して、重み係数 β_{ij} を導入することで、遷移のしやすさに関する事前知識を導入することが可能である。 β_{ij} を小さく設定した場合、 a_{ij} の項の影響が小さくなるため、より大きな遷移確率が得られやすい。また、 β_{ij} は時間帯によらず共通であるが、式(5.11)の制約によって a_{ij} は異なる特性(遷移確率行列)を持つ。

いま、事前知識として行為によって差はあるものの、同じ行為は続きやすいと仮定する。仕事をしている人は次の時刻も仕事である確率が高い、在宅をしている人は次の時刻も在宅している確率が高いなどがその例である。他の行為への遷移に関しては、同じ重みを取るとし、同じ行為の遷移は高い確率を取りやすいと仮定すると、重みの数を n^2 から n に削減できる。以下、他の行為への遷移にかかる重みを $\beta_{ij} = 1$ とし、行為 i 同士の遷移にかかる重みを $1 - \beta_i$ と再定義すると、式(5.8)は

$$\text{minimize} \quad \sum_{i,j} (1 - \beta_i \delta_{ij}) a_{ij}^{(t)2} \quad (5.15)$$

と表すことができる。ただし、 δ_{ij} はクロネッカーのデルタである。また、重み β_i は $[0, 1]$ の値を取り、値が大きいほど同じ行為の遷移確率が高くなる。つまり、 β_i は同じ行為の続きやすさを制御するパラメータとなっている。

式(5.15)は目的関数が $a_{ij}^{(t)}$ の2次式、式(5.9)–(5.11)は制約条件が $a_{ij}^{(t)}$ の1次式なので、いわゆる2次計画問題となっている。

2次計画問題は一般に以下の式で表される：

$$\text{minimize} \quad \frac{1}{2} \mathbf{x}^T \mathbf{Q} \mathbf{x} + \mathbf{p}^T \mathbf{x} \quad (5.16)$$

$$\text{subject to} \quad \mathbf{A}^T \mathbf{x} \geq \mathbf{b}^T. \quad (5.17)$$

ここで、遷移確率行列の要素を次のように並べた n^2 次元ベクトル \mathbf{x} を考える：

$$\mathbf{x}^T = [a_{11}^{(t)}, a_{12}^{(t)}, \dots, a_{ij}^{(t)}, \dots, a_{nn}^{(t)}] \quad (5.18)$$

このとき、 $n^2 \times n^2$ 次元行列 \mathbf{Q} は以下の対角ブロック行列となる：

$$\mathbf{Q} = \text{diag} [\mathbf{B}_1, \mathbf{B}_2, \dots, \mathbf{B}_n], \quad (5.19)$$

ただし、 \mathbf{B}_i は以下の式で表される $n \times n$ 次元行列である：

$$\mathbf{B}_i = \text{diag} [2(1 - \beta_i \delta_{i1}), 2(1 - \beta_i \delta_{i2}), \dots, 2(1 - \beta_i \delta_{in})]. \quad (5.20)$$

したがって、行列 \mathbf{Q} も対角行列であり、また、 β_i の定義より、各要素は非負である。これは \mathbf{Q} が正定値行列であることを意味しており、この最適化問題は凸2次計画問題として唯一の最適解が保証される。

以上のように、遷移確率行列を求める問題を2次計画問題として定式化した。あとは、1日の行為者率と最も適合するように β_i を調整し、遷移確率行列を求めれば良い。 β_i の調整は以下のように行われる。最適化問題の解から得られる1日の行為者率が実データよりも大きい場合には、 β_i をより大きく設定することで、より低い1日の行為者率が得られるよう調整することができる。その反対に、最適化問題の解から得られる1日の行為者率が実データよりも小さい場合には β_i を小さく設定することで、より高い1日の行為者率が得られるよう調整が可能である。

行為 i' の1日の行為者率 $P_{i'}^{(\text{day})}$ は、1度も i' を行わない確率を $P_{i'}^{(\text{day})}$ と定義すると、1から $P_{i'}^{(\text{day})}$ を引くことで求められる。すなわち、

$$P_{i'}^{(\text{day})} = 1 - P_{i'}^{(\text{day})} \quad (5.21)$$

と表される。

いま、1日が $t = \{0, \dots, T-1\}$ の全部で T の時間帯で表現されるとする。ある時刻 t における遷移確率 $A^{(t)}$ の i' 行を全て0に置き換えた行列 $\tilde{A}_{i'}^{(t)}$ と時刻0における時間帯別行為者率の i' 行を0に置き換えたベクトル $\mathbf{y}_{i'}^{(0)}$ を考える。このとき、1日の間に1度も行為 i' を行わない確率 $P_{i'}^{(\text{day})}$ は以下の式で表すことができる。

$$P_{i'}^{(\text{day})} = \mathbf{1}^T \tilde{A}_{i'}^{(T-1)} \tilde{A}_{i'}^{(T-2)} \dots \tilde{A}_{i'}^{(0)} \mathbf{y}_{i'}^{(0)} \quad (5.22)$$

ここで、 $\mathbf{1}^T$ は要素が全て1のベクトルである。

5.2.3.2 2次のマルコフモデル

これまで、行為の遷移に1次のマルコフ性を仮定し、時間帯別の行為者率を制約条件とした数理最適化問題を解くことで行為間の遷移確率を求める方法について説明してきた。前述の方法では、行為は1時刻前の行為にのみ依存するという極めてシンプルなものであったが、ここでは2時刻前の行為までに依存する2次のモデルへの拡張を試みる。

2次のマルコフ性の仮定より、あるエージェントの時刻 $t+2$ における行為の分布 $P(\mathbf{y}^{(t+2)})$ は、その2つ前までの行為 $\mathbf{y}^{(t)}$ 、 $\mathbf{y}^{(t+1)}$ に共に依存して決まることから、これらの関係は以下の式で表現される：

$$P(\mathbf{y}^{(t+2)}) = \sum_{\mathbf{y}^{(t)}} \sum_{\mathbf{y}^{(t+1)}} P(\mathbf{y}^{(t+2)} | \mathbf{y}^{(t)}, \mathbf{y}^{(t+1)}) P(\mathbf{y}^{(t)}, \mathbf{y}^{(t+1)}) \quad (5.23)$$

$\mathbf{y}^{(t)}$ 、 $\mathbf{y}^{(t+1)}$ の同時分布 $P(\mathbf{y}^{(t)}, \mathbf{y}^{(t+1)})$ は、直接データから与えられない。しかし、Figure 5.4に示すように、この同時分布は1時刻前の同時分布と遷移確率から求めることができる。したがって、

$$P(\mathbf{y}^{(t+2)}) = \sum_{\mathbf{y}^{(t)}} \sum_{\mathbf{y}^{(t+1)}} P(\mathbf{y}^{(t+2)} | \mathbf{y}^{(t)}, \mathbf{y}^{(t+1)}) \cdot \left\{ \sum_{\mathbf{y}^{(t-1)}} P(\mathbf{y}^{(t+1)} | \mathbf{y}^{(t-1)}, \mathbf{y}^{(t)}) P(\mathbf{y}^{(t-1)}, \mathbf{y}^{(t)}) \right\} \quad (5.24)$$

と書き表すことができる。この操作を繰り返すと、

$$P(\mathbf{y}^{(t+2)}) = \sum_{\mathbf{y}^{(0)}} \dots \sum_{\mathbf{y}^{(t+1)}} \left\{ P(\mathbf{y}^{(t+2)} | \mathbf{y}^{(t)}, \mathbf{y}^{(t+1)}) \dots P(\mathbf{y}^{(2)} | \mathbf{y}^{(0)}, \mathbf{y}^{(1)}) P(\mathbf{y}^{(0)}, \mathbf{y}^{(1)}) \right\} \quad (5.25)$$




Figure 5.4: 2 次のマルコフモデルにおける同時分布の再帰的關係

となる． $P(\mathbf{y}^{(0)}, \mathbf{y}^{(1)})$ は、これ以上遡ることができないことから、1 次のマルコフ性を仮定して求める． すなわち、

$$P(\mathbf{y}^{(0)}, \mathbf{y}^{(1)}) = P(\mathbf{y}^{(1)} | \mathbf{y}^{(0)}) P(\mathbf{y}^{(0)}) \quad (5.26)$$

を前述の方法にしたがって解けばよい．

任意の時刻において、毎回式 (5.25) を計算する必要はない． つまり、Figure 5.4 に示すように任意の時刻の同時分布は 1 時刻前の同時分布とそこからの遷移確率を用いて求められるので、遷移確率を推定した後、次の時刻の同時分布を計算し、この同時分布のみを記憶すれば良い． 各時刻における遷移確率は、この制約条件を満たすように決定されるため、この同時分布を周辺化したものは、時間帯別の行為者率のデータと整合する．

次に、この 2 次のマルコフモデルを要素で書き表す． まず、時刻 $t = 1$ における遷移の制約条件は、前述の通り 1 次のマルコフ性を持つと仮定すると、

$$y_i^{(1)} = \sum_j a_{ij}^{(0)} y_j^{(0)} \quad (5.27)$$

$$= \sum_j c_{ij}^{(0)} \quad (5.28)$$

と書き表すことができる． ただし、式 (5.28) 中の $c_{ij}^{(0)}$ は、時刻 $t = 0$ で行為 j 、時刻 $t = 1$ で行為 i をとる同時確率を表す． 次に、時刻 $t = 2$ における行為 i の行為者率 $y_i^{(2)}$ は、前の時刻の同時確率 $c_{jk}^{(0)}$ と遷移確率 $b_{ijk}^{(0)}$ の積を時刻 $t = 0$ と $t = 1$ で周辺化することで求められるので、

$$y_i^{(2)} = \sum_j \left(\sum_k b_{ijk}^{(0)} c_{jk}^{(0)} \right) \quad (5.29)$$

と求められる． また、時刻 $t = 1$ と時刻 $t = 2$ の同時確率は、

$$c_{ij}^{(1)} = \sum_k b_{ijk}^{(0)} c_{jk}^{(0)} \quad (5.30)$$

と計算できる． あとは、遷移確率 $b_{ijk}^{(t)}$ と同時確率 $c_{ij}^{(t)}$ を逐次的に計算していくことで、任意の時刻の制約条件を求めることができる．

1 次のマルコフモデルで説明したように、遷移確率はデータから一意には決まらないため、式 (5.15) に示す拡張したエントロピーの最大化問題として求めた。これを 2 次のモデルに拡張する。1 時刻前の状態の続けやすさを 1 次モデルと同様に β_i とし、2 時刻前の状態の続けやすさを ξ_i とする。これらが独立に影響を及ぼすと仮定すると、目的関数は、

$$\text{minimize} \quad \sum_{i,j,k} (1 - \beta_i \delta_{ij}) (1 - \xi_i \delta_{ik}) b_{ijk}^{(t)2} \quad (5.31)$$

となる。行為数が n の場合、遷移確率 $b_{ijk}^{(t)}$ の要素数は n^3 となるが、これを $2n$ 個のパラメータで制御することができる。

ここまでの議論をまとめると、2 次のマルコフモデルの遷移確率を求める 2 次計画問題は以下の通りとなる。

時刻 $t = 1$ において、以下の 2 次計画問題と解く：

$$\text{minimize} \quad \sum_{i,j} (1 - \beta_i \delta_{ij}) a_{ij}^{(0)2}, \quad (5.32)$$

$$\text{subject to} \quad \sum_i a_{ij}^{(0)} = 1, \quad (5.33)$$

$$a_{ij}^{(0)} > 0 \quad \forall i, j, \quad (5.34)$$

$$y_i^{(1)} - \sum_j a_{ij}^{(0)} y_j^{(0)} = 0. \quad (5.35)$$

また、時刻 $t \geq 2$ において、以下の 2 次計画問題を解く：

$$\text{minimize} \quad \sum_{i,j,k} (1 - \beta_i \delta_{ij}) (1 - \xi_i \delta_{ik}) b_{ijk}^{(t)2}, \quad (5.36)$$

$$\text{subject to} \quad \sum_i b_{ijk}^{(t)} = 1, \quad (5.37)$$

$$b_{ijk}^{(t)} > 0 \quad \forall i, j, k, \quad (5.38)$$

$$y_i^{(t)} - \sum_j \left(\sum_k b_{ijk}^{(t-2)} c_{ij}^{(t-2)} \right) = 0. \quad (5.39)$$

ただし、

$$c_{ij}^{(t)} = \sum_k b_{ijk}^{(t-1)} c_{jk}^{(t-1)}, \quad (5.40)$$

$$c_{ij}^{(0)} = a_{ij}^{(0)} y_j^{(0)} \quad (5.41)$$

である。2 次のモデルについて β_i, ξ_i が $[0, 1]$ の値を取れば、この問題は凸 2 次計画問題として、唯一の最適解が保証される。

5.2.4 目的地系列生成

目的地系列は、1日の各時間帯における目的地の時系列で、エージェントが1日に訪問する場所を示すものである。各エージェントの目的地の選択には Wilson のエントロピーモデルを用いる [88]：

$$X_{lm} = A_l B_m O_l D_m e^{-\gamma c_{lm}}. \quad (5.42)$$

ここで、 X_{lm} は lm 間の移動量、 O_l はメッシュ l における発生量、 D_m はメッシュ m における集中量、 c_{lm} は lm 間の距離、 A_l 、 B_m 、 γ はパラメータを表す。このモデルでは、あるメッシュ間の移動量は、発生量（移動需要）と集中量（魅力度）にそれぞれ比例し、また、距離が近いほど移動量は大きい。

