

博士論文

メッシュ人口データを用いた人口動態の  
変化検出に向けた潜在状態推定

(Latent State Estimation for  
Change Detection in Human Dynamics  
Using Mesh Population Data)

神谷 啓太

## 論文要旨

都市における人々の移動や人口分布の時系列的な振る舞いの把握、すなわち人口動態の把握は多岐にわたる分野において重要である。従前より、人口動態を把握するためには、アンケート調査型の国勢調査やパーソントリップ調査、ならびに定点観測型の交通量調査やトラフィックカウンターによって人口動態を推計するという方法が取られてきた。近年ではさらに GPS 軌跡データや交通系 IC カードデータ、携帯電話通信情報など多様なデータが取得されるようになってきた。このデータ取得の広がりを受け、人口動態の把握に関する研究が盛んに行われている。ここでいう人口動態を把握することとは、都市内における OD フローや人口分布の代表的なパターンなど、対象空間における人の流れや滞在に関して理解することである。そのため、大量に存在するデータをいかに解釈可能な形に縮約するか、すなわちデータの要約や可視化に研究の主軸が置かれてきた。人口動態の把握を通じた分析結果は、都市計画への活用や災害シミュレーションのシナリオ策定に用いられているほか、エリアマーケティングへの利用やインフルエンザや感染症の流行予測などへの応用もされている。

ただし人口動態は日々変動するものであり、しかもそのダイナミクスは定常的であるとは限らない。人の移動が有する不確実性だけでなく、災害やイベントの発生など非日常時における局所的な変化や、都市構造や人口構造の変化に基づく人口動態のトレンド変遷など、人口動態自体のダイナミクスの変化というものも存在する。そのため前述した対象空間全体の人口動態のデータ要約だけでなく、人口動態のダイナミクスの変化をより詳細な空間で把握することが、より高度な交通サービスに資すると考えられる。ただし、上述した複雑なダイナミクスの複雑性により、見かけ上は人口動態に変化が存在しても、それは日常的な変動である場合や、逆に、見かけ上では変化が無くとも、その背後では変化や異常が生じている場合もあると考えられる。そのため、これらの変化は単にデータの大小や増減によって把握できるものではない。したがって、より詳細な空間に着目した上で、該当する空間周辺の人口動態や時系列の振る舞いを考慮し、人口動態の観測データから直接測ることのできないデータの構造やデータ生成に影響を及ぼす状態を推定することとなる。すなわち、潜在状態の推定問題として手法を構築する必要があり、既往研究はいまだ限定的である。

また、これまでの人口動態の状態把握の取り組みでは、主に非集計データを用いた分析が行われてきた。そのため、個々人のトリップや移動情報を保持したまま分析が行える一方で、プライバシー保護の観点からデータ取得や公開に制限がかかりやすい問題がある。従って、単位空間で集計化された入手可能性の高いデータで前述の人口動態の状態推定を行えることが望ましい。

以上の背景の下、本論文はメッシュ人口データを用いて、人口動態の変化検出に向けた潜在的な状態推定を行うことを目的とする。まず、状態推定手法の整理および基本モデルの検証を行い、モデルの拡張方針についてまとめる。この拡張方針に基づいて潜在状態の推定を通じた変化検出手法を構築し、その有効性を検証する。そして人口動態の変化検出手法の発展性に関する議論を行う。

ここで、人口動態の潜在的な状態推定とそれに基づく変化検出がもたらす可能性について、交通サービスに関して説明する。本研究は、人口動態の観測データの背後には潜在的なデータ構造や状態が存在するという立場に立っており、状態推定手法を通じてその分析を目指す。この潜在状態に着目した変化検出結果を新たな指標の一つとして交通サービスに組み込むことにより、より良いサービス設計に有用であると考え。例えば、ある日の人口動態に対して検知された異常状態が時間と共に拡散・遷移する様子を分析することができれば、その異常発生の原因究明やサービス改善のための評価が可能となる。短期的な視点では、開催されたイベントがもたらした人口動態や人の動きへのインパクトの評価、そして長期的な視点では、交通インフラの新設が人口動態に及ぼした影響の把握などである。そして、潜在状態の解釈を加えることで、そのインパクトとは何だったのか、どのような潜在的ニーズの変化に対して交通サービスを改善する必要があるのかなど、評価や意思決定に対してより有用な指標になると考える。このように人口動態の潜在的な状態推定はより高度な交通サービスに資するものであると考える。

本論文は全6章で構成される。各章の内容の要約を以下に記す。

第1章（序論）では、本研究の背景と目的を述べる。まず、近年盛んに行われている人口動態把握に関する既往研究を概観し、人口動態の変化検出のためには潜在的な状態に着目することが重要であることを述べる。また、人口動態把握に用いられるデータの多様性についても触れ、入手可能性の高いデータを用いた分析の有用性を述べる。以上を踏まえ、本研究ではメッシュ人口分布データを用いて、詳細な空間に着目した人口動態変化検出に向けた、潜在的な状態推定を行うことを目的とする。

第2章（既往研究の整理）では、状態推定問題を対象とする既往研究を整理する。まず、分野横断的に状態推定手法のレビューを実施し、各手法の持つ特性について述べる。次に、人口動態を対象とした既往研究を整理する。それぞれの取り組みの中で人口動態の状態がどのように定義・分析されているかを説明する。また、前章で行ったデータの整理結果を踏まえ、各既往研究内で使用されているデータと分析内容との関係を整理する。

第3章（潜在状態推定手法の基本フレームワーク）では、潜在状態推定の基本フレームワークとなる状態空間モデルについて述べる。状態空間モデルはデータ同化の文脈で頻繁に使われているモデルであり、観測データとシミュレーションを統合することが可能である。しかし、人口動態分析における潜在状態の時系列遷移を記述するシステムモデルに制約があることなど、本論文で扱う問題にデータ同化を適用することには課題がある。これを、データ同化手法の適用を通じて示す。そこで、既存シミュレーションモデルによらないデータ指向な方法として、状態変数に離散値をとる隠れマルコフモデルの適用を考える。東京23区のメッシュ人口の潜在状態の推定と視覚化の検証を通じ、状態数を事前に設定する必要があること、および推定される潜在状態の解釈が困難であることが変化検出に向けた課題であることを示す。これらの議論を踏まえた上で、人口動態の状態推定に向けたモデル拡張方針について述べる。

第4章（隠れマルコフモデルによる変化検出）では、第3章で議論したモデル拡張方針に従い、階層ベイズ法の導入および事前分布の共有化によるモデルを構築する。また、そのモデルをメッシュ人口に対する変化検出問題へと適用する。変化検出においては、学習用メッシュ人

口時系列から潜在状態およびモデルパラメータを学習し、そのモデルを用いて検証用メッシュ人口時系列の潜在状態を推定した上で変化スコアを算出する手法を開発している。そしてシミュレーションデータへの適用を通じ、提案手法の精度検証を実施する。また、実データに対する適用では、列車運休がもたらした短期的な人口動態の異常な振る舞いと、中長期的な人口動態の変化の検出を実施する。適用結果の考察を通じて、提案手法の有効性を実証するとともに、その課題について議論する。

第5章（トピックモデルによる変化検出）では、メッシュ人口データに含まれる居住地などの属性データを利用し、推定される潜在状態および検出される変化内容の意味解釈を試みる。そこで自然言語の分野でよく用いられるトピックモデルによるアプローチを導入する。潜在状態数の事前設定の問題を解消するため、階層ベイズ法を導入したトピックモデルとしてモデルの構築を行い、人口動態の潜在状態推定を行う。人口動態をトピックモデルとして捉えるため、各時刻における各メッシュを一つの文書、そのメッシュ内に存在する滞在者の居住地を一つの単語、「ある地域からの来訪者が潜在的に多い」などといった潜在的な構造としての人口特性をトピックして扱う。実データに対する適用を通じ、推定された潜在状態の意味解釈の有効性、およびメッシュ毎の潜在状態の把握の有効性について分析・考察する。さらに、メッシュ毎に推定されたトピック分布の経年変化に基づく変化検出手法を構築する。提案手法を実データへ適用し、人口動態の構成に変化が起きたと考えられる地域の検出と、その変化内容の分析を行う。そして上述した隠れマルコフモデルに基づく手法とトピックモデルに基づく手法の特徴について比較し、人口動態の変化検出手法の更なる発展性について議論・整理する。