パラメータ A_l 、 B_m 、 γ は、以下の発生制約、集中制約、トリップ長制約を用いて決定できる：

$$O_l = \sum_m X_{lm}, \quad (5.43)$$

$$D_m = \sum_l X_{lm}, \quad (5.44)$$

$$\sum_{l,m} X_{lm} c_{lm} = C. \quad (5.45)$$

ここで、 C は総移動距離を表す。この総移動距離はトリップ数と平均移動距離の積から求めることができる。集中量の代わりに魅力度を用いる場合には、上記の制約を満たさないため、以下の操作により、発生量の総和と魅力度の総和が等しくなるよう調整する：

$$D_m \rightarrow \frac{\sum_l O_l}{\sum_m D_m} D_m. \quad (5.46)$$

式 (5.42)–(5.45) より、以下の式が得られる：

$$A_l = \left(\sum_m B_m D_m e^{-\gamma c_{lm}} \right)^{-1}, \quad (5.47)$$

$$B_m = \left(\sum_l A_l O_l e^{-\gamma c_{lm}} \right)^{-1}, \quad (5.48)$$

$$\sum_{l,m} A_l B_m O_l D_m e^{-\gamma c_{lm}} \cdot c_{lm} = C. \quad (5.49)$$

パラメータ A_l 、 B_m 、 γ は、これらを連立させた反復計算を行うことにより決定できる。反復計算の概略は以下の通りである。

(i) 初期値設定

(a) $\nu = 1$ とし、初期値 γ^0 、 A_l^0 、 B_m^0 を与える。

(ii) γ^ν に対応する A_l^ν 、 B_m^ν の算出

(a) $\kappa = 1$ とおき、探索の初期値を $\hat{A}_l^0 = A_l^{\nu-1}$ 、 $\hat{B}_m^0 = B_m^{\nu-1}$ とする。

(b) $\hat{B}_m^\kappa = \left(\sum_l \hat{A}_l^{\kappa-1} O_l e^{-\gamma^{\nu-1} c_{lm}} \right)^{-1}$ を算出。

(c) $\hat{A}_l^\kappa = \left(\sum_m \hat{B}_m^\kappa D_m e^{-\gamma^{\nu-1} c_{lm}} \right)^{-1}$ を算出。

- (d) $\hat{A}_l^\kappa \equiv \hat{A}_l^{\kappa-1}$ かつ, $\hat{B}_m^\kappa \equiv \hat{B}_m^{\kappa-1}$ であれば, $A_l^\nu = \hat{A}_l^\kappa$, $B_m^\nu = \hat{B}_m^\kappa$ とし, iii) へ. そうでなければ $\kappa := \kappa + 1$ として (b) へ戻る.

(iii) γ^ν の更新 (Newton-Raphson 法)

- (a) $\mu = 1$ とおき, 探索の初期値を $\hat{\gamma}^0 = \gamma^\nu$ とする.
(b) $\hat{\gamma}^\mu = \hat{\gamma}^{\mu-1} - f(\hat{\gamma}^{\mu-1})/f'(\hat{\gamma}^{\mu-1})$ を計算する.
ただし, $f(\gamma) = \sum_{l,m} A_l B_m O_l D_m e^{-\gamma c_{lm}} \cdot c_{lm} - C$,
 $f'(\hat{\gamma}^{\mu-1}) = -\sum_{l,m} A_l B_m O_l D_m e^{-\hat{\gamma}^{\mu-1} c_{lm}} \cdot c_{lm}^2$ である.
(c) $\hat{\gamma}^\mu \equiv \hat{\gamma}^{\mu-1}$ であれば, $\gamma^\mu = \hat{\gamma}^\mu$ として, iv) へ. そうでなければ, $\mu := \mu + 1$ として (b) へ戻る.

(iv) 収束判定

- (a) $\gamma^\nu \equiv \gamma^{\nu-1}$ であれば, $\gamma = \gamma^\nu$, $A_l = A_l^\nu$, $B_m = B_m^\nu$ として終了. そうでなければ, $\nu := \nu + 1$ として ii) へ戻る.

反復計算の具体的な方法については栗田 (2013)[89] に詳しい.

前節のステップにより, 各エージェントの行為系列が既知なので, 行為別に移動量を推定することができる. ある行為 i に関する移動量を $X_{lm}^{(i)}$ と書き表すとき, $X_{lm}^{(i)}$ は,

$$X_{lm}^{(i)} = A_l^{(i)} B_m^{(i)} O_l^{(i)} D_m^{(i)} e^{-\gamma^{(i)} c_{lm}} \quad (5.50)$$

と書き表すことができる. ただし, 他の変数に関しても上付きの添え字 i は「行為 i に関する」という意味である. 目的地選択に関しても 1 次のマルコフ性を仮定すると, 目的地選択を以下の式から求めることができる:

$$P(\text{pos}^{(t+1)} = m \mid \text{act}^{(t+1)} = i \neq j, \text{pos}^{(t)} = l) = \frac{X_{lm}^{(i)}}{\sum_m X_{lm}^{(i)}}. \quad (5.51)$$

ただし, 添字 t は時刻, $\text{pos}^{(t)}$ は時刻 t における位置, $\text{act}^{(t)}$ は時刻 t における行為を表す. このように行為別の移動量 $X_{lm}^{(i)}$ を計算しておくことで, 各エージェントの目的地生成を逐次的に行うことができる. また, 目的地の生成は時刻 $t + 1$ における行為 i が, 直前の行為 j と異なるときにのみ行われることに注意されたい. 同じ行為を続けている限りは移動を行わないと仮定している.

行為別の発生量は 1 日の訪問箇所が複数ある場合, 2 箇所目以降は動的に決定される. そのため, 式 (5.51) が決まる前に 2 箇所目以降の発生地点を予め知ることはできない. そこで, まず始めにすべての行為はエージェントの居住メッシュから発生するとの仮定の下, 上記の方法を用いてエージェントに目的地を付与する. 得られた目的地の系列をもとに再び発生量を計算し, それをもとにエージェントに目的地を付与し直す. 以上のプロセスを繰り返し行うことにより, 動的に決まる発生量の計算が可能となる.

Table 5.2: 取得したサンプルの数

年代	性別	
	男性	女性
15-19 歳	30	44
20-24 歳	84	100
25-29 歳	138	230
30-34 歳	138	230
35-39 歳	181	230
40-44 歳	171	222
45-49 歳	196	167
50-54 歳	168	153
55-59 歳	119	83
60-64 歳	86	107
65-69 歳	79	57
70-74 歳	48	18
75 歳以上	15	4
合計	3,098	

5.3 行為系列生成モデルの推定とモデル選択

本節では、提案した2つの行為系列生成モデルを Web アンケートで取得したデータに適用し、モデルの選択を行う。

5.3.1 データ

モデルの推定・選択を目的として、Web アンケートを実施した。アンケートは、豊田市・岡崎市在住者と名古屋市在住者向けに合計2回実施した。各アンケートでは、豊田市・岡崎市在住者1,454人、名古屋市在住者1,644人の合計3,098人から回答を得ることができた。モデルの評価を目的としたアンケートのため、各属性に対してサンプル数なるべく均等になるように行ったが、一部の属性については十分なサンプル数を確保できない属性もあった。取得したサンプル数の一覧は Table 5.2 に示すとおりである。Web アンケートによる調査ということもあり、高齢者のサンプルは少ないが、半数以上の属性では、100 サンプル以上のサンプルが取得できた。

アンケートでは、直近の平日について各時間帯に行った行為を尋ねた。ただし、行為は社会生活基本調査をもとに再定義した9つの行為を用いた。回答者には、この再定義された9つの行為のなかから各時間帯の行為を選択してもらった。行為の定義の詳細については、次節にて詳述する。

5.3.2 行為遷移確率の推定

社会生活基本調査には全部で20の行為が定義されている (Table 5.3)。このうちの多くは外出とは直接関係のない行為であるため、在宅と8つの外出行為に再定義した (Table 5.4)。なかには必ずしも外出に該当しない行為 (例えば、食事や休養・くつろぎ) も存在する。こうした行為に関しては、残りの行為から得られる在宅/外出の比率によって按分を行った。詳しい計算の方法は Table 5.4 に示す通りである。

2次計画問題を解くにあたっては、MATLAB® の quadprog 関数を利用した。

Table 5.3: 社会生活基本調査の行為の定義（在宅/外出は筆者が加えたもの）

番号	行為の種類	在宅/外出
1	睡眠	在宅
2	身の回りの用事	在宅
3	食事	在宅/外出
4	通勤・通学	外出
5	仕事	外出
6	学業	外出
7	家事	在宅
8	介護・看護	在宅
9	育児	在宅
10	買い物	外出
11	移動（通勤・通学を除く）	外出
12	テレビ・ラジオ・新聞・雑誌	在宅
13	休養・くつろぎ	在宅/外出
14	学習・自己啓発・訓練（学業以外）	外出
15	趣味・娯楽	外出
16	スポーツ	外出
17	ボランティア活動・社会参加活動	外出
18	交際・付き合い	外出
19	受診・療養	外出
20	その他	外出

Table 5.4: 再定義した行為

番号	行為の種類	計算方法
1	在宅	在宅行為 + (食事 + 休養・くつろぎ) × 在宅率
2	仕事	仕事 + 通勤・通学 × (仕事) / (仕事 + 学業)
3	学業	学業 + 通勤・通学 × (学業) / (仕事 + 学業)
4	買い物	買い物
5	趣味・娯楽	趣味・娯楽
6	スポーツ	スポーツ
7	受診・療養	受診・療養
8	外食	食事 × 外出率
9	その他外出	上記以外の外出行為 + 休養・くつろぎ × 外出率

5.3.3 モデル選択の手順

モデル選択は Figure 5.5 に示す手順で行った。まず、Web アンケートによって取得した個票データを集計処理し、時間帯別の行為者率データと1日の行為者率データを作成する。続いて、これらを入力として1次モデル・2次モデルそれぞれの遷移確率を求める。最後にモデル選択基準の一つである AIC (Akaike's Information Criterion) を用いてモデルの選択を行う。

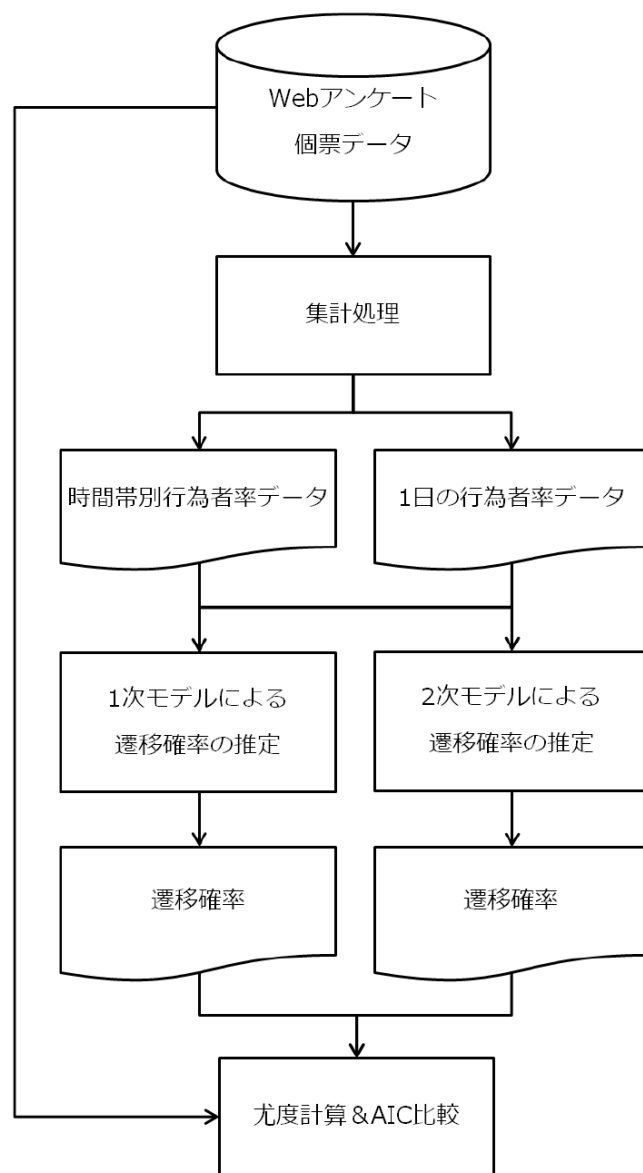


Figure 5.5: モデル選択のフロー

5.3.4 行為遷移確率行列の推定結果

ここでは、個票データから求めた遷移確率行列と推定した遷移確率行列の結果の一例を Figure 6 と Figure 7 にそれぞれ示す。図の比較から同じ行為間の遷移や、在宅-仕事間などの遷移に関しては、比較的良く再現できている一方で、買い物やその他活動などの人によって活動時間が異なる行為に関しては値が異なる傾向にある。