最後に、第6章（結論）で本論文の成果をとりまとめ、今後の課題および展望について示す。

本論文では、メッシュ人口データを用いて、人口動態の変化検出に向けた潜在状態の推定を実施した。隠れマルコフモデルに階層ベイズ法を導入し、事前分布の共有化を施したモデルに基づく変化検出手法を開発した。提案手法の適用を通して、電車運行停止に起因したメッシュ人口値の異常状態の検知や、人口動態の経年変化の検出などに対して、提案手法が有効であることを確認した。また、推定した潜在状態および検出した変化に対して、トピックモデルに基づく潜在的意味解釈を行い、提案手法が詳細な移動情報を基にした人口動態の構造把握に資することを確認した。

なお、提案手法における人口動態の状態推定手法は、メッシュ人口データ以外のデータに対しても適用することのできる汎用的なものである。また、単位空間にメッシュ以外を設定することも容易である。そのため、提案手法を用いることで任意のデータセットに対して任意の単位空間を設定した分析を行うことが可能となる。さらに、状態空間モデルを利用する提案手法を基盤に、複数の観測データを統合するモデルへと拡張することが可能である。本研究で行った変化検出や潜在的意味解釈のアプローチを実施することで、移動に関する社会メカニズムの解明に貢献することが期待される。

# 目次

<b>第 1 章</b>	<b>序論</b>	<b>1</b>
1.1	研究の背景	1
1.1.1	人口動態の変化検出の重要性	1
1.1.2	人口動態の潜在的な状態推定がもたらす可能性	2
1.2	人口動態を表すデータの整理	3
1.3	研究の目的	7
1.4	本論文の構成	8
<b>第 2 章</b>	<b>既往研究の整理</b>	<b>10</b>
2.1	潜在状態推定手法の整理	10
2.1.1	潜在状態推定問題の概要	10
2.1.2	モデルの導入に基づく状態推定手法	10
2.1.3	データの変換に基づく状態推定手法	13
2.2	潜在状態推定に関する研究事例の整理	14
2.2.1	潜在状態推定の適用分野の整理	14
2.2.2	人口動態分析における潜在状態推定のレビュー	17
2.2.3	本研究の位置付け	20
<b>第 3 章</b>	<b>潜在状態推定手法の基本フレームワーク</b>	<b>21</b>
3.1	基本となる状態空間モデル	21
3.1.1	状態空間モデルの定式化	21
3.1.2	ベイズ推定による潜在状態の推定	23
3.1.3	状態空間モデルの適用方針	24
3.2	データ同化による人口動態の状態推定	24
3.2.1	データ同化の全体像	25
3.2.2	データ同化の適用結果	27
3.3	隠れマルコフモデルによる人口動態の状態推定	29
3.3.1	隠れマルコフモデルの定式化	29
3.3.2	隠れマルコフモデルの適用結果	32
3.4	変化検出に向けた課題の抽出とモデル拡張方針	35

<b>第 4 章</b>	<b>隠れマルコフモデルによる人口動態の変化検出</b>	<b>38</b>
4.1	メッシュ人口データに対する変化検出問題の設定	38
4.1.1	変化検出問題の整理	38
4.1.2	状態空間モデルによる変化検出	41
4.2	ノンパラメトリックベイズモデル	41
4.2.1	ディリクレ過程	42
4.2.2	階層ディリクレ過程	43
4.2.3	階層ディリクレ過程隠れマルコフモデル	43
4.2.4	ブロック化ギブスサンプリングによるパラメータ推定	44
4.3	sHDP-HMM を援用した変化検出手法の提案	46
4.3.1	提案手法の概要	46
4.3.2	メッシュ人口データへの適用方法	48
4.4	提案手法の適用と結果の考察	49
4.4.1	シミュレーション実験による性能評価	50
4.4.2	実データへの適用	54
<b>第 5 章</b>	<b>トピックモデルによる人口動態の変化検出</b>	<b>63</b>
5.1	トピックモデル	63
5.1.1	Latent Dirichlet Allocation	63
5.1.2	階層ディリクレ過程 LDA	64
5.2	メッシュ人口データへのトピックモデルの適用方針	67
5.2.1	多分野におけるトピックモデルの変数設定の整理	67
5.2.2	メッシュ人口データにおける変数設定方法の検討	68
5.3	HDP-LDA による人口動態の潜在的意味解釈	71
5.3.1	適用データと実験条件	71
5.3.2	手法の適用とその結果の分析	72
5.4	トピックモデルを用いた変化検出手法の提案	78
5.4.1	変化検出手法の提案と検証	78
5.4.2	人口動態の変化検出手法の更なる発展に向けた議論	81
<b>第 6 章</b>	<b>結論</b>	<b>85</b>
6.1	本研究の成果	85
6.1.1	人口動態の潜在状態を推定する枠組みの整理と基本モデルの検証	85
6.1.2	人口動態に対する変化検出手法の構築	86
6.1.3	人口動態の潜在的意味解釈	86
6.1.4	人口動態の変化検出手法の更なる発展に向けた検討	87
6.2	今後の課題と展望	87
6.2.1	状態推定手法のさらなる性能向上	87

6.2.2	潜在的意味解釈に基づく変化検出に向けた理論構築 . . . . .	89
6.2.3	今後の展望 . . . . .	90
<b>付録 A</b>	<b>空中写真からの車両認識</b>	<b>92</b>
A.1	はじめに . . . . .	92
A.2	使用する空中写真 . . . . .	92
A.2.1	市街地における航空写真および衛星画像 . . . . .	92
A.2.2	VEDAI データセット . . . . .	93
A.2.3	学習データセットの作成 . . . . .	93
A.3	車両認識手法の設計 . . . . .	94
A.3.1	BING による物体検知 . . . . .	94
A.3.2	CNN によるクラス分類 . . . . .	95
A.4	手法の適用と精度検証 . . . . .	96
A.4.1	BING 手法の学習および車両検知率の検証 . . . . .	96
A.4.2	CNN の学習および分類精度の検証 . . . . .	98
A.4.3	提案手法の適用結果と車両認識性能の比較 . . . . .	99
A.4.4	今後の課題 . . . . .	101
<b>付録 B</b>	<b>データ駆動型シミュレーションモデルの作成</b>	<b>102</b>
B.1	はじめに . . . . .	102
B.2	提案手法の構築 . . . . .	103
B.2.1	多層パーセプトロン . . . . .	103
B.2.2	制約ボルツマンマシン . . . . .	104
B.2.3	メッシュ単位のシミュレーションモデル作成手法 . . . . .	105
B.3	適用と検証 . . . . .	106
B.3.1	適用対象データ . . . . .	106
B.3.2	制約ボルツマンマシンの構造の検証 . . . . .	107
B.3.3	多層パーセプトロンの構造の検討 . . . . .	108
B.3.4	予測精度の検証 . . . . .	110
B.3.5	今後の課題 . . . . .	110
	<b>参考文献</b>	<b>112</b>

# 目次

1.1	カメラや距離センサからの観測例	4
1.2	GPS データ例	5
1.3	Uber Movement	6
1.4	モバイル空間統計	6
3.1	一般状態空間モデル	22
3.2	データ同化的アプローチの全体像	26
3.3	データ同化の適用対象ゾーン	27
3.4	隠れマルコフモデル	31
3.5	潜在状態の推定結果	33
3.6	潜在状態の解釈と各潜在状態に対応する色の定義	34
3.7	メッシュ別・時刻別の潜在状態の推定結果	35
3.8	推定された潜在状態の GIS 可視化結果	36
3.9	変化検出に向けたモデルの拡張方針	37
4.1	メッシュ人口データに含まれる変化・異常の例	40
4.2	階層ベイズモデルのグラフィカルモデル	43
4.3	sHDP-HMM による変化検出手法の概略	47
4.4	スティッキー階層ディリクレ過程隠れマルコフモデルの複数メッシュへの適用	49
4.5	作成したシミュレーションデータ	50
4.6	シミュレーションデータでの潜在状態の推定結果	51
4.7	状態推定結果の比較	52
4.8	シミュレーションデータでの変化検出結果	52
4.9	提案手法の精度検証結果	53
4.10	対象とする狭領域と変化スコアのメッシュ平均	56
4.11	変化スコアの時刻平均	57
4.12	特定メッシュにおける人口値と変化スコアの比較	57
4.13	伊勢崎線沿線のメッシュ別・時刻別の変化スコア算出結果	58
4.14	広領域対象エリアにおける時刻別平均変化スコア	59
4.15	広領域対象エリアにおけるメッシュ別平均変化スコア	60

4.16	広領域対象エリアにおける変化スコアの GIS 可視化結果 . . . . .	61
4.17	広領域対象エリアにおける変化スコアと人口値の差分の比較 . . . . .	62
5.1	LDA のグラフィカルモデル表現 . . . . .	65
5.2	HDP-LDA を用いたメッシュ人口データの表現方法 . . . . .	72
5.3	HDP-LDA によるトピック数の推定結果 . . . . .	73
5.4	推定された地域集合の可視化結果 . . . . .	74
5.5	各トピックにおける上位出単語 . . . . .	75
5.6	対象エリアにおける西側地域からの来訪者による影響度の可視化結果 . . . . .	77
5.7	対象エリアにおける南西地域からの来訪者による影響度の可視化結果 . . . . .	78
5.8	トピック分布の乖離度に着目した変化検出結果 . . . . .	80
5.9	トピック分布の変化内容の可視化結果 . . . . .	82
5.10	HMM 手法と LDA 手法のグラフィカルモデルの比較 . . . . .	83
A.1	データセットの例 . . . . .	94
A.2	構築した畳み込みニューラルネットワーク . . . . .	96
A.3	BING による車両検出率の比較 . . . . .	97
A.4	BING による車両検出率の比較 (補正済み) . . . . .	98
A.5	提案した車両認識手法の適用例 . . . . .	101
B.1	多層パーセプトロンと制約ボルツマンマシンのグラフィカルモデル . . . . .	103
B.2	メッシュ単位のシミュレーションモデル作成手法の概要 . . . . .	105
B.3	シミュレーションモデル作成の対象範囲 . . . . .	106
B.4	隠れ変数を可変とした場合の RBM による再構成誤差 . . . . .	107
B.5	隠れ変数が 60 の場合の RBM による時間帯別再構成誤差 . . . . .	108
B.6	対象範囲 A における RBM による時間帯別の再構成結果 . . . . .	109
B.7	中間層のユニット数を可変とした場合の MLP による特徴量の予測誤差 . . . . .	109
B.8	作成したシミュレーションモデルの時間帯別の予測誤差 . . . . .	110
B.9	対象範囲 B における予測結果 . . . . .	111

# 表目次

3.1	データ同化の適用結果 . . . . .	28
4.1	従来手法と提案手法の比較検証結果 . . . . .	55
5.1	多分野におけるトピックモデルの変数設定方法の例 . . . . .	69
A.1	航空写真の仕様 . . . . .	93
A.2	衛星画像の仕様 . . . . .	93
A.3	データセット別の画像仕様 . . . . .	94
A.4	CNN のクラス分類性能の比較 . . . . .	98
A.5	提案手法の認識性能の比較 . . . . .	100

# 第 1 章

## 序論

### 1.1 研究の背景

#### 1.1.1 人口動態の変化検出の重要性

都市における人々の移動や人口分布の時系列的な振る舞いの把握，すなわち人口動態の把握は多岐にわたる分野において重要である。従前より，人口動態を把握するためには，アンケート調査型の国勢調査やパーソントリップ調査，ならびに定点観測型の交通量調査やトラフィックカウンターによって人口動態を推計するという方法が取られてきた。ただしこれらのデータ取得のためには高いコストがかかることや，取得されるデータのカバー率および空間分解能が低いこと，そしてデータ更新頻度が低いことなどが問題であった。しかし後述するように，近年ではさらに GPS 軌跡データや交通系 IC カードデータ，携帯電話通信情報など多様なデータが取得されるようになってきた。このデータ観測技術の発達により，より細かな時空間分解能にて比較的安価に大量の情報が活用できる環境が整備されてきている。

このデータ取得の広がりを受け，人口動態の把握に関する研究が盛んに行われている [1][2][3]。ここでいう人口動態を把握することとは，都市内における OD フローや人口分布の代表的なパターンなど，対象空間における人の流れや滞在に関して理解することである。そのため，大量に存在するデータをいかに解釈可能な形に縮約するか，すなわちデータの要約や可視化に研究の主軸が置かれてきた。人口動態の把握を通じた分析結果は，都市計画への活用や災害シミュレーションのシナリオ策定に用いられているほか，エリアマーケティングへの利用やインフルエンザや感染症の流行予測などへの応用もされている。

ただし人口動態は日々変動するものであり，しかもそのダイナミクスは定常的であるとは限らない。人の移動が有する不確実性だけでなく，災害やイベントの発生など非日常時における局所的な変化や，都市構造や人口構造の変化に基づく人口動態のトレンド変遷など，人口動態自体のダイナミクスの変化というものも存在する。そのため前述した対象空間全体の人口動態のデータ要約だけでなく，人口動態のダイナミクスの変化をより詳細な空間で把握することが，より高度な交通サービスに資すると考えられる。ただし，上述した複雑なダイナミクスの複雑性により，見かけ上は人口動態に変化が存在しても，それは日常的な変動である場合や，

逆に、見かけ上では変化が無くとも、その背後では変化や異常が生じている場合もあると考えられる。そのため、これらの変化は単にデータの大小や増減によって把握できるものではない。したがって、より詳細な空間に着目した上で、該当する空間周辺の人口動態や時系列の振る舞いを考慮し、人口動態の観測データから直接測ることのできないデータの構造やデータ生成に影響を及ぼす状態を推定することとなる。すなわち、潜在状態の推定問題として手法を構築する必要があり、既往研究はいまだ限定的である。

また、これまでの人口動態の状態把握の取り組みでは、主に非集計データを用いた分析が行われてきた。そのため、個々人のトリップや移動情報を保持したまま分析が行える一方で、プライバシー保護の観点からデータ取得や公開に制限がかかりやすい問題がある。従って、単位空間で集計化された入手可能性の高いデータで前述の人口動態の状態推定を行えることが望ましい。

### 1.1.2 人口動態の潜在的な状態推定がもたらす可能性

人口動態の潜在的な状態推定とそれに基づく変化検出がもたらす可能性について説明する。本研究は、人口動態の観測データの背後には潜在的なデータ構造や状態が存在するという立場に立っており、状態推定手法を通じてその分析を目指す。

現状、人口動態を把握するためには人口動態データの値や増減率などの簡易な分析結果そのものに着目するほかない。そのため、見かけ上は人口動態に変化は無くとも、その背後では異常や変化が生じている場合にはその検出は不可能である。人口動態という社会的なインパクトが大きな問題について考えるうえで、異常や変化が顕著的に認知される前に対策を講じることが求められる。また、この潜在的な状態推定に基づく変化検出結果を新たな指標の一つとして交通サービスに組み込むことが、より良いサービス設計に有用であると考えられる。短期的な視点では、開催されたイベントがもたらした人口動態へのインパクトの評価、そして長期的な視点では、交通インフラの新設が人口動態に及ぼした影響の把握などが考えられる。例えば、ある期間における人口動態に対して検出された異常状態が時間と共に拡散・遷移する様子を分析することができれば、その異常発生の原因究明やサービス改善のための評価へと繋がる。さらに、異常状態や変化は負の要因だけでなく、新しい交通ニーズや生活形態の変化によってももたらされうるものである。既存交通サービスの改善や新規事業の立ち上げを効率的・効果的に行うためには、その潜在的なニーズの変化を早い段階で検出する必要がある。