Figure 5.6: 個票データから求めた 30-34 歳男性の遷移確率行列（白抜きはデータが存在しない箇所）




Figure 5.7: 30-34 歳男性の遷移確率行列の推定結果




Figure 5.8: AIC の比較

5.3.5 AIC の計算方法

モデルの選択の基準となる AIC は、アンケートデータを集計して得られる 1 日の行為者数が得られる尤度 L を用いて以下の式で計算する：

$$AIC = -2(\ln L - n_p) \quad (5.52)$$

ここで、 n_p はパラメータ数で、1 次のモデルの場合は行為の種類 n であり、2 次のモデルの場合は $2n$ である。

いま、属性 k に対するアンケートで得られたサンプル数を $l^{(k)}$ とし、1 日のうちに少しでも行為 i を行った人の数を $l_i^{(k)}$ としたときに、モデル \mathcal{M}_j によって $l_i^{(k)}$ が得られる尤度を $P(l_i^{(k)} | l^{(k)}, \mathcal{M}_j)$ と表すことにする。このとき、この行為 i の 1 日の行為者数が得られる尤度は、二項分布を用いて表すことができ、

$$P(l_i^{(k)} | l^{(k)}, \mathcal{M}_j) = \binom{l^{(k)}}{l_i^{(k)}} \cdot \{P_i^{(\text{day})}\}^{l_i^{(k)}} \cdot \{1 - P_i^{(\text{day})}\}^{l^{(k)} - l_i^{(k)}} \quad (5.53)$$

となる。ただし、ここで $P_i^{(\text{day})}$ はモデルで得られた行為 i の 1 日の行為者率であり、1 次のモデルであれば式 (5.21)-(5.22) を用いて計算される。各行為の 1 日の行為者数が独立であると仮定すれば、全行為の 1 日の行為者数が同時に得られる尤度は各行為の 1 日の行為者数の尤度の積で書けて、

$$L = P(l_1^{(k)}, \dots, l_n^{(k)} | l^{(k)}, \mathcal{M}_j) \quad (5.54)$$

$$= \prod_i P(l_i^{(k)} | l^{(k)}, \mathcal{M}_j) \quad (5.55)$$

$$= \prod_i \binom{l^{(k)}}{l_i^{(k)}} \cdot \{P_i^{(\text{day})}\}^{l_i^{(k)}} \cdot \{1 - P_i^{(\text{day})}\}^{l^{(k)} - l_i^{(k)}} \quad (5.56)$$

となる。

5.3.6 AIC の比較

属性別の AIC の比較を Figure 5.8 に示す。比較の結果、全 26 ケース中 21 ケースで 1 次のモデルの方が AIC が低いという結果が得られた。一方で、2 次のモデルの方が AIC が低かった 5 ケースはいずれも女性であった。この理由としては、女性の方が行動パターンが複雑で 1 次のモデルでは表現しきれない可能性がある。




Figure 5.9: スムージングの例 (実線が元データ, 破線がスムージング後). 左から $\delta = 0.1, 0.01, 0.001$.

5.3.7 データ生成の尤度

本節の最後に、アンケートデータそのものが得られる尤度について計算を行う。各時間帯ごとの行為の生成確率を計算することにより、個票データの再現性を確かめる。

以下では、アンケートデータによって得られる属性 k のサンプルを $D^{(k)} = \{\mathbf{d}_1^{(k)} \dots \mathbf{d}_{l^{(k)}}^{(k)}\}$ と表す。モデル \mathcal{M}_j からデータが得られる尤度を $P(D^{(k)}|\mathcal{M}_j)$ と書き表すと、1つのデータが得られる平均対数尤度は、

$$\frac{1}{l^{(k)}} \ln P(D^{(k)}|\mathcal{M}_j) = \frac{1}{l^{(k)}} \sum_h \ln P(\mathbf{d}_h^{(k)}|\mathcal{M}_j) \quad (5.57)$$

となる。

しかし、ここで1つ問題が発生する。式 (5.57) の中で1つでも発生確率が0のデータが存在すると全体の確率が0 (対数をとると $-\infty$) になる。これは、確率的な言語モデルなどではよく起こる問題で、「ゼロ頻度問題」と呼ばれ、ある単語の生起確率を計算する際に、その単語が学習データに含まれていないと生起確率が0になる問題を指す。この問題の一般的な回避方法としてはスムージングがある。例えば、ある行為が出現する確率 P_i に対し、小さな正の値 δ を用いて

$$P_i \rightarrow \frac{P_i + \delta}{1 + \delta N} \quad (5.58)$$

と置き換えることで、確率が0になることを回避できる。ただし、式中の N は行為の種類である。Figure 5.9 に式 (5.58) によるスムージングの例を示す。 δ を大きくすると元のデータから大きく乖離する様子が分かる。

また、元データに対してスムージングを行っても、その後に2次計画問題を解く際に、解が0になっては意味がない。そこで、遷移確率の制約式である式 (5.10)、(5.38) の右辺を0の代わりに正の微小な値 ϵ に変更する。

δ の選び方に関しては、 $\epsilon = 0.00001$ と固定した上で、テストデータに対する平均対数尤度が高くなるものを選んだ。35-39歳の女性のデータを用いて評価した結果、 $\delta = 0.01$ 以下では対数尤度はほとんど変化しなかった。そこで、時間帯別の行為者率誤差を減らすために δ として十分小さい値 0.0001 を評価では用いることとした。

データ生成の尤度の比較対象として、個票データから最尤推定を行うことにより得られる遷移確率を用いた場合の尤度の計算も行う。この遷移確率は時刻 t における行為 j から i への遷移の頻度 $n_{ij}^{(t)}$ を用いて以下のように求められる：

$$P^{(t)}(i \leftarrow j) = \frac{n_{ij}^{(t)}}{\sum_i n_{ij}^{(t)}}. \quad (5.59)$$

このときの尤度は、個票データから求めた最尤値であることから1次のマルコフ性を仮定した場合の最大値である。したがって、提案の1次のモデルの尤度が完全に




Figure 5.10: データ生成の平均対数尤度の比較

一致した場合、同じ遷移確率行列が得られていることを意味する。また、そもそもこの遷移確率を用いた尤度が低い場合、その属性に関しては1次のマルコフ性の仮定では十分に表現ができていないと考えられる。

データの生成に対する平均対数尤度の比較を Figure 10 に示す。比較の結果、1次モデルは全ての属性において、2次モデルよりもデータ生成尤度が高いことが明らかになった。また、個票データから求めた尤度が高い属性に関しては、提案手法でも高い尤度を得られていることが分かった。

この平均対数尤度から時間帯あたりの予測確率を計算してみると、30-34歳男性の場合、個票データからの推計で $\exp(-6.0/24) \sim 0.78$ 、1次モデルの場合で $\exp(-7.8/24) \sim 0.72$ となり、提案の1次モデルを用いても比較的良好な結果が得られている。

以上のことから、対案した2つのモデルの比較では、1日の行為者数のAIC、データ生成尤度のどちらの観点からも1次モデルを支持する結果となった。以上の結果から、次節で述べるモデルの適用では、1次のモデルを採用することとする。

5.4 モデルの適用

本節では、これまで説明してきた移動行動生成モデルを実際の集計データセットへ適用し、携帯電話から得られる人口統計情報であるモバイル空間統計 [90] との比較検証を行う。モバイル空間統計は、NTTdocomoの携帯ネットワークの仕組みを使用して作成される人口統計情報で、docomoのユーザ約6,500万人の所在する基地局の情報をを用いることから高い信頼性を持つ滞在人口を提供することができる。

5.4.1 データセットと処理過程

今回使用したデータセットは以下の通りである。

- 国勢調査地域メッシュ統計 (2010)
- 社会生活基本調査 (2011)
- 経済センサス (2009)
- 商業統計メッシュデータ (2007)
- 昼間人口他計算指標¹
- Web アンケート (平均移動距離算出のため)

¹ 「H17年国勢調査、H18年事業所・企業統計調査等のリンクによる地域メッシュ統計」を元に作成されたもの。

これらのデータセットに移動行動生成モデルを適用し、対象地域の都市内の移動行動の推定を行う。評価にはモバイル空間統計（2014年4月の平日の平均値）を用いる。

データの適用のおおまかな流れは以下の通りである。

1. 国勢調査の属性別（性・年齢層）の3次（1km）メッシュ人口に基づき、エージェントを生成。ただし、評価に用いるモバイル空間統計の対象に合わせ、15-79歳のみを生成
2. エージェント毎に社会生活基本調査から学習した遷移確率を用いて行為系列を生成
3. 目的地選択確率の計算に必要な目的地の魅力度の指標をデータセットから抽出し、これらを用いて目的地選択確率を学習し、学習した結果を用いて目的地系列を生成する。ただし、メッシュ間の距離にはメッシュ間の中心距離を用いる。また、同一メッシュ内の距離は500mとした。各行為に関する指標は以下のものを用いた。
 - 仕事：全産業従業者数²（経済センサスより抽出）
 - 学業：生徒・学生数（対象エリア内の全高校・大学の生徒数）
 - 買物：小売業年間販売額（商業統計より抽出）
 - 受診・療養：病院数，診療所数，歯科医院数の重み付き和³（施設数は、昼間人口計算指標より抽出）

また、今回は上記以外の行為が選択された場合には移動が発生しないと仮定した。

前述したように、距離に関するパラメータ γ は、平均移動距離を制約として計算が可能となる。行為別の移動距離は、Webアンケートの結果から算出した（詳細は5.4.4節を参照のこと）。

5.4.2 対象地域

モバイル空間統計による評価対象エリアとして、豊田市の中心部を含む309メッシュ（人口約27万人）を設定した。また、モデルの対象地域は、Figure 5.11に示す通りである。対象地域は、豊田市との往来が多い岡崎市の市街地、みよし市と安城市の一部を含むおよそ500km²のエリアで、メッシュ数は576、エリア人口は約72万人となった。

5.4.3 行為系列生成モデルの適用

社会生活基本調査から遷移確率行列を推定し、行為系列を生成した。社会生活基本調査の時間帯別行為者率は15分単位の集計データであるが、今回は1時間単位で平均化を行い、推定を行った。Figure 5.12に、生成された行為系列のサンプルを示す。

²経済センサスでは、事業所の所在地情報を緯度経度に変換し、それぞれのメッシュに割り当てている。したがって、メッシュを跨がる大規模な事業所・工場などは、ある一つのメッシュに全ての従業員数が割り当てられるという問題が起こる。そこで、そのような大規模な事業所に関しては、有価証券報告書から工場・事業所の2009年度の従業員数を取得し、各メッシュへの負担率に応じて従業員数を按分する処理を行った。

³医療施設に関する重みは、病院：250，診療所：40，歯科医院：20に設定した。大規模な病院に関しては、1日の平均外来患者数の実績値を使用した。

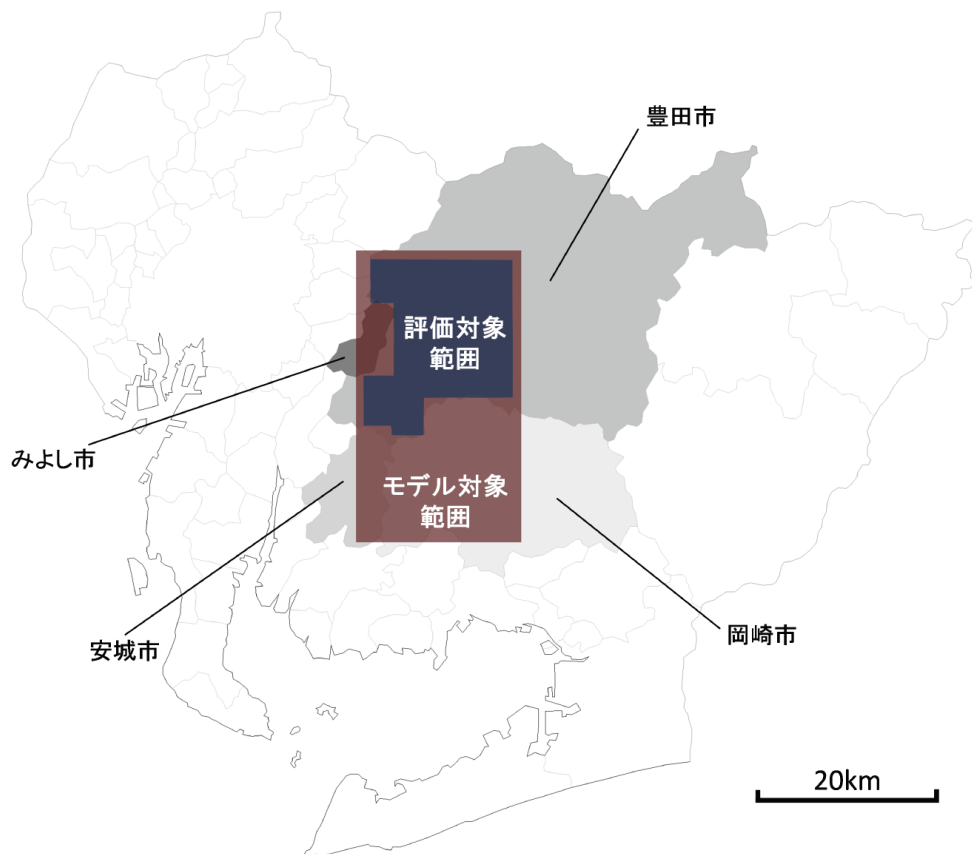


Figure 5.11: 対象地域 (CraftMap[2] をもとに作成)