人口動態の潜在状態の状態推定がもたらす別の可能性は、潜在状態の意味解釈による人口動態の把握である。先に述べた通り人口動態を把握するためには人口値そのものやその代表的なパターンに着目することがほとんどである。このような複雑な振る舞いを持つデータに対して潜在状態の解釈を行うことができれば、検出された変化や異常状態についてもその原因説明や解釈が容易になる。イベントがもたらしたインパクトとは何だったのか、どのような潜在的ニーズの変化に対して交通サービスを改善する必要があるのかなど、評価や意思決定に対してより有用な指標になると考える。このように、人口動態の潜在的な状態推定がもたらす可能性

は、より高度な交通サービスに資するものであると考える。

## 1.2 人口動態を表すデータの整理

前述したとおり、測位技術および情報通信技術の発達により利用可能な位置データが増加している。そこでデータ観測方法を軸に具体的なデータの特徴について整理する。

### 従来型の統計調査

従前よりパーソントリップ調査 (PT 調査)、大都市交通センサスをはじめとした従来型統計調査によって人口動態・人の流れのデータ取得が行われてきた。PT 調査とは人の一日の行動を「目的を有する移動＝トリップ」ごとに分割し、数%のサンプルを抽出しアンケート方式で調査したものである。一人の人間がある目的を持って出発地から到着地までに要する移動について、アンケート用紙に記載し郵送回答してもらうことによって調査対象者の一日の行動移動の調査を行っている。大都市交通センサスは5年毎に首都圏・中京圏・近畿圏の三大都市圏において、鉄道・バス等の大量公共交通機関の利用実態を調査したものである。旅客流動量や利用状況、乗換え施設の実態を把握することが目的であり、各交通機関利用者を対象に調査票を配布・回収することでデータを取得している。

これらの行動調査による人口動態データは、アンケート型のデータであるため、性別・年齢などの個人属性のデータも取得できる。特にPT 調査では対象都市圏で数%のサンプルを抽出して行うため、年代性別嗜好などの偏りなく人の行動を調査できると言われている。そしてデータ公開・利用のための法的整備が十分になされている点も人口動態分析を行う研究・サービスへの高いメリットとなる。しかし調査頻度が数年10年に一度であることや、調査に高コストを要することなど、データ取得に対する課題は大きい。また、調査対象となる人の動きはある1日のものに限定されてしまうこと、アンケート回答に対する信ぴょう性が疑われることや、サンプリング調査のためデータ多様性が限定されてしまうことなど、データ自体の課題も近年では問題視されている。

### 定点観測による交通量調査

従来より行われてきた定点観測による交通量調査により得られたデータも、人口動態の一部を表現するデータである。例えば調査員による交通量計測および通行量調査、トラフィックカウンターによる常時交通量観測などが行われ、観測地点・単位時間での集計データとして取得される。前者であれば任意地点の交通量を把握できる点で有用であり、後者であれば24時間365日の常時観測ができるという特徴を持つ。一方で人的・機器設置に対するコストが大きい、観測できる箇所が交差点単位など限られるというデメリットがある。

### カメラや距離センサを用いた非集計観測

定点観測の別の方法として、設置したカメラや距離センサから人や車の動きを検知する観測方法がある(図1.1)。これまではカメラに映った状況を人間の目で判断していたが、近年の画

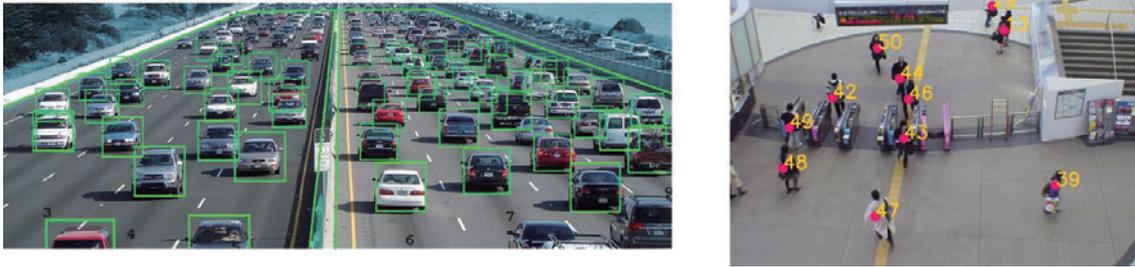


図 1.1. カメラや距離センサからの観測例  
 (左図) 動画像からの車両認識システムのイメージ [4], (右図) シミュレーションモデルとの統合による歩行者追跡 [5]

像認識技術の発展によりそれらが全自動で行われつつある。動画像から画像マッチングや深層学習技術によって人物や車両を特定する手法や、歩行者モデルなどのシミュレーションモデルとの統合を行うことで精度を高めている技術などが提案されている。

精度の問題を無視すれば、計測できるデータはカメラ内に収まる全ての人物・車両であり、非集計観測データとして利用することが可能である。さらに観測空間内の対象物体の細かな動きを認識することができるため、車線変更や歩行移動軌跡などの方法を取得できるという特徴を持つ。

しかし計測可能領域にはやはり限りがあり、広範囲に渡って計測するには多くの機器を設置して統合しなければならない。観測範囲が限定であるという問題に対し、衛星画像や航空写真からの車両位置の非集計観測を行うという方法 [6] も考えられる。撮影範囲が広い空中写真から車両認識を行うためには、物体検知手法と物体分類手法を組み合わせた手法を構築することとなる。しかし、詳しくは付録 A にて説明するが、高い検知率が期待できる一方で精度に関してははまだ課題が残されている。

### GPS による移動軌跡データ

GPS による位置情報の取得は今や測位技術のデファクトスタンダードとなりつつある。GPS 搭載した携帯電話や車両が移動した軌跡のログデータを利用することで、誤差数 m で数秒間隔の非集計データを入手することが可能となる。路線バスの GPS 軌跡を記録したバスプローブデータや、民間車両の民間プローブデータなどのデータが長く用いられている。

また、近年では ETC2.0 の普及率も伸びてきており、その活用が期待されている。ETC2.0 データには走行経路・走行速度等の走行歴情報と、急ブレーキ・急ハンドルなどの挙動履歴が逐次蓄積され、ITS スポット通過時に路車間通信によりデータを収集している。非集計データとして取得されるため、その情報量のリッチさも兼ねて交通状況の分析や安全対策への基礎データとして用いられる。

ただし GPS は高精度・常時観測が可能がゆえにユーザの行動が特定されてしまうため、個人情報保護を多分に考慮に入れる必要がある。データ利用のためにはユーザの許諾を取る必要があるほか、例えば ETC2.0 では個別車両が特定できないようにデータの ID を付与すると

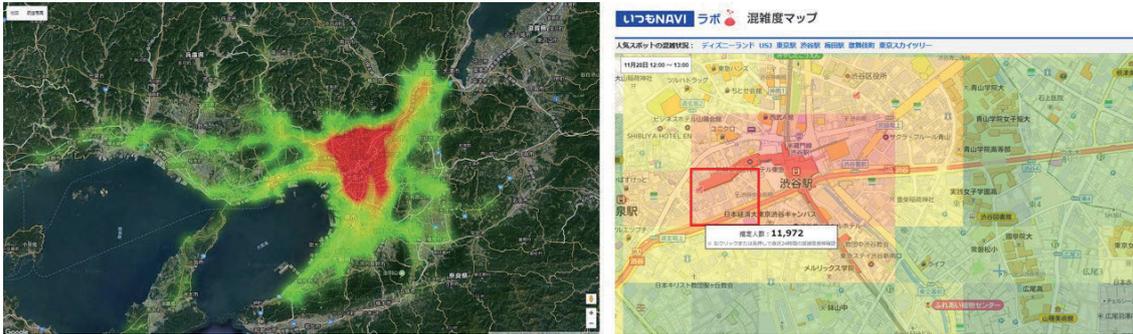


図 1.2. GPS データ例(左図) 流動人口データの活用事例 [7], (右図) 混雑度マップ [8]