5.4.4 目的地系列生成モデルの適用

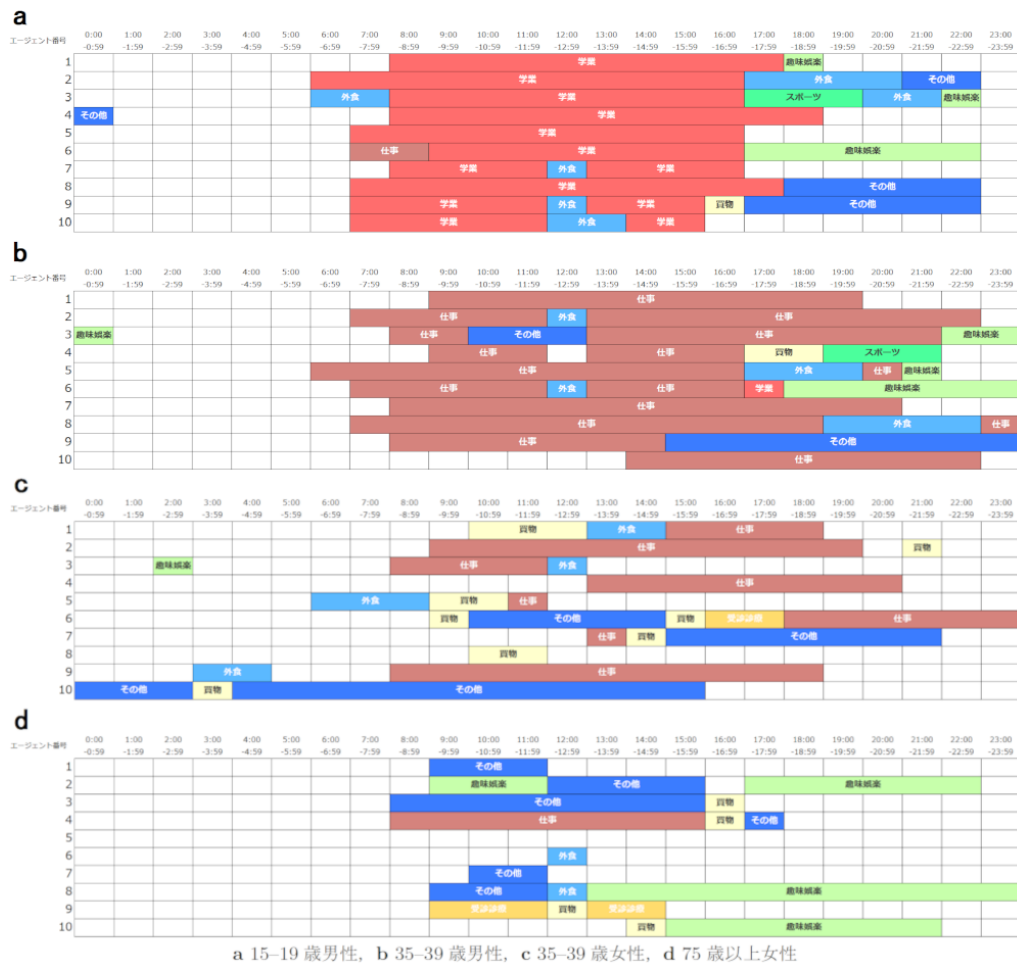
距離に関するパラメータ γ を計算する。Web アンケートでは、1日の滞在場所を地図上に示してもらった。地図上の滞在場所から移動距離を直線距離で求め、行為ごとの平均値を算出した。求められた平均移動距離は、それぞれ、仕事：3.81km、学業：3.86km、買物：2.15km、受診・療養：2.70kmとなった。これらの平均移動距離が所与の下、エントロピーモデルを適用した結果、以下のパラメータ γ が得られた。

- 仕事：0.449
- 学業：0.509
- 買物：1.638
- 受診・療養：0.708

5.4.5 推定結果の検証

推定されたメッシュ人口とモバイル空間統計の時間帯別滞在人口の比較を行った。モバイル空間統計と推定値の3時間毎のメッシュ人口の比較を Figure 5.13 に示す。ただし、Figure 5.13 の右下の図のみは、モバイル空間統計の4時台と国勢調査の比較を示している。

国勢調査との比較から分かるように国勢調査とモバイル空間統計の夜間人口に関しても両者は完全には一致しない。これは国勢調査が常住人口を示す一方で、モバイル空間統計は対象時間帯に実際にいたエリアをもとに集計がなされているため



a 15-19 歳男性, b 35-39 歳男性, c 35-39 歳女性, d 75 歳以上女性

Figure 5.12: 生成された行為系列 (空白は在宅)

である。個別のメッシュごとに分析を行ったところ、電話の携帯が許可されていないであろう刑務所を含むエリアや夜勤のある工場を含むエリアで人口の違いが生じていることが分かった。また、国勢調査が2010年10月に実施されているのに対して、今回容易したモバイル空間統計のデータが2014年4月と調査日に3年半のずれがあることにも起因していると考えられる。

時間帯ごとの推計値とモバイル空間統計の比較から分かるように、いずれの時間帯も国勢調査とモバイル空間統計の相関と同等、もしくはそれ以上の相関を示しており、良好な推計値が得られていることが分かる。

次に、属性別にメッシュ人口の比較を行い、得られた相関係数の時間変化をFigure 5.14に示す。図より、20代以上の全ての年代において時間帯に関わらず、高い相関があるという結果が得られた。一方で、10代に関しては、相関係数が0.5-0.7と他の世代に比べて低い相関という結果となった。

この主な原因としては、夜間の時間帯においても相関が低いことから、国勢調査とモバイル空間統計自体にずれがあることに起因していると考えられる。このずれのさらなる原因としては、調査年度に開きがあることや10代の携帯電話保有率が他の世代に比べて低いことによるモバイル空間統計の推計精度の低下などが考えられる。

本節では、提案した移動行動生成モデルを実データへ適用し、携帯電話の基地局情報から得られる滞在人口情報と比較を行った。結果は、良好な推計ができていたことを確認したものの、使用するデータによっては、推計時点と統計調査のタイミングにより最新の情報が反映できないという課題がある。また、受診・療養行為については病院、診療所、歯科医院の魅力度の重みをそれぞれ一律に設定してお

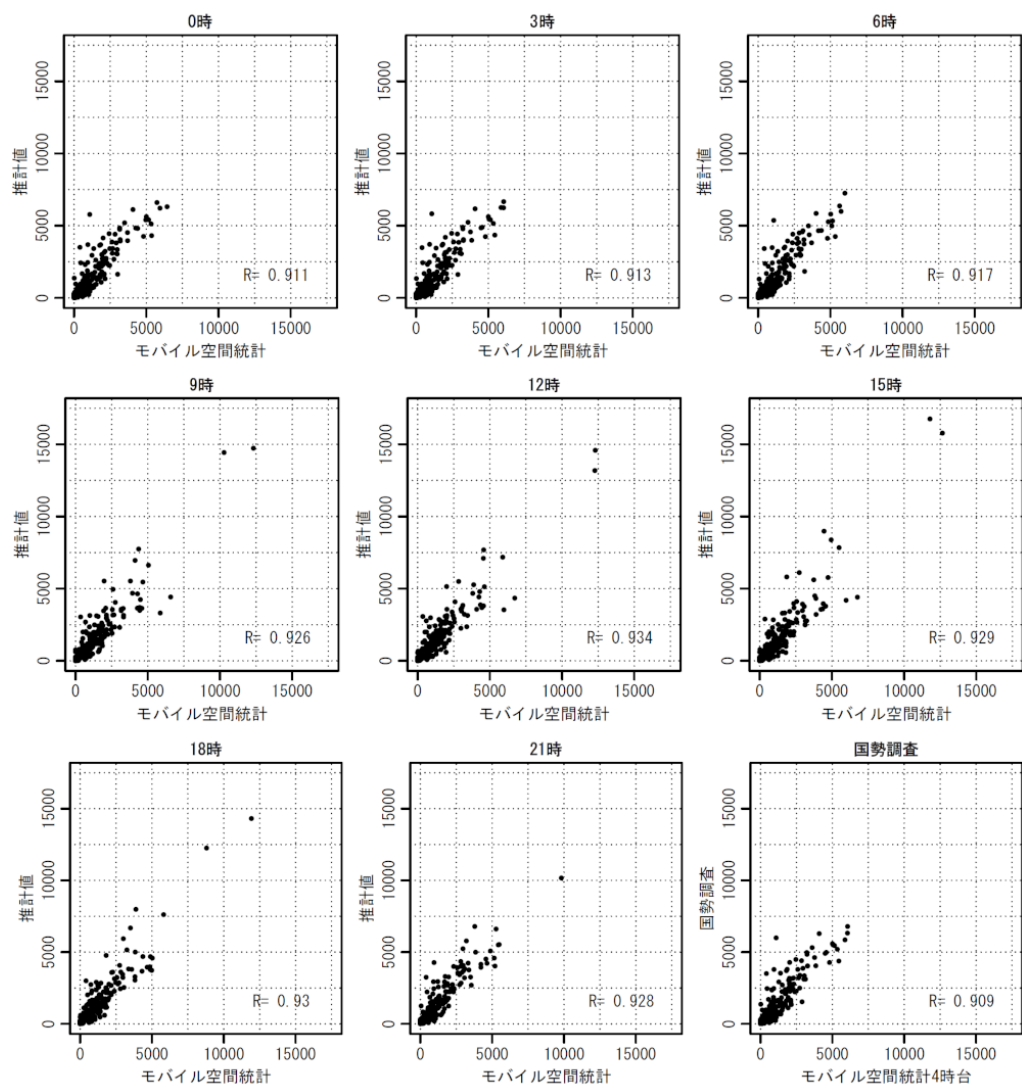


Figure 5.13: モバイル空間統計と推計値のメッシュ人口比較（右下図のみモバイル空間統計4時台と国勢調査の比較）

り、実際の病院の規模を反映できていないという課題が残る。そこで、次節では移動目的ごとの魅力度を、より更新頻度の高い別の公開情報を手掛かりに算出し、更新する手法について提案する。

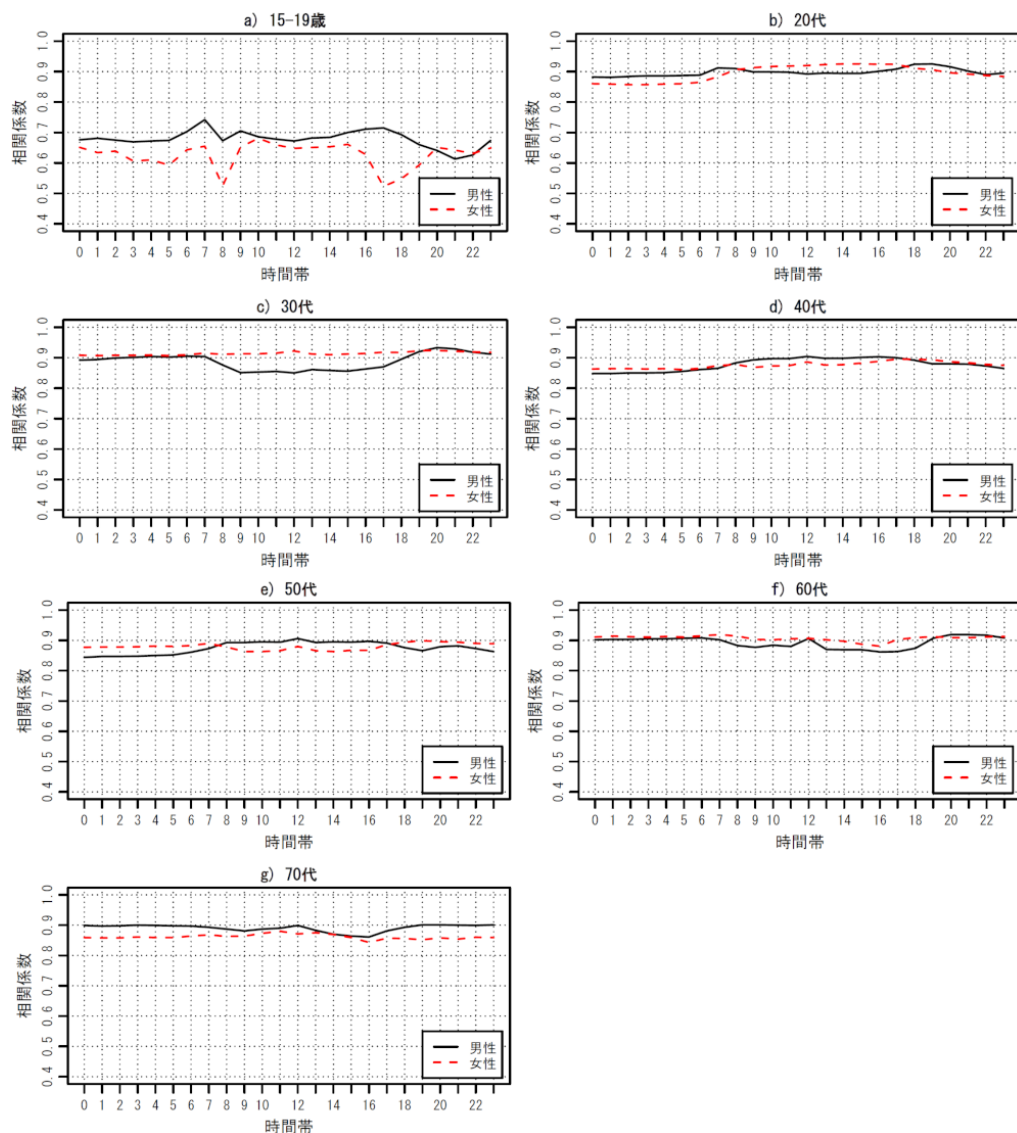


Figure 5.14: モバイル空間統計と推計値の相関係数の時間変化（属性別）

5.5 統計データの時点更新

前節では、提案した移動行動生成モデルを携帯電話の基地局情報から得られる滞在人口をもとに比較検証を行い、良好な推計を確認することができた。一方で、提案手法が抱える問題として、統計調査のタイミングによっては最新の情報が反映できないという課題があった。また、受診・療養行為に関しては、外来患者数に相当する魅力度の設定が難しいという課題があった。本節では、この2つの課題に対して、より更新頻度の高い別の公開情報をもとに推計する方法について提案する。以降の節では、まず始めに、前節までの方法では最新の情報が反映できないような対象地域の選定を行い、その後に対象地域を例に提案する推計方法について詳述する。