共に、起終点付近のデータが秘匿される仕組みになっている。また、移動の様子は克明に記録することが可能だが、移動の目的や交通手段は明らかではない、移動と滞在の判断が難しいという欠点も存在する。

プライバシー保護の観点から生の移動軌跡データの公開・利用が制限される GPS データだが、メッシュ単位で時間別の人口分布データとしての集計データが公開・販売されているケースは多い(図 1.2)。例えば Agoop 社の販売する流動人口データは、自社のスマートフォンアプリの GPS ログをもとに人口推計を行ったものであり、メッシュに滞在した時間情報をもとに「滞在人口」と「通過人口」に分類が行われている。ゼンリンデータコムでは、ドコモ地図ナビのユーザから利用許諾を得た上で送信される位置情報を集計し、メッシュ人口値を推定した「混雑統計」データの提供や Web サービス「混雑度マップ」の公開が行われている。

その他、タクシーに搭載された GPS 情報を基に、新規サービスの設立やデータセットの公開も行われている。例えば Uber が保有する交通データを利用できるウェブサイト Uber Movement(図 1.3)[9] が公開されており、長期にわたって蓄積された移動情報を基に、ある地点からある地点まで移動するのにかかる所要時間をインタラクティブに検索できる。また、ニューヨークのタクシー乗降とその位置情報データがオープンデータとして公開されている[10]。

### 携帯電話基地局情報

携帯電話基地局情報 (Call Detail Records ; CDR) とは、携帯電話と基地局との間で行われた通信が記録されたものである。通信インフラの障害検出や通信料金算出のために収集したデータであるが、単位時間で集計しメッシュなど別の空間単位への分割し直すことで、人の位置情報に関する集計データとして活用されている。

多くの研究や交通サービスに利用されてきたデータとして、NTT ドコモが販売するモバイル空間統計(図 1.4)[11]がある。基地局エリアごとに自社の携帯電話台数を集計し、ドコモの携帯電話普及率を加味した上で1時間ごとのメッシュ人口を推計しているものである。ユーザの年齢階級、性別、居住地エリアも含めたデータであるため、性別年代別人口の時間変動や、ある地域にどこから来ている人が多いのか、ある地域からどこに行く人が多いのかなど、多様な情報を含む。

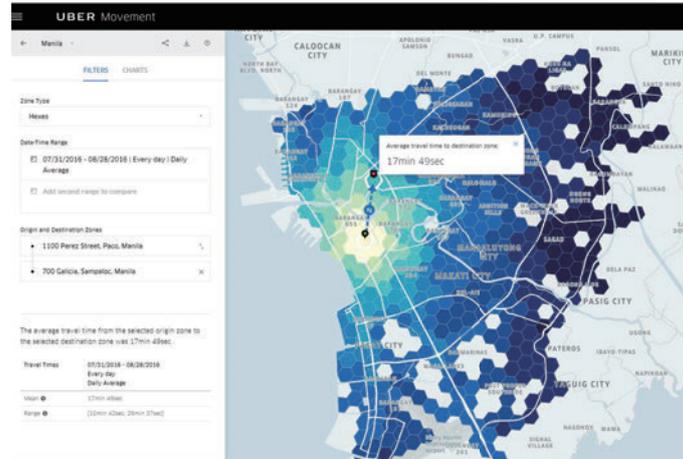


図 1.3. Uber Movement[9]

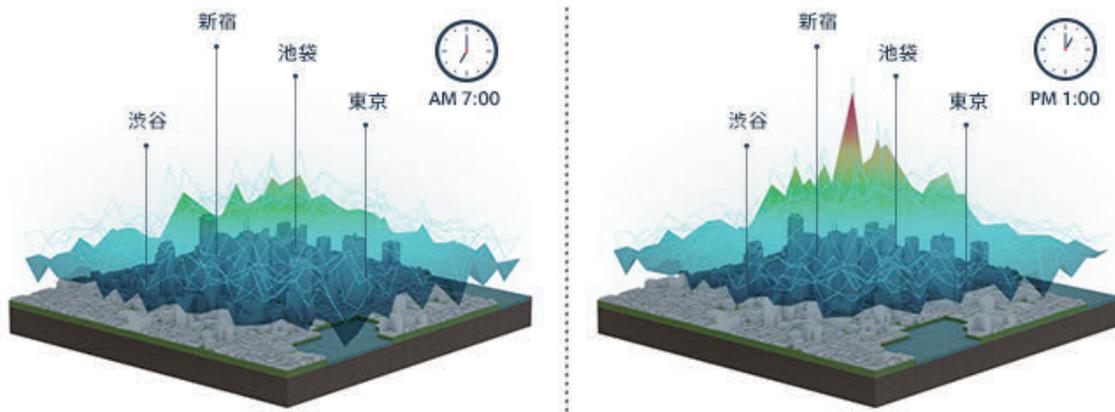


図 1.4. モバイル空間統計 [11]

また、2014年に携帯電話事業者 Telecom Italia によって開催された Big Data Challenge コンペティションで用いられたデータセットが、コンペ終了後に Open Big Data として dandelion 社の API を通じ公開・無償提供されている。このデータはイタリアのミラノおよびトレントを対象とし、2013年11月～12月の2ヶ月間におけるインターネット通信料やSMS、電話などのCDRに加え、天気や大気環境、社会的なイベントなどが整理されたものである。ミラノを対象とするCDRの場合、対象地域が一辺235mの10,000のメッシュに分割されており、データが10分間隔で集計され記録されている [12]。

#### ICカードなどによる公共交通機関利用者データ

日々の通勤・通学は人口動態を表す大きな要因の一つであり、鉄道やバスの公共交通機関の利用者数に関するデータの利用も考えられている。SUICAやPASMOなどの非接触型ICカード乗車券には乗車駅・降車駅が記録されているためOD分析との親和性も高く、全利用者の履歴がほとんど漏れなく鉄道事業者により保管されている。多くの乗客が利用するIC

カードデータは人口動態のより詳細な分析を行うための高いポテンシャルを持つデータと考えられる。しかし IC 乗車券の利用履歴の利用には個人情報に関する課題が多い。フランス・レンヌ地域の鉄道事業会社が保有するスマートカードデータを用いた分析が行われた例 [13] があるが、日本国内において同様の分析が行われるには法的整備など多くの課題が存在する。

また、近年ではシェアサイクルも新たな交通サービスとして捉えられており、取得される情報は人口全体のごく一部ではあるものの、人口動態を表すデータとして注目を集めている。ニューヨークのバイクシェアプログラムを提供する citi bike[14] や、ロンドン市内のシェアバイク Santander Cycles[15] では、利用開始・返却バイクステーションやその時刻などの利用履歴データが公開されている。

### 位置情報付き SNS データ

Twitter や Instagram などの SNS の投稿には位置情報付きの投稿が複数含まれている。投稿内容および投稿に付加された位置情報を人口動態の分析に用いることも考えられている。ただし、取得されるデータは SNS ユーザのさらにごく一部に限られるため、そのデータの利用先としてはホットスポットやイベントの検出などに限定される。

### 本論文で使用するデータ

以上整理したように、現在は人口動態を表す数多くのデータが取得され、利用されている。特に、GPS 移動軌跡データは個々人のトリップや移動情報を保持したまま分析が行えるためこれまでの人口動態の分析に数多く使用されてきた。しかし一方で、プライバシー保護の観点からデータ取得や公開に制限がかかりやすい問題がある。ゆえに、単位空間で集計化された入手可能性の高いデータで前述の人口動態の状態推定および変化検出を行えることが望ましい。

そこで本論文では、メッシュ人口データを利用した分析を行う。データカバー率が大きいデータとして日本国内における入手取得可能性も大きく、かつ細かな時空間分解能でのデータとして利用できるためである。具体的には、1 時間 500m メッシュ単位で人口値が記録された混雑統計とモバイル空間統計を用いる。

## 1.3 研究の目的

以上の背景の下、本論文はメッシュ人口データを用いて、人口動態の変化検出に向けた潜在的な状態推定を行うことを目的とする。まず、状態推定手法の整理および基本モデルの検証を行い、人口動態の状態推定手法のモデル拡張のための課題と方向性を議論する。次に、この拡張方針に基づき、潜在状態の推定を通じた変化検出手法を構築する。なお、人口動態の潜在状態の定義や状態数の定義が困難となることが予想されることから、データに応じてそれらを自動的に学習することができる機構を導入する。そして提案手法をメッシュ人口データへと適用し、その有効性や精度について検証する。また、推定された潜在状態や検出された変化の解釈を容易にすることを目指し、人口動態の状態推定を通じた潜在的意味解釈を行う。さらに潜在的意味解釈を利用した変化検出手法を構築し、提案手法の適用可能性を検証する。最後に、本

論文を通して開発した変化検出手法とその分析結果を基に、人口動態の変化検出手法の発展性に関する議論を行う。

## 1.4 本論文の構成

本論文は全 6 章で構成される。各章の内容の要約を以下に記す。

第 1 章（序論）では、本研究の背景と目的を述べた。

第 2 章（既往研究の整理）では、状態推定問題を対象とする既往研究を整理する。まず、分野横断的に状態推定手法のレビューを実施し、各手法の持つ特性について述べる。次に、人口動態を対象とした既往研究を整理する。それぞれの取り組みの中で人口動態の状態がどのように定義・分析されているかを説明する。また、前章で行ったデータの整理結果を踏まえ、各既往研究内で使用されているデータと分析内容との関係を整理する。

第 3 章（状態推定手法の基本フレームワーク）では、状態推定の基本フレームワークとなる状態空間モデルについて述べる。状態空間モデルはデータ同化の文脈で頻繁に使われているモデルであり、観測データとシミュレーションを統合することが可能である。しかし人口動態分析における潜在状態の時系列遷移を記述するシステムモデルに制約があることなど、本論文で扱う問題にデータ同化を適用することには課題がある。これを、データ同化手法の適用を通じて示す。そこで、既存シミュレーションモデルによらないデータ指向的な方法として、状態変数に離散値を置く隠れマルコフモデルの適用を考える。そして東京 23 区のメッシュ人口の潜在状態の推定と視覚化の適用を例に、状態数を事前に設定する必要があること、および推定される潜在状態の解釈が困難であることがモデル拡張のための課題であると示す。これらの議論を踏まえた上で、人口動態の状態推定に向けたモデル拡張方針について述べる。

第 4 章（隠れマルコフモデルによる変化検出）では、前章で議論したモデル拡張方針に従い、階層ベイズ法の導入および事前分布の共有化によるモデルを構築する。また、そのモデルをメッシュ人口に対する変化検出問題へと適用する。変化検出においては、平常時のメッシュ人口時系列から平常状態およびモデルパラメータを学習し、そのモデルを用いて検証用メッシュ人口時系列の潜在状態を推定した上で変化スコアを算出する手法を開発する。シミュレーションデータへの適用を通じ、提案手法の精度検証を行うとともに、実データに対する適用と考察を通じて、手法の有効性を実証する。

第 5 章（トピックモデルによる変化検出）では、推定された潜在状態の意味解釈を容易にすることを念頭に、自然言語の分野でよく用いられるトピックモデルによるアプローチを導入する。状態数の事前設定の問題を解消するため、階層ベイズ法を導入したトピックモデルとしてモデルの構築を行い、人口動態の状態推定を行う。人口動態をトピックモデルとして捉えるため、各時刻における各メッシュを一つの文書、そのメッシュ内に存在する滞在者の居住地を一つの単語、「ある地域からの来訪者が潜在的に多い」などといった潜在的な構造としての人口特性をトピックして扱う。そして、実データに対する適用を通じ、手法の適用可能性を実証する。その中で、推定された潜在状態（トピック分布）の意味解釈の有効性、およびメッシュ毎の潜在的状況の把握の有効性について分析・考察する。さらに、メッシュ毎に推定されたト

ピック分布の比較に基づく変化検出手法を構築する。提案手法を実データへと適用し、人口動態の構成に変化が起きたと考えられるメッシュの検出と、その変化内容の意味解釈を行う。そして上述した隠れマルコフモデルによる変化検出手法とトピックモデルによる手法の特徴について比較し、人口動態の変化検出手法の更なる発展性について議論・整理する。

最後に、第 6 章（結論）で本論文の成果をとりまとめ、今後の課題および展望について示す。

また、付録 A では新たな人口動態データ取得方法の可能性として空中写真からの車両認識について述べる。付録 B では人口動態の再現・予測を行うためのデータ駆動型シミュレーションモデルの作成方法について示す。

## 第 2 章

# 既往研究の整理

### 2.1 潜在状態推定手法の整理

#### 2.1.1 潜在状態推定問題の概要

状態推定，特に潜在状態の推定問題とは，観測データ集合からその背後に潜む潜在的な物理量や構造を推定することである．潜在的な物理量とは，観測されたデータからノイズを除去した真のデータであることもあれば，観測できない何らかの別の変数である場合もある．もしくは，データの構造や状態を推察するために，より解釈可能な形にデータを処理したうえで，別途設けた方策によってデータを分類することによって状態推定が行われる場合もある．このように状態推定問題に厳密な定義は存在せず，その適用ドメインや扱われる手法によってその考え方はさまざまである．

そこで以下では，状態推定のための手法やそれに準ずる手法について挙げる．本論文では，推定対象である潜在状態に対する捉え方の違いに着目し，モデルの導入に基づく状態推定手法とデータの変換に基づく状態推定手法に大別する．前者は，推定対象である状態に対応する概念として，観測できないがデータ生成に影響を与える潜在変数として捉えるものである．そのため，観測データが生成される過程を表すモデルの構造を仮定したうえで，観測されたデータから潜在変数を推定することとなる．一方，後者の場合は，観測データを低次元化したりノイズを分離したりすることによって，データの本質を表す物理量へと変換することを考える．その後，別途設けた方策に従ってデータを分類したりラベリングしたりすることで，観測されたデータの潜在的な状態を推定することとなる．以下では，各手法について具体例とともに概説する．

#### 2.1.2 モデルの導入に基づく状態推定手法

観測データを生成するモデル構造を仮定し，その中に観測されない潜在変数を有する手法である．扱う手法によって構築するモデル構造が変わるが，いずれの方策においても，観測データを観測ベクトルと捉えたときに，推定したい状態を潜在変数と捉えることとなる．その推定手法の多くにベイズ学習の理論が用いられており，データセットからその潜在変数の取りうる

値や分布を推定することで状態推定が行われる。この方策のメリットとしては、観測されない物理量をモデルに組み込むことができるため、任意の潜在状態について推定を行うことができる点にある。ただし、複雑なモデル構造を仮定する場合にはその推定が困難となる場合がある。

### 状態空間モデル

時系列データに対する状態推定問題を解くための最も一般的かつ古くから利用されてきた手法である。状態空間モデルは非常に幅広い概念であり、もともとは物理システムの記述に使われていたモデルである。Kalman[16]により理論の整備がなされた本手法だが、ほとんどの時系列モデルを表現できる汎用性の高い時系列分析のモデルゆえに幅広い分野にて用いられる。状態空間モデルは観測できない変数である状態ベクトルと、観測される変数である観測ベクトルから構成される。潜在状態の時系列遷移を規定するシステムモデルに従って状態ベクトルが時間変化すると共に、各々の状態ベクトルから観測モデルに従って観測ベクトルが出力される機構を持つ。この問題設定下では、観測されたデータに基づいて、カルマンフィルタやパーティクルフィルタなどの逐次ベイズ手法によって潜在状態の事後分布推定を行うこととなる。