5.5.1 対象地域の選定

対象地域の選定として、以下の2つの条件により選定を行った。

1. 移動が対象範囲内で比較的閉じていること

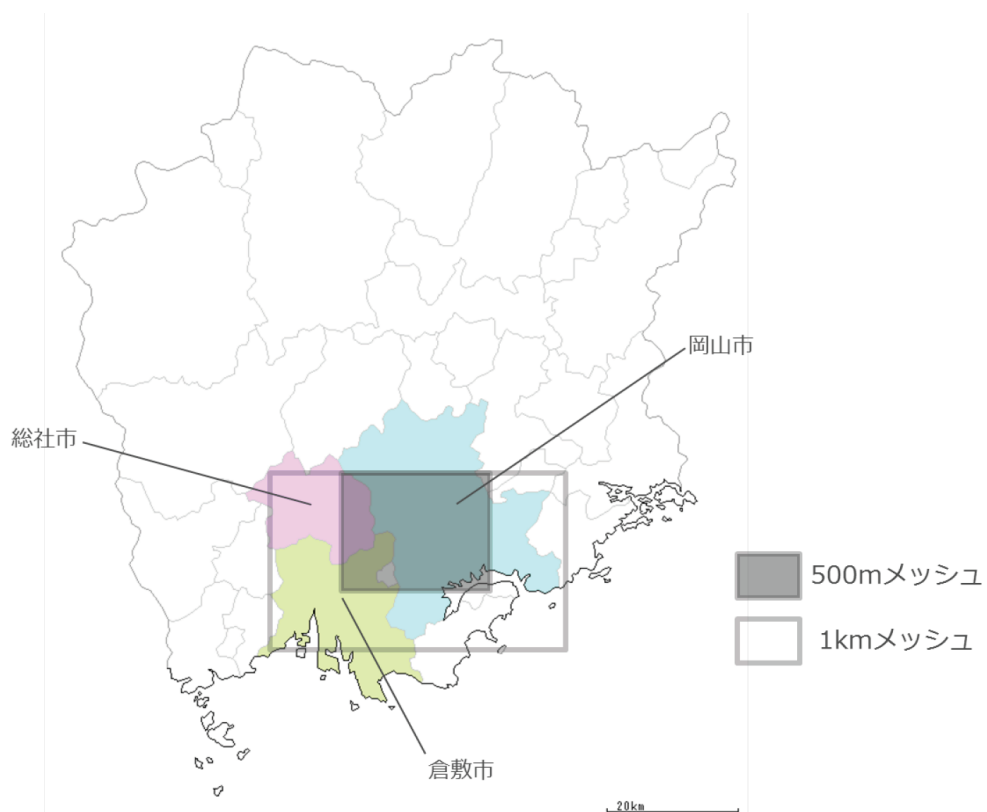


Figure 5.15: 対象地域 (CraftMap[2] をもとに作成)

2. 商業統計 (2007) ではデータに反映されていない 2007 年以降に大規模な商業施設等が開店していること⁴

1つ目の条件は現状のモデルが対象範囲外への移動を陽に扱うことができないための条件であり、また、2つ目の条件は提案する手法によって移動の変化を捉えることができるかを確認するための条件となっている。

条件を満たす地域として岡山市を選定した。岡山市は岡山県の県庁所在地で人口約 70 万人、2009 年には政令指定都市に指定されている。また、その南側を瀬戸内海、北側を中国山地に囲まれており、多くの移動を東西に制限された地域でもある。岡山市中心部には 2014 年末にイオンが西日本最大規模の旗艦店と位置付ける「イオンモール岡山」が開業している [91]。

Figure 5.15 に対象とする地域を示す。都市雇用圏地図 [92] を参考に近隣の倉敷市、総社市を含む範囲で対象地域を設定した。対象地域は標準地域メッシュの 2 次メッシュ区画で 12 区画分、東西約 40km、南北約 30km の約 1,200km² となった。

対象地域内の総人口は約 125 万人、うち対象とする 15-79 歳人口は約 98 万人となった⁵。計算時間の削減のため、メッシュサイズは中心部の 20km 四方のみを 4 次メッシュ (500m メッシュ) とし、その他のエリアを 3 次メッシュ (1km メッシュ) とした。メッシュの数は合計で 2,400 となった。

⁴現在では、2014 年版の商業統計が利用できる

⁵前節同様に、評価に用いるモバイル空間統計の対象年齢に合わせてデータ作成を行ったため

Table 5.5: 校態別の生徒数算出方法

校態区分	対象	県内の数	生徒数の算出方法
大学	○	52 (学部別)	各校の HP より抽出
大学院	○	14	各校の HP より抽出
短期大学	○	23 (学科別)	各校の HP より抽出
高等専門学校	○	4 (学科別)	各校の HP より抽出
高等学校	○	89	ポイントデータより抽出
高等学校通信課程		3	
中等教育学校	○	2	生徒数 ÷ 2
中学校		172	
小学校		419	
幼稚園		330	
盲学校		1	
ろう学校		1	
養護学校		13	
各種学校		15	
専修学校	○	49	募集定員 × 履修年数

5.5.2 適用方法

本節では、移動の対象とする4つの目的（仕事/学業/買物/受診・療養）について魅力度の算出方法を説明する。

5.5.2.1 仕事の魅力度

仕事の魅力度は、平成26年（2014年）経済センサス500mメッシュデータの全産業従業者数をそのまま用いた[93]。

5.5.2.2 学業の魅力度

学業の魅力度には、学校ポイントデータ[94]に収録されている緯度経度をメッシュごとに集計した生徒数を用いた。ただし、学校ポイントデータに収録されている生徒数は全ての学校の生徒数を網羅しておらず、また、大学に関しては生徒数でなく入学定員が収録されているため、各学校のHPを参考に生徒数の情報を収集した。専修学校については生徒数が記載されている学校がないため、入学定員 × 履修年数により算出した。Table 1に校態別の生徒数の算出方法についてまとめる。

5.5.2.3 買物の魅力度

買物の魅力度には、商業統計から得られる小売業の年間商品販売額を用いた。ただし、メッシュ内の小売事業者数が2店舗以下の場合、販売額は秘匿されるため、秘匿のされていない項目である小売業計従業者数と年間商品販売額の関係を用いて、秘匿されているメッシュの年間販売額を推定した。Figure 5.16に小売業計従業者数と年間商品販売額の関係を示す。ここでは、単純な線形関係を仮定し、得られた回帰式を用いて秘匿されているメッシュの販売額を推定した。

しかしながら、前述のように商業統計は2007年のデータであるため、最近の実情が反映されていない。前述のように岡山市中心部には「イオンモール岡山店」が開店し、これにより周囲の買物の人流れは大きく変わったと考えられる。これを反映するため、商業統計の調査日である2007年6月1日以降に大規模店舗立地法




Figure 5.16: 小売業計従業者数と年間商品販売額の関係

に基づいて届出のあった大規模店舗（店舗面積が 1,000m² 以上）について岡山県、岡山市、倉敷市の各 HP に公開されている届出情報を収集した [95, 96, 97].

次に、予め商業統計から売場面積と年間販売額の回帰式を求めておき、この回帰式をもとに新規店舗の年間販売額の推計を行った⁶ (Figure 5.17). この販売額を商業統計から得られるメッシュ別の販売額と足し合わせることで現在の販売額を算出し、買物の魅力度とした.

5.5.2.4 受診・療養の魅力度

医療機関のポイントデータは国土交通省の国土数値情報ダウンロードサービスより入手可能である [98]. しかしながら、ポイントデータから作成される魅力度はメッシュ内の医療機関数であり、医療機関の規模を考慮できるものとはなっていない. 一方で、厚生労働省地方厚生局が公開している保険医療機関・保険薬局のコード内容別医療機関一覧表 [99] からは常勤医師数・非常勤医師数等の情報を収集できる. そこで、常勤医師数を足掛かりに 1 日の平均外来患者数の推計を行った. まず、厚生労働省病院報告 [100] から病床規模別にみた 1 病院当たりの常勤換算医師数を対応づけ、さらに、外来患者延数、病院の種類、病床規模のデータから外来患者と病床規模を対応づけることで、常勤換算医師数と平均外来患者数を対応づけた (Figure 5.18). 求められた常勤換算医師数と平均外来患者数の関係を Figure 5.19 に示す. この結果から、常勤換算医師数が 1 人であれば、約 34 人の外来患者数という関係が得られた.

国土数値情報と中国四国厚生局管内の医療機関一覧表の名寄せ作業により、約 85% の病院・診療所において常勤医師数を取得することができた. 残りの約 15% の病院・診療所に関しては一律 30 人の外来患者数とした. また、歯科医院に関しては一律 20 人の外来患者数とした.

外来患者数の推計の妥当性を検証するため、岡山県医師研修支援機構 HP の登録医療機関 [3] に平均外来患者数の記載のあった 39 件に関して推計値との比較を行った (Figure 5.20). 推計値が実績に比べて約 3 割過少に推計されている理由と

⁶ 店舗面積は、売場面積に加え、ショーウィンドーやサービス施設などを含むため過大推計となることが予想されるが、入手できるデータがないため、店舗面積をそのまま用いた.




Figure 5.17: 売場面積と年間商品販売額の関係

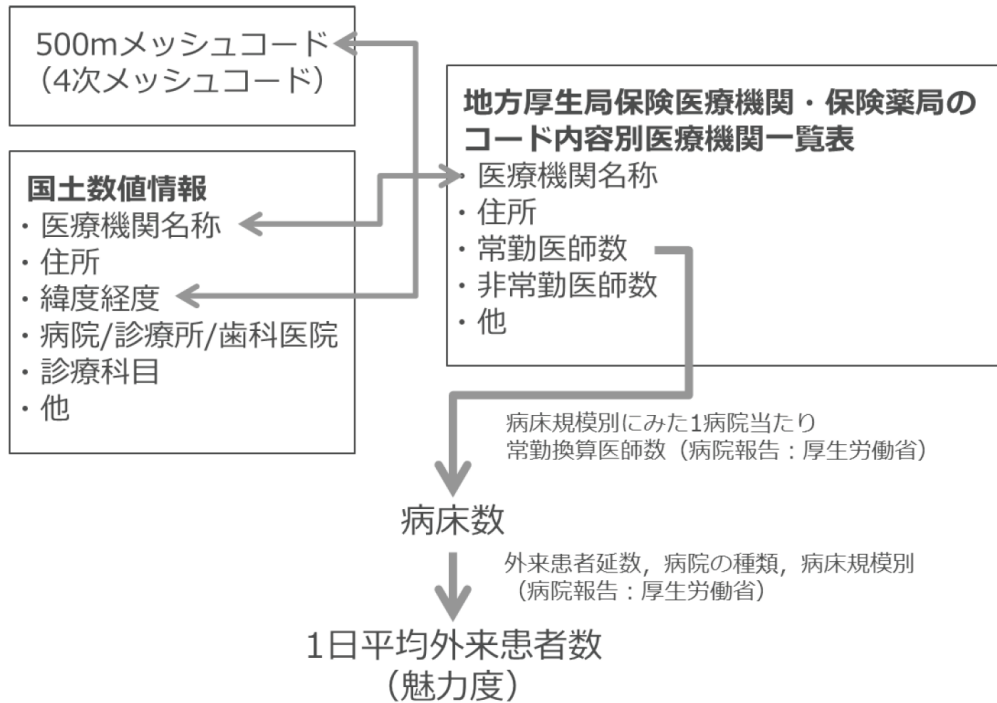


Figure 5.18: 受診・療養の魅力度算出の考え方




Figure 5.19: 常勤換算医師数と平均外来患者数の関係

して、常勤換算医師数ではなく、常勤医師数を用いて推計を行っているためであると考えられる。常勤換算医師数を求めるためには非常勤医師数を常勤医師数に換算する必要があるが、今回魅力度として用いる分には相対的な値が意味を持つため、常勤医師数から推定した平均外来患者数を魅力度として用いることとする。