状態空間モデルは時系列データと時間発展するシミュレーションを統合できるという特徴から、データ同化を目的として利用されることが多い。データ同化は Kitagawa[17] や Gordonら [18] によって提案された理論的枠組みであり、現象のモデルに対して断片的な観測値を融合する手法である。気象学・海洋学分野をはじめ、シミュレーションを活用した研究領域で発展してきた。シミュレーションの精度・性能を観測データによって改善する、観測データの不足をシミュレーションで補うといった特徴を有する。

状態空間モデルの中でも、システムモデルと観測モデルが線形で、各モデルに含まれるノイズがガウス分布に従うと仮定したものは線形・ガウス状態空間モデルとも呼ばれ、制御理論の文脈で頻繁に用いられる。また、システムモデルと観測モデルをより一般的な形として条件付き分布を用いて表現したものは一般状態空間モデルと呼ばれ、多種多様なシミュレーションモデルを取り組むことが可能となる。さらに、状態空間モデルの枠組みの中で状態ベクトルに離散変数をおいたモデルを隠れマルコフモデルと呼ぶ。状態変数を離散値であるがゆえに、その定義や時系列遷移の設定が一般状態空間モデルによるものよりも比較的容易に行うことができ、音声認識や形態素解析、ゲノム解析などに応用されているモデルである。

### トピックモデル

トピックモデルはもともと文書の確率的生成モデルとして提案されたモデルであり、文書データを定量的に分析し、そこに潜む意味(トピック)を統計的にとらえる(潜在的意味解釈)ことを目的として分析手法である。文書を構成する単語の組み合わせから文書全体のトピックを明らかにしようという試みの端緒となったのは、特異値分解を利用した手法である。その後、確率モデルへと発展を遂げ、2003年以降には階層ベイズモデルの導入により爆発的に関連研究が増加したといわれている [19]。トピックモデルの中でも表現能力の高さや推定方法の簡便さ、モデル拡張の容易さから最も代表的な手法として現在位置づけられているのが Latent

Dirichlet Allocation(LDA)[20]である。自然言語処理をはじめ、画像や購買データなどの大規模かつ非構造化データの潜在意味解釈や、データ生成モデリングを目的として盛んに適用されている。

### マルコフ確率場モデル

マルコフ確率場 (MRF) モデルは観測変数・潜在変数に対応するノード集合と、ノード間を接続する無向リンク集合からなるグラフィカルモデルである。有向リンク集合で構築されたモデルをベイジアンネットワークと呼び、無向リンク集合によるモデルをマルコフ確率場と呼ぶ。このモデルによる無向リンクは変数間の同時出現確率を記述することとなるため、知りたい物理量の空間分布についてある程度の連続性を仮定しやすいモデルとなる。具体的には、空間的滑らかさを持つ状態の出現確率が高くなるようなガウシアングラフィカルモデルや、 $q$  個の離散状態をもつ  $q$  状態ポツモデルなどが挙げられる [21]。また、後述する制限ボルツマンマシン [22] はマルコフ確率場に属するニューラルネットワークモデルの一つである。

マルコフ確率場モデルを適用することで、観測データのみからノイズを自動的に除去することや、物理量の空間分布を精度良く推定することが可能となる。物理量の空間方向の連続性は自然科学分野のさまざまな対象に対して比較的妥当な過程であるので、画像データのノイズ除去や、脳科学分野における神経活動のマッピング問題など、多岐にわたる分野に適用されている。

### ニューラルネットワーク

ニューラルネットワークとは人の脳内の情報伝搬の様子を模した確率モデルであり、ノードとリンクによってデータの生成モデルや分類モデルが表現される。特に多層ニューラルネットワークによる機械学習を深層学習 (ディープラーニング) と呼び、近年、音声や画像、その他大量データを対象とした諸問題に対し、深層学習は高い精度を示すことが分かってきている。ボルツマンマシン [23] は 1980 年代に提案されたニューラルネットワーク由来の確率モデルであり、マルコフ確率場に属するモデルである。開発当初は学習に要する計算時間の制約により積極的な利用はされてこなかったが、2000 年初頭での制限ボルツマンマシン [22](RBM) の再発掘と効率的な学習理論の開発により、近年は深層学習技術の一部として大きな役割を担っている。RBM は観測できる可視変数と観測できない潜在変数を持っており、可視変数と潜在変数間のみ結合を有するボルツマンマシンである。RBM における潜在変数は、「可視変数の繋がりを柔軟にする蝶番のような存在 [24]」とも捉えることができ、データ生成過程のモデル化や、観測データからのノイズ除去、データ復元などの問題に使用されている。なお、RBM を複数積み重ねた深層ボルツマンマシンへの拡張や、深層ニューラルネットワークの事前学習機構としても利用されている。

また、自己符号化器 (autoencoder; AE) は入力と出力に同じ訓練データを設定して教師なし学習を行うことにより、データをよく表す特徴を獲得することを目的とするモデルである。AE によって抽出された特徴は、RBM を同様に、データの潜在的な特徴を表す潜在変数であると解釈することができる。この特徴量をもとにデータの分類や圧縮に使用したり、深層

ニューラルネットワークの事前学習に用いたりすることが可能である。

### 2.1.3 データの変換に基づく状態推定手法

観測データを低次元化したりノイズと分離したりすることによって、データの本質を表す物理量へと変換することを考える。その後、別途設けた方策に従ってデータを分類し、観測されたデータの潜在的な状態を推定することとなる。データの生成に関するモデル構造が未知の場合でも、データ指向的に推定を行うことができる方法である。ただし、モデル構造を仮定しないために、推定対象として扱える潜在状態に限りがある点がデメリットである。

#### スパースモデリングによる状態推定

スパースモデリングとはデータの冗長性を排除し、データの本質部分のみを抽出しようとする手法である。典型的なスパースモデリング手法としては、回帰分析におけるコスト関数にパラメータ絶対値の総和に対する制約を設ける LASSO が挙げられる。いずれの手法においても、最小化すべき目標とパラメータの縮小を合成したコスト関数を定義し、それを最小化することでスパースな解が求められる。

これらスパースモデリングの特徴として、データの本質部分のみを抽出することが可能な点である。例えば画像処理の分野では、画像データに含まれるノイズの処理であったり、動画像に対して適用することで変化点と背景部分の抽出を行うことが可能である。この文脈のもとでは、スパースモデリングによって推定されたデータの本質的な部分を状態として考えることとなる。

#### 因子分析

因子分析とは多変量データに潜む共通因子を探り出すための手法である。因子分析モデルでは、観測データは潜在変数である共通因子からの合成量であるとの仮定を置き、個々の構成要素を得ることが目的である。観測された多数の変数を少数の因子に縮約する統計手法であるとも換言できる。

#### クラスタリングによる手法

クラスタリングはデータの集合をクラスタという部分集合に分割する分析手法であり、代表的な教師なし学習手法である。k-means 法による非階層的クラスタリング手法や、最短距離法や Ward 法によって階層的クラスタリングを実施してデンドログラムを作図するなどの方法がある。これらクラスタリング自体は潜在変数の仮定を置かない手法であるため状態推定手法とはいえない。しかし分割したクラスタごとに、クラスタ内に含まれるデータの特徴を記述することで間接的にデータの解釈や全体パターンの把握を行うことができる。

## 2.2 潜在状態推定に関する研究事例の整理

### 2.2.1 潜在状態推定の適用分野の整理

状態推定手法は多岐にわたる適用ドメインにおいて普遍的な問題である。そこで状態推定問題が数多く適用されている分野を中心に、そのドメインにおける状態推定問題の考え方について整理する。