Figure 5.20: 平均外来患者数の実績値と推計値の比較（実績値は岡山医師研修支援機構 HP より [3]

Table 5.6: 評価に使用したモバイル空間統計の諸元

対象区域	岡山市全域
期間	2015年4月の平日
曜日	平日
時間帯	6-21時の1時間毎
年代	10歳階
空間分解能	1km

5.5.3 滞在人口を用いた評価

5.5.3.1 評価データの概要

滞在人口の評価には、ここでもモバイル空間統計を用いる [90]。評価にあたっては、岡山市全域のデータを入手した。データの緒言については、Table 5.6 に示す通りである。

5.5.3.2 滞在人口分布の比較

Figure 5.21 に3時間ごとの滞在人口の分布を示す。滞在人口の空間分布は、どの時間帯に対しても良い再現ができていることが分かる。また、滞在人口の比較の散布図を Figure 5.22 に示す。こちらもどの時間帯を見ても概ね良い推計ができていることが分かる。ただ、一部のメッシュにおいて過大に推計されている様子が見取れる。過大推計が起きているメッシュの位置を調べたところ、岡山駅周辺の数か所のメッシュと岡山大学を含むメッシュであることが分かった。まず、岡山駅周辺に関して、滞在者の移動目的の内訳を調べたところ、仕事の目的の人が多いことが分かった。このことから考えられる原因としては、魅力度の指標である経済センサスの全従業者数がパートタイマーなどの短時間労働者を含んでいるにも関わらず、仕事の魅力度としては他の正社員と同様に扱われているために、中心部のサービス業の多い地域において魅力度が過大に評価されているという可能性である。また、岡山大学を含むメッシュに関しては、隣接メッシュの滞在者数が過少に推計されており、魅力度の按分が上手くいっていないことが原因と考えられる。これらのメッシュに関しては魅力度を調整することでさらに推計値をモバイル空間統計に近づけることが可能である。

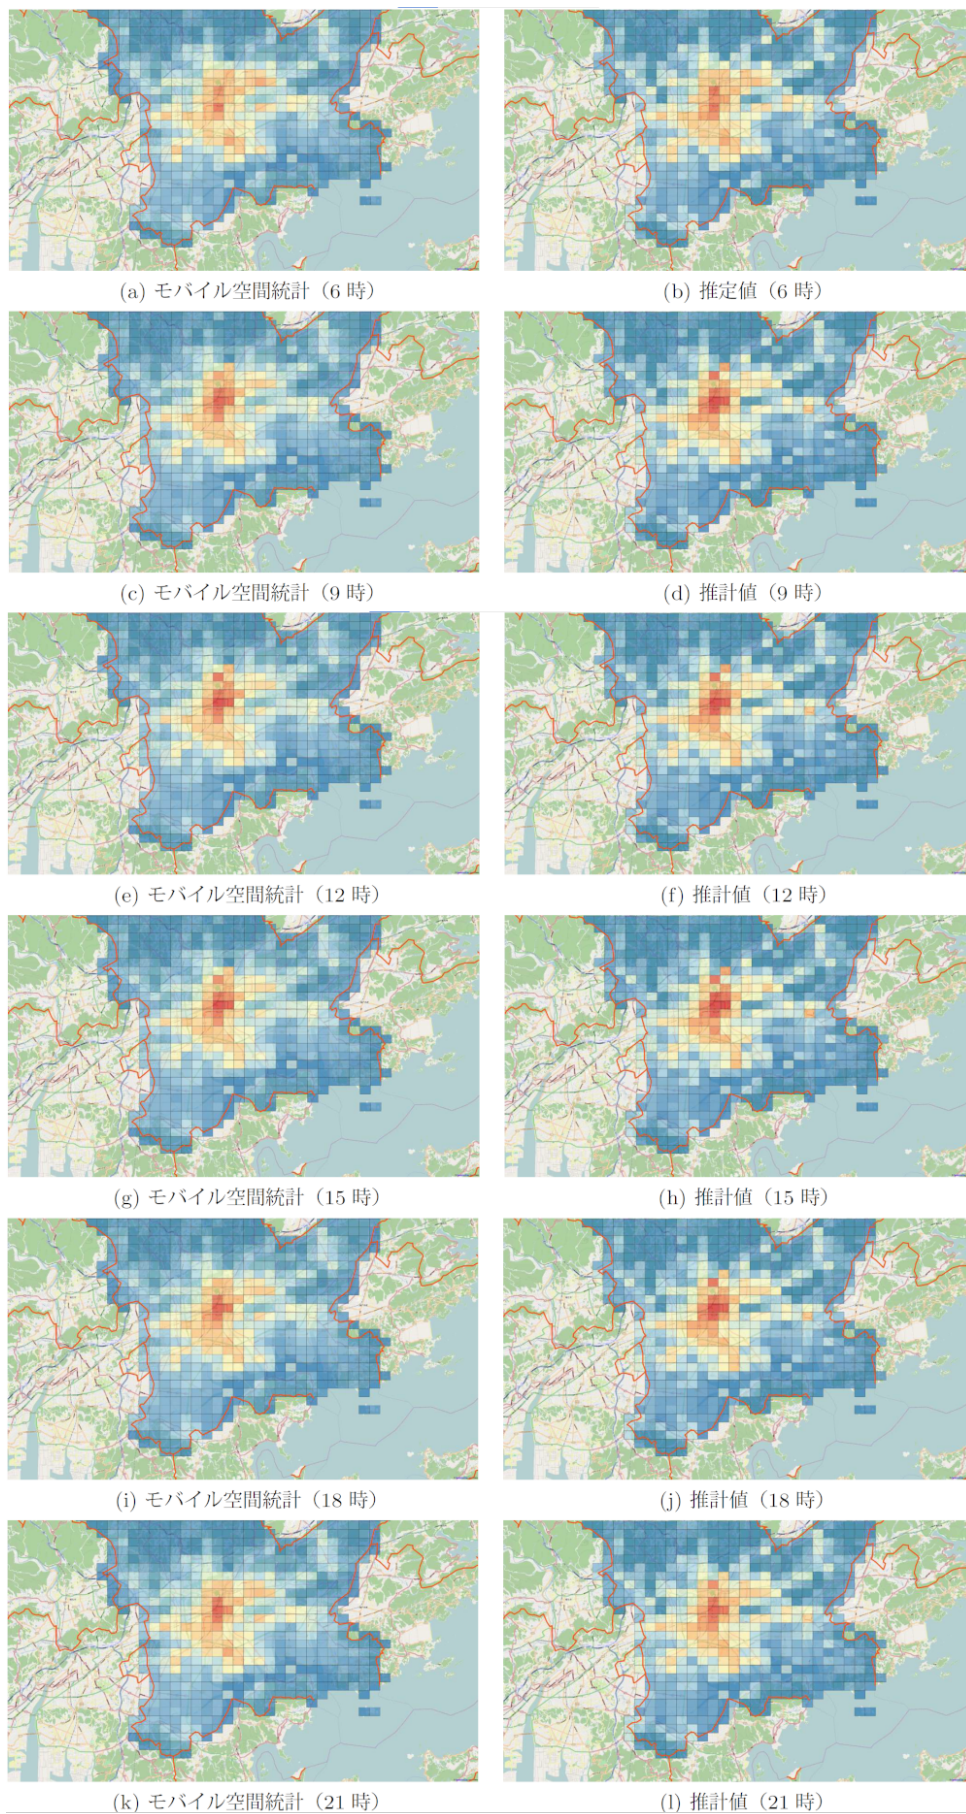





Figure 5.21: 滞在人口の空間分布の比較




(a) 6 時における滞在人口の比較




(b) 9 時における滞在人口の比較



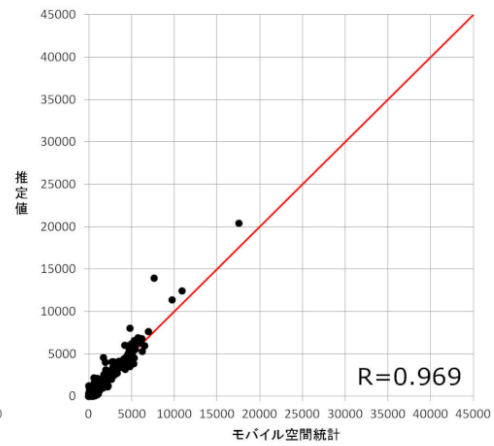
(c) 12 時における滞在人口の比較



(d) 15 時における滞在人口の比較



(e) 18 時における滞在人口の比較



(f) 21 時における滞在人口の比較

Figure 5.22: 滞在人口の比較

5.6 まとめ

本章では、国勢調査や生活時間調査のような個人情報的一切含まない集計データに着目し、これらの統合により疑似的な人の移動行動データを生成する手法を提案した。これらの集計データは利用の制約なく誰もが利用できるものであり、また、どこの地域に対しても簡便に、かつ低コストに都市内の移動行動データを生成できる。

提案モデルを携帯電話の基地局情報から作成される人口統計情報と比較検証を行った結果、時間帯別、属性別の詳細な粒度において高い再現性を持つことが確認できた。また、統計情報の更新頻度の問題に対応する方法として、大規模店舗立地法の届出情報や地方厚生局が公開する医療機関一覧を利用する方法を述べた。

今後、取り組むべき課題としては、

- 内外移動量の考慮
- 対象とする移動目的の拡充

が挙げられる。提案モデルでは、対象地域内で移動が閉じているとの仮定のもとで推計を行ったが、現実的にはさらにその外との往来を考える必要がある。また、対象とする行為9種類のうち、移動の生成を行ったのは5種類（在宅含む）であった。今回、検討できなかった行為の魅力度の定義は今後の課題である。

Chapter 6

結論

6.1 本研究の成果

人を中心に据えた街づくりへ空間を再構築しようとする取組みが進むなか、国土交通省の「スマート・プランニング」に代表されるデータ駆動型の街づくりが注目を集めている。このアプローチは、データに裏付けされた共通認識をステークホルダー間に醸成し、エビデンスに基づいた政策の決定につながると期待されている。

しかしながら、現状のスマート・プランニング手法には以下に示す3つの大きな課題があった。

1. 個人単位の詳細な移動軌跡データを十分に活かしきれていない
2. 歩行者の複雑な意思決定、回遊行動の特徴を十分に表現できていない
3. 広域からの来訪者数の推定は、四段階推計が前提となっている

これらの課題に対して、本研究ではそれぞれ新たな手法を提案し、課題の解決を図った。

第3章では、歩行者の複雑な意思決定行動の中の経路選択行動に着目し、従前の目的地指向型の移動軌跡の生成のみならず、迂回や滞在を含む回遊行動の生成が可能なモデルを提案した。また、実際の環境を模した数値実験により、現実的な環境の下でもこれらの回遊行動に特徴的な軌跡の生成が可能なことを確認した。

第4章では、歩行者の複雑な行動の表現が可能なグリッドベースの空間表現の適用のためのGPSデータの処理方法について提案した。また、歩行者の活動スケジューリング行動に着目し、活動選択と活動時間配分の同時選択を逐次的に行うことができる動的活動スケジューリングモデルの適用を行った。道の駅で取得されたGPSデータへの適用の結果、来訪者グループの属性が活動選択や活動時間の配分に与える影響を定量的に明らかにした。推定結果は、早い時間帯の方が活動時間が短くなる傾向になることを示しており、これは事前に計画しているが未実行の活動が多いことによる時間的圧力の存在を示唆していた。

第5章では、広域の来訪者数の推定のために、パーソントリップ調査に代表される大規模な交通行動調査を必要としない、新しい推計方法の提案を行った。提案方法では、日本全国どこでも安価で簡便に推計が可能である。また、一般的に入手が容易な集計データのみを使用しているため、プライバシー保護等の問題も一切発生しない。さらに、生成されるデータは属性や移動目的も付与されているため、対象とする施設にどんな属性の人が何時に来訪するかの推計が可能である。

本研究で提案した方法を組み合わせることで、広域からの来訪者の予測から、対象となる施設内の歩行者の複雑な意思決定までをカバーするマルチスケールな行動モデリングが可能となり、今後の歩行空間計画のためのツールとしての活用が期待される。

6.2 今後の課題

本研究で明らかになった課題を以下にまとめる。以下では、まず初めに個々のモデル単独での課題を示した後に、モデル間の整合性や統合に関する課題を示す。

第3章で扱った移動行動軌跡生成に関しては、到着時間制約の与え方に関する問題がある。第4章で示した動的活動スケジューリングモデルを組み合わせることで、目的地の制約は明らかにすることができた。一方で、活動時間配分は移動時間と活動時間の合計時間としての制約を与えてはいるが、移動時間と活動時間の配分までをも明らかにできていない。

第4章で扱った活動スケジューリングモデルに関しては、総滞在時間を外生的に与えているという問題がある。総滞在時間が活動スケジューリングに与える影響は大きいと考えられるが、これを定量的に把握することは今後の課題である。

第5章で扱った移動行動生成モデルに関しては、属性別の来訪者数の推計はできるものの個人を対象としたモデルになっており、家族単位などのグループを扱うことができないという問題がある。また、第4章のモデルの説明変数に含まれる子どもの数などをどのように与えるかは今後の課題である。さらに、魅力度が定義できている行為（活動）が限定的であり、趣味・娯楽といった第4章で扱った移動目的の魅力度をどのように定義するかも今後の課題である。本研究で提案した移動行動生成モデルは、四段階推計と同様に政策に関する感度がないモデルであることにも留意する必要がある。ただし、本研究のモデルは魅力度として小売業販売額のように集計量を必ずしも指定する必要がないため、政策感度のある代替指標を魅力度に指定することで政策感度を持つモデルへの拡張が可能である。その際、直線距離による移動量の減衰の表現を所要時間や一般化コストへ変更する必要がある。

モデルの共通の問題として、環境の魅力度を直接的に数値に反映するのみのモデルとなっている問題がある。「賑わいのある街づくり」を目指していく上では、「賑わいの表現」を含む相互作用のモデル化に取り組む必要がある。

モデル間の整合性の問題として以下のものがある。第3章と第4章における時間の取り扱いに関する整合性の問題もある。第3章では、時間割引率を導入することで将来に渡る効用を割引いていた一方で、第4章では、時間に対する対数関数のモデルを用いることで限界効用の逡減を表現していた。これらのモデルを統合する上で、時間の取り扱い方を統一したモデルにする必要がある。

また、第3章と第4章のモデルを統合するためには、第3章で得られる期待効用を第4章のモデルに反映し、第4章で得られた時間配分の結果を第3章の制約に反映しながら、それぞれのモデルを繰り返し計算し均衡解を求めるなどの工夫が必要となる。モデル間の統合は大きな課題の一つである。

最後に、本研究で提案した枠組みは歩行空間計画のためのマルチスケールな行動を扱うことができる枠組みであるが、全てを組み合わせた推計までは示すことが出来なかった。マルチスケールなモデルを全体で実施するツールとして整備していくことが、今後の歩行空間計画への活用のために最も重要な一歩であると考えられる。

Appendix A

最大エントロピー逆強化学習の対数尤度関数の計算

本節では、3.2.2 節の式 (3.10) の導出について説明する。

$$\boldsymbol{\theta}^* = \operatorname{argmax}_{\boldsymbol{\theta}} \sum_i \log P(\zeta_i | \boldsymbol{\theta}) \quad (\text{A.1})$$

$$= \operatorname{argmax}_{\boldsymbol{\theta}} \sum_i \log \frac{\exp \{R(\zeta_i)\}}{\sum_{\zeta \in Z} \exp \{R(\zeta)\}} \quad (\text{A.2})$$

$$= \operatorname{argmax}_{\boldsymbol{\theta}} \sum_i \left\{ R(\zeta_i) - \log \sum_{\zeta \in Z} \exp \{R(\zeta)\} \right\} \quad (\text{A.3})$$

式 (A.3) の第 1 項は、3.2.2 節で見たように $R(\zeta_i) = \sum_{s \in \zeta_i} \boldsymbol{\theta}^\top \mathbf{f}_s$ である。第 2 項は、軌跡の log-sum 項であるので、初期位置に対する状態価値関数に一致する。したがって、式 (3.10) が得られる。

$$\boldsymbol{\theta}^* = \operatorname{argmax}_{\boldsymbol{\theta}} \sum_i \left\{ \left(\sum_{s \in \zeta_i} \boldsymbol{\theta}^\top \mathbf{f}_s \right) - V^{\approx}(s_{t=0}) \right\} \quad (\text{A.4})$$

References

- [1] 国土交通省都市局都市計画課都市計画調査室. 都市調査の動向. 都市と交通, Vol. 98, pp. 2-3, 2014.
- [2] CraftMap. Craftmap hp. <http://www.craftmap.box-i.net/> (参照 2021-04-15).
- [3] NPO 法人岡山医師研修支援機構. 登録医療機関一覧. http://www.ishikenshuushien.com/institution_search.php(参照 2021-04-16).
- [4] 国土交通省 都市局街路交通施設課. 街路空間の再構築・利活用に向けた取組～居心地が良く歩きたくなる街路づくり～. https://www.mlit.go.jp/toshi/toshi_gairo_tk_000081.html (参照 2021-03-26).
- [5] Matthew Carmona. Place value: place quality and its impact on health, social, economic and environmental outcomes. *Journal of Urban Design*, Vol. 24, No. 1, pp. 1-48, 2019.
- [6] Vikas Mehta. Lively streets: Determining environmental characteristics to support social behavior. *Journal of Planning Education and Research*, Vol. 27, No. 2, pp. 165-187, 2007.
- [7] Jamie Anderson, Kai Ruggeri, Koen Steemers, and Felicia Huppert. Lively social space, well-being activity, and urban design: Findings from a low-cost community-led public space intervention. *Environment and Behavior*, Vol. 49, No. 6, pp. 685-716, 2017.
- [8] 国土交通省都市局 都市計画課都市計画調査室. スマート・プランニング実践の手引き～個人単位の行動データに基づく新たなまちづくり～【第二版】. <https://www.mlit.go.jp/common/001255680.pdf> (参照 2021-03-27).
- [9] Serge P Hoogendoorn and Piet HL Bovy. Pedestrian route-choice and activity scheduling theory and models. *Transportation Research Part B: Methodological*, Vol. 38, No. 2, pp. 169-190, 2004.
- [10] Aloys Borgers and Harry Timmermans. A model of pedestrian route choice and demand for retail facilities within inner-city shopping areas. *Geographical analysis*, Vol. 18, No. 2, pp. 115-128, 1986.
- [11] Hieronymus C Borst, Henk ME Miedema, Sanne I de Vries, Jamie MA Graham, and Jef EF van Dongen. Relationships between street characteristics and perceived attractiveness for walking reported by elderly people. *Journal of Environmental Psychology*, Vol. 28, No. 4, pp. 353-361, 2008.
- [12] Jan Gehl. *Cities for People*. Island press, 2013.
- [13] Victor J Blue and Jeffrey L Adler. Cellular automata microsimulation for modeling bi-directional pedestrian walkways. *Transportation Research Part B: Methodological*, Vol. 35, No. 3, pp. 293-312, 2001.

- [14] Khandker M Nurul Habib. A random utility maximization (rum) based dynamic activity scheduling model: Application in weekend activity scheduling. *Transportation*, Vol. 38, No. 1, pp. 123–151, 2011.
- [15] Alan Penn and Alasdair Turner. Space syntax based agent simulation. Springer-Verlag, 2002.
- [16] Alasdair Turner and Alan Penn. Encoding natural movement as an agent-based system: an investigation into human pedestrian behaviour in the built environment. *Environment and Planning B: Planning and Design*, Vol. 29, No. 4, pp. 473–490, 2002.
- [17] Gianluca Antonini, Michel Bierlaire, and Mats Weber. Discrete choice models of pedestrian walking behavior. *Transportation Research Part B: Methodological*, Vol. 40, No. 8, pp. 667–687, 2006.
- [18] Miho Asano, Takamasa Iryo, and Masao Kuwahara. A pedestrian model considering anticipatory behaviour for capacity evaluation. In *Transportation and Traffic Theory 2009: Golden Jubilee*, pp. 559–581. Springer, 2009.
- [19] Th. Robin, G. Antonini, M. Bierlaire, and J. Cruz. Specification, estimation and validation of a pedestrian walking behavior model. *Transportation Research Part B: Methodological*, Vol. 43, No. 1, pp. 36–56, 2009.
- [20] W.L. Wang, S.M. Lo, S.B. Liu, and H. Kuang. Microscopic modeling of pedestrian movement behavior: Interacting with visual attractors in the environment. *Transportation Research Part C: Emerging Technologies*, Vol. 44, pp. 21–33, 2014.
- [21] Takashi Akamatsu. Cyclic flows, markov process and stochastic traffic assignment. *Transportation Research Part B: Methodological*, Vol. 30, No. 5, pp. 369–386, 1996.
- [22] Michael G.H. Bell. Alternatives to dial’s logit assignment algorithm. *Transportation Research Part B: Methodological*, Vol. 29, No. 4, pp. 287–295, 1995.
- [23] Robert B Dial. A probabilistic multipath traffic assignment model which obviates path enumeration. *Transportation Research*, Vol. 5, No. 2, pp. 83–111, 1971.
- [24] Mogens Fosgerau, Emma Frejinger, and Anders Karlstrom. A link based network route choice model with unrestricted choice set. *Transportation Research Part B: Methodological*, Vol. 56, pp. 70–80, 2013.
- [25] Tien Mai, Mogens Fosgerau, and Emma Frejinger. A nested recursive logit model for route choice analysis. *Transportation Research Part B: Methodological*, Vol. 75, pp. 100–112, 2015.
- [26] Tien Mai. A method of integrating correlation structures for a generalized recursive route choice model. *Transportation Research Part B: Methodological*, Vol. 93, pp. 146–161, 2016.
- [27] Yuki Oyama and Eiji Hato. A discounted recursive logit model for dynamic gridlock network analysis. *Transportation Research Part C: Emerging Technologies*, Vol. 85, pp. 509–527, 2017.

- [28] Brian D Ziebart, Andrew L Maas, J Andrew Bagnell, and Anind K Dey. Maximum entropy inverse reinforcement learning. In *AAAI*, Vol. 8, pp. 1433–1438. Chicago, IL, USA, 2008.
- [29] Maëlle Zimmermann and Emma Frejinger. A tutorial on recursive models for analyzing and predicting path choice behavior. *EURO Journal on Transportation and Logistics*, Vol. 9, No. 2, p. 100004, 2020.
- [30] Oskar Blom Västberg, Anders Karlström, Daniel Jonsson, and Marcus Sundberg. A dynamic discrete choice activity-based travel demand model. *Transportation Science*, Vol. 54, No. 1, pp. 21–41, 2020.
- [31] Maëlle Zimmermann, Oskar Blom Västberg, Emma Frejinger, and Anders Karlström. Capturing correlation with a mixed recursive logit model for activity-travel scheduling. *Transportation Research Part C: Emerging Technologies*, Vol. 93, pp. 273–291, 2018.
- [32] Maëlle Zimmermann, Tien Mai, and Emma Frejinger. Bike route choice modeling using gps data without choice sets of paths. *Transportation Research Part C: Emerging Technologies*, Vol. 75, pp. 183–196, 2017.
- [33] Kris M. Kitani, Brian D. Ziebart, James Andrew Bagnell, and Martial Hebert. Activity forecasting. In Andrew Fitzgibbon, Svetlana Lazebnik, Pietro Perona, Yoichi Sato, and Cordelia Schmid, editors, *Computer Vision – ECCV 2012*, pp. 201–214, Berlin, Heidelberg, 2012. Springer Berlin Heidelberg.
- [34] B. D. Ziebart, N. Ratliff, G. Gallagher, C. Mertz, K. Peterson, J. A. Bagnell, M. Hebert, A. K. Dey, and S. Srinivasa. Planning-based prediction for pedestrians. In *2009 IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp. 3931–3936, 2009.
- [35] E. Frejinger, M. Bierlaire, and M. Ben-Akiva. Sampling of alternatives for route choice modeling. *Transportation Research Part B: Methodological*, Vol. 43, No. 10, pp. 984–994, 2009.
- [36] Xuan Liu, John M. Usher, and Lesley Strawderman. An analysis of activity scheduling behavior of airport travelers. *Computers & Industrial Engineering*, Vol. 74, pp. 208–218, 2014.
- [37] Antonin Danalet, Loïc Tinguely, Matthieu de Lapparent, and Michel Bierlaire. Location choice with longitudinal wifi data. *Journal of Choice Modelling*, Vol. 18, pp. 1–17, 2016.
- [38] Alexandra Beaulieu and Bilal Farooq. A dynamic mixed logit model with agent effect for pedestrian next location choice using ubiquitous wi-fi network data. *International Journal of Transportation Science and Technology*, Vol. 8, No. 3, pp. 280–289, 2019.
- [39] Junyi Zhang. A model of time use and expenditure of pedestrians in city centers. In *Pedestrian Behavior*. Emerald Group Publishing Limited, 2009.
- [40] Sachiyo Fukuyama and Eiji Hato. Pedestrian velocity and direction choice problem based on probabilistic activity domain (in Japanese). *Journal of the City Planning Institute of Japan*, Vol. 51, No. 3, pp. 688–694, 2016.