#### ロボット工学における自己位置推定

ロボット工学における自己位置推定問題は状態推定問題の大きなドメインの一つである。自己位置推定とは、ロボットなどの計測機器によって逐次計測される GPS やジャイロセンサ、加速度センサ、地磁気センサなどによる情報を用いて、機器の位置を求める問題である [25]。航空機やミサイル制御で利用されている慣性航法から端を発し、歩行者特有の加速度の波形から歩数を推定し、移動量を推定する PDF (Pedestrian Dead-Reckoning) [26] などの研究が積極的に進められている。これらの問題の多くの場面では観測情報としてセンサデータを設定し、真の位置や速度などを状態変数とした状態空間モデルによるモデリングが行われる。その上でカルマンフィルタやその発展的フィルタ手法による状態推定を通じて、真の位置を推定することとなる。

また、センシングした 2D/3D 画像を用いて周辺環境の 3 次元復元を自己位置推定と同時に行うことは SLAM (Simultaneously Localization and Mapping) [27] と呼ばれる問題である。自律移動ロボットなどに利用される手法であり、自己位置を推定しながら周辺環境地図を作成して動いていくことになる。中でも EKF SLAM [28] や Fast SLAM [29] は、推定すべき自己位置・姿勢と周辺環境を示すランドマークを潜在変数に組み込んだ状態空間モデルを構築した上で、拡張カルマンフィルタや Rao-Blackwellized パーティクルフィルタで逐次推定を行っている。また、スマートフォンなどに搭載されている簡易センサやカメラ情報を同化させることによって自己位置推定を行おうとする研究も存在する [30][31]。

#### 各種センサを利用した物体追跡

ロボット工学やコンピュータビジョンの分野における物体追跡では、固定カメラからの動画像などの各種センサ情報を取得することによって、移動物体の現在位置及びその経路を検知・追跡することを目的とする。例えば歩行者追跡システムでは人物の真の位置や速度などの物理量を潜在状態として考える。そして、カメラ映像や距離画像などのセンサ情報、およびそれらの情報から計算した特徴量などを観測データとして与え、追跡対象の時系列的挙動を予測するシミュレーションモデルをシステムモデルとして持つ一般状態空間モデルを考慮する [32][33]。状態空間モデルの設計には、計算のリアルタイム性や人の動きの連続性を考慮した線形ガウス状態空間モデル [34] や、詳細な歩行者モデルを考慮した一般状態空間モデル [5] が考えられ、カルマンフィルタやパーティクルフィルタによって潜在状態の推定が実施される。また、自律

型移動カメラによるリアルタイム顔追跡 [35] では、カルマンフィルタと Echo State Network を組み合わせた状態推定手法によって、ユーザの顔の追跡と移動カメラの自立制御が行われている。

### 画像処理への応用

状態推定問題を応用した画像処理技術も盛んに研究されている。例えば画像データからノイズを除去したり、オクルージョンが存在する画素部分の推定を行う手法は、画像データに対する潜在状態の推定手法と換言できる。観測されている画像データをノイズやオクルージョンを含んだデータと設定し、潜在状態としてノイズが付加される前の真の画像データを推定することとなる。マルコフ確率場モデリングによって隣接画素間の連続性を仮定することによって、画像のノイズ除去 [36] や超分解能画像の生成 [37] が行われている。また、スパースモデリングを利用した事例では、ノイズを含まない画像データ空間への射影によるノイズ除去や、テクスチャと線画の分離などが行われている [38]。

ニューラルネットワークを用いた手法では、ノイズやオクルージョンの除去をはじめとして多岐にわたる応用研究が実施されている。畳み込みニューラルネットワーク (CNN) を用いた画風変換アルゴリズム [39] では、コンテンツ画像に書かれた物体の配置をそのままに、画風をスタイル画像に変換した画像を生成する。CNN によってスタイル画像に含まれる画風という潜在的なメタ情報を抽出し、コンテンツ画像の画風を置き換えることによって画風変換を行うこととなる。また、ニューラルネットワーク型生成モデルとして、generator と discriminator という 2 つのネットワークによってデータの生成過程を学習する Generative Adversarial Network (GAN) [40] が開発されている。この派生モデルである DCGAN [41] を利用することにより、例えば「サングラスをかけた男」 - 「男」 + 「女」 = 「サングラスをかけた女」という演算を、画像特徴を示す潜在空間上で行い、その演算結果である画像を生成することが可能となる。

### ネットワークにおける状態推定

電力網や電力システムにおける状態推定問題は、ネットワークデータを対象とした状態推定の中でも古くから扱われてきた問題である。電力網の信頼性の高い運用を保証するためにはシステム監視が必要であり、電力メータの測定や電力システムモデルの分析を通じて電力網の状態を推定することとなる [42][43][44]。同様に、インターネットや携帯電話通信網などのネットワーク上を日々大量に流れる通信データを用いた状態推定も盛んである。

また、ネットワーク上の異常検知問題の適用も盛んであり、センサネットワークの故障検知やサイバー攻撃の早期検知 [45]、電力システムへの不正データ注入攻撃検知 [46] などに適用されている。

### 心理状態の推定

観測できない物理量として、医療分野において心理状態の推定への適用も盛んである。例えば fMRI データを用いた例 [21] では、隠れマルコフモデルと深層学習を利用して脳の

functional connectivity networks のモデル化が行われている。この研究では、学習したモデルを利用して軽度認知障害診断に使用することが提案されている。また、計測された脳波データから被験者の感情の推定を目指した手法の開発も行われている [47]。

医療分野以外でも心理状態の推定は関心のある領域であり、教育学の観点からは、カメラによって撮影された映像から聴講者が集中／非集中のいずれの状態にあるのかを、畳み込みニューラルネットワークによって推定するための検討が行われている [48]。さらに、スピーチ音声からの感情認識を目的として、深層ニューラルネットワークと隠れマルコフモデルの混合モデル (DNN-HMM) による検証も行われている [49]。

### マーケティングでの活用

状態空間モデルをはじめとするベイズモデリングを用いたマーケティング現象のモデル化も多く行われている [50]。例えば POS データを用いた市場反応分析の例では、商品に対する消費者の値ごろ感を示す指標である参照価格などの高次情報が潜在構造に組み込まれた上で、商品陳列方法が売りに上げに与える影響の分析が行われている [51]。また、RFID から取得した顧客の動線とその顧客の POS データを用いて、商品の購入を比較・検討している熟考状態と、どの商品を買うか具体的に検討している実践状態を隠れマルコフモデルによる推定を行った研究もある [52]。

また、EC サイトにおける購買データやアクセスログからユーザがどのような商品に興味があったのか、など消費行動における心理状態の推定を試みた例も複数登場している。例えばトピックモデルの拡張モデルである Topic Tracking Model を用いたアクセスログの解析が行われている [53]。ここでは購買商品と関連した有用なトピックを検出することで、ユーザの興味関心の推定が実施された。サービスのパーソナライゼーションという観点では、ある状況下でユーザは何を要求しているのかというユーザの認知的な状態を組み込んだシステム構築技術が提案されている [54]。これらの研究で用いられているアプローチは、ウェブログ分析、アイトラッキング分析などの分野でも横断的に用いられている方法であり [55]、ビジネスへの活用・展開も盛んである。

### 都市構造の推定

都市の潜在構造の推定という問題に対しても、様々な状態推定手法を通じた研究・検証が数多く存在する。例えば稲垣ら [56] は中心市街地の店舗の共起関係に基づいて、店舗の集積メカニズムを説明できる潜在的な属性を実証的に明らかにした。この研究では、店舗をノード、店舗間の共起関係をリンクとして店舗の共起ネットワークで店舗集積を表現し、店舗の共起ネットワークを生み出した店舗の潜在的な属性を推定が試みられた。氏家ら [57] の