- [41] Yuki Oyama and Eiji Hato. Link-based measurement model to estimate route choice parameters in urban pedestrian networks. *Transportation Research Part C: Emerging Technologies*, Vol. 93, pp. 62–78, 2018.
- [42] Piyawan Kasemsuppakorn and Hassan A. Karimi. A pedestrian network construction algorithm based on multiple gps traces. *Transportation Research Part C: Emerging Technologies*, Vol. 26, pp. 285–300, 2013.
- [43] Miho Asano, Takamasa Iryo, and Masao Kuwahara. Microscopic pedestrian simulation model combined with a tactical model for route choice behaviour. *Transportation Research Part C: Emerging Technologies*, Vol. 18, No. 6, pp. 842–855, 2010. Special issue on Transportation Simulation Advances in Air Transportation Research.
- [44] Weilin Xu, Liu Liu, Sisi Zlatanova, Wouter Penard, and Qing Xiong. A pedestrian tracking algorithm using grid-based indoor model. *Automation in Construction*, Vol. 92, pp. 173–187, 2018.
- [45] Satu Sarjala. Built environment determinants of pedestrians’ and bicyclists’ route choices on commute trips: Applying a new grid-based method for measuring the built environment along the route. *Journal of Transport Geography*, Vol. 78, pp. 56–69, 2019.
- [46] 藤井聡, 大塚祐一郎, 北村隆一, 門間俊幸. 時間的空間的制約を考慮した生活行動軌跡を再現するための行動シミュレーションの構築. *土木計画学研究・論文集*, Vol. 14, pp. 643–652, 1997.
- [47] J.L Bowman and M.E Ben-Akiva. Activity-based disaggregate travel demand model system with activity schedules. *Transportation Research Part A: Policy and Practice*, Vol. 35, No. 1, pp. 1–28, 2001.
- [48] Chandra R Bhat, Konstadinos G Goulias, Ram M Pendyala, Rajesh Paleti, Raghuprasad Sidharthan, Laura Schmitt, and Hsi-Hwa Hu. A household-level activity pattern generation model with an application for southern california. *Transportation*, Vol. 40, No. 5, pp. 1063–1086, 2013.
- [49] Eric J. Miller and Matthew J. Roorda. Prototype model of household activity-travel scheduling. *Transportation Research Record*, Vol. 1831, No. 1, pp. 114–121, 2003.
- [50] Theo A Arentze and Harry J.P Timmermans. A learning-based transportation oriented simulation system. *Transportation Research Part B: Methodological*, Vol. 38, No. 7, pp. 613–633, 2004.
- [51] W.W Recker. The household activity pattern problem: General formulation and solution. *Transportation Research Part B: Methodological*, Vol. 29, No. 1, pp. 61–77, 1995.
- [52] Zipei Fan, Xuan Song, and Ryosuke Shibasaki. Cityspectrum: A non-negative tensor factorization approach. In *Proceedings of the 2014 ACM International Joint Conference on Pervasive and Ubiquitous Computing, UbiComp ’14*, p. 213–223, New York, NY, USA, 2014. Association for Computing Machinery.
- [53] Barbara Furlotti, Paolo Cintia, Chiara Renso, and Laura Spinsanti. Inferring human activities from gps tracks. In *Proceedings of the 2nd ACM*

SIGKDD International Workshop on Urban Computing, UrbComp '13, New York, NY, USA, 2013. Association for Computing Machinery.

- [54] Ryugo S. HAYANO and Ryutaro ADACHI. Estimation of the total population moving into and out of the 20 km evacuation zone during the fukushima NPP accident as calculated using “Auto-GPS” mobile phone data. *Proceedings of the Japan Academy, Series B*, Vol. 89, No. 5, pp. 196–199, 2013.
- [55] Samiul Hasan, Xianyuan Zhan, and Satish V. Ukkusuri. Understanding urban human activity and mobility patterns using large-scale location-based data from online social media. In *Proceedings of the 2nd ACM SIGKDD International Workshop on Urban Computing*, UrbComp '13, New York, NY, USA, 2013. Association for Computing Machinery.
- [56] Lun Wu, Ye Zhi, Zhengwei Sui, and Yu Liu. Intra-urban human mobility and activity transition: Evidence from social media check-in data. *PLOS ONE*, Vol. 9, No. 5, pp. 1–13, 05 2014.
- [57] Marta C Gonzalez, Cesar A Hidalgo, and Albert-Laszlo Barabasi. Understanding individual human mobility patterns. *Nature*, Vol. 453, No. 7196, pp. 779–782, 2008.
- [58] Santi Phithakkitnukoon, Teerayut Horanont, Giusy Di Lorenzo, Ryosuke Shibasaki, and Carlo Ratti. Activity-aware map: Identifying human daily activity pattern using mobile phone data. In Albert Ali Salah, Theo Gevers, Nicu Sebe, and Alessandro Vinciarelli, editors, *Human Behavior Understanding*, pp. 14–25, Berlin, Heidelberg, 2010. Springer Berlin Heidelberg.
- [59] C. Kang, S. Gao, X. Lin, Y. Xiao, Y. Yuan, Y. Liu, and X. Ma. Analyzing and geo-visualizing individual human mobility patterns using mobile call records. In *2010 18th International Conference on Geoinformatics*, pp. 1–7, 2010.
- [60] Qian Ge and Daisuke Fukuda. Updating origin–destination matrices with aggregated data of gps traces. *Transportation Research Part C: Emerging Technologies*, Vol. 69, pp. 291–312, 2016.
- [61] 清家剛, 三牧浩也, 原裕介, 森田祥子. 基礎自治体におけるモバイル空間統計の活用可能性に関する研究. *日本建築学会技術報告集*, Vol. 19, No. 42, pp. 737–742, 2013.
- [62] Yuzo Iida, Michiyoshi Iwabe, Akira Kikuchi, Ryuichi Kitamura, Kuniaki Sasaki, Yasuo Shiromizu, Dai Nakagawa, Masatoshi Hatoko, Satoshi Fujii, Takayuki Morikawa, and Toshiyuki Yamamoto. Micm-simulation based travel demand forecasting system for urban transportation planning. *INFRASTRUCTURE PLANNING REVIEW*, Vol. 17, pp. 841–847, 2000.
- [63] Matthew J. Roorda, Eric J. Miller, and Khandker M.N. Habib. Validation of tasha: A 24-h activity scheduling microsimulation model. *Transportation Research Part A: Policy and Practice*, Vol. 42, No. 2, pp. 360–375, 2008.
- [64] Dirk Helbing, Illés Farkas, and Tamas Vicsek. Simulating dynamical features of escape panic. *Nature*, Vol. 407, No. 6803, pp. 487–490, 2000.
- [65] Dorine C. Duives and Hani S. Mahmassani. Exit choice decisions during pedestrian evacuations of buildings. *Transportation Research Record*, Vol. 2316, No. 1, pp. 84–94, 2012.

- [66] Milad Haghani and Majid Sarvi. Pedestrian crowd tactical-level decision making during emergency evacuations. *Journal of Advanced Transportation*, Vol. 50, No. 8, pp. 1870–1895, 2016.
- [67] S.M. Lo, H.C. Huang, P. Wang, and K.K. Yuen. A game theory based exit selection model for evacuation. *Fire Safety Journal*, Vol. 41, No. 5, pp. 364–369, 2006.
- [68] Mojdeh Nasir, Chee Peng Lim, Saeid Nahavandi, and Douglas Creighton. Prediction of pedestrians routes within a built environment in normal conditions. *Expert Systems with Applications*, Vol. 41, No. 10, pp. 4975–4988, 2014.
- [69] Mehdi Moussaïd, Niriasca Perozo, Simon Garnier, Dirk Helbing, and Guy Theraulaz. The walking behaviour of pedestrian social groups and its impact on crowd dynamics. *PLOS ONE*, Vol. 5, No. 4, pp. 1–7, 04 2010.
- [70] Adrien Treuille, Seth Cooper, and Zoran Popović. Continuum crowds. *ACM Trans. Graph.*, Vol. 25, No. 3, p. 1160–1168, July 2006.
- [71] Zhengchao Wang, Yuki Oyama, Riccardo Scarinci, Michel Bierlaire, and Nikolaos Geroliminis. Pedestrian activity schedule models: review and promises. In *18th Swiss Transport Research Conference (STRC)*. Monte Verita/Ascona, 2018.
- [72] Antonin Danalet, Bilal Farooq, and Michel Bierlaire. A bayesian approach to detect pedestrian destination-sequences from wifi signatures. *Transportation Research Part C: Emerging Technologies*, Vol. 44, pp. 146–170, 2014.
- [73] Toshiyuki Yamamoto, Tomoki Usui, Norimasa Nakamura, and Takayuki Morikawa. Activity-travel behavior survey at tourist attraction by BLE in comparison with GPS. In *Launch Workshop of NECTOR Cluster 5, Tourism and Transport:exploration of interdependecies*, 2016.
- [74] R. Krajewski, J. Bock, L. Kloeker, and L. Eckstein. The highd dataset: A drone dataset of naturalistic vehicle trajectories on german highways for validation of highly automated driving systems. In *2018 21st International Conference on Intelligent Transportation Systems (ITSC)*, pp. 2118–2125, 2018.
- [75] Alan M Wilson, Tatjana Y Hubel, Simon D Wilshin, John C Lowe, Maja Lorenc, Oliver P Dewhurst, Hattie LA Bartlam-Brooks, Rebecca Diack, Emily Bennitt, Krystyna A Golabek, et al. Biomechanics of predator–prey arms race in lion, zebra, cheetah and impala. *Nature*, Vol. 554, No. 7691, pp. 183–188, 2018.
- [76] H. E. RAUCH, F. TUNG, and C. T. STRIEBEL. Maximum likelihood estimates of linear dynamic systems. *AIAA Journal*, Vol. 3, No. 8, pp. 1445–1450, 1965.
- [77] Mohammed S Tarawneh. Evaluation of pedestrian speed in Jordan with investigation of some contributing factors. *Journal of Safety Research*, Vol. 32, No. 2, pp. 229–236, 2001.
- [78] Rajat Rastogi, Ilango Thaniarasu, and Satish Chandra. Design implications of walking speed for pedestrian facilities. *Journal of Transportation Engineering*, Vol. 137, No. 10, pp. 687–696, 2011.

- [79] Winnie Daamen and Serge P Hoogendoorn. Free speed distributions—based on empirical data in different traffic conditions. In *Pedestrian and Evacuation Dynamics 2005*, pp. 13–25. Springer, 2007.
- [80] Caleb Van Nostrand, Vijayaraghavan Sivaraman, and Abdul Rawoof Pinjari. Analysis of long-distance vacation travel demand in the united states: A multiple discrete–continuous choice framework. *Transportation*, Vol. 40, No. 1, pp. 151–171, 2013.
- [81] Jacopo Torriti. A review of time use models of residential electricity demand. *Renewable and Sustainable Energy Reviews*, Vol. 37, pp. 265–272, 2014.
- [82] Joakim Widén and Ewa Wäckelgård. A high-resolution stochastic model of domestic activity patterns and electricity demand. *Applied Energy*, Vol. 87, No. 6, pp. 1880–1892, 2010.
- [83] NHK. 国民生活時間調査. <https://www.nhk.or.jp/bunken/yoron-jikan/> (参照 2021-04-13).
- [84] 総務省統計局. 平成 28 年社会生活基本調査. <https://www.stat.go.jp/data/shakai/2016/> (参照 2021-04-13).
- [85] Constantino Tsallis. Possible generalization of boltzmann-gibbs statistics. *Journal of Statistical Physics*, Vol. 52, No. 1, pp. 479–487, 1988.
- [86] Albert O Hirschman. *National power and the structure of foreign trade*, Vol. 105. Univ of California Press, 1980.
- [87] Edward H Simpson. Measurement of diversity. *Nature*, Vol. 163, No. 4148, pp. 688–688, 1949.
- [88] A. G. Wilson. A statistical theory of spatial distribution models. *Transportation Research*, Vol. 1, No. 3, pp. 253–269, 1967.
- [89] 栗田治. 都市と地域の数理モデル: 都市解析における数学的方法. 共立出版, 2013.
- [90] NTTdocomo. モバイル空間統計. <https://mobaku.jp/> (参照 2021-04-15).
- [91] AEON. Aeon news release. <https://www.aeonmall.com/upload/1408682956.pdf>(参照 2021-04-15).
- [92] 東京大学空間情報科学センター. Urban Employment Area. <http://www.csis.u-tokyo.ac.jp/UEA/index.htm>(参照 2021-04-15).
- [93] 総務省統計局. 平成 26 年経済センサス -基礎調査. <https://www.stat.go.jp/data/e-census/2014/>(参照 2021-04-15).
- [94] ゼンリンマーケティングソリューションズ. 学校ポイントデータ, note = https://www.zenrin-ms.co.jp/gis_marketing/database/point/school_points/(参照 2021-04-15),.
- [95] 岡山県産業労働部経営支援課. 大規模小売店舗立地法届出状況. <https://www.pref.okayama.jp/page/607609.html>(参照 2021-04-16).
- [96] 岡山市産業観光局商工部産業振興・雇用推進課商業振興係. 大規模小売店舗立地法について. <https://www.city.okayama.jp/jigyosha/0000009653.html>(参照 2021-04-16).

- [97] 倉敷市商工課. 大規模小売店舗立地法届出に関する情報. <https://www.city.kurashiki.okayama.jp/4118.htm>(参照 2021-04-16).
- [98] 国土交通省国土政策局. 国土数値情報ダウンロード医療機関データ. https://nlftp.mlit.go.jp/ksj/gml/datalist/KsjTmplt-P04-v2_1.html(参照 2021-04-16).
- [99] 中国四国厚生局. 中国四国厚生局管内の保険医療機関・保険薬局のコード内容別医療機関一覧. <https://kouseikyoku.mhlw.go.jp/chugokushikoku/chousaka/iryoukikanshitei.html>(参照 2021-04-16).
- [100] 厚生労働省. 病院報告. <https://www.mhlw.go.jp/toukei/list/80-1.html>(参照 2021-04-16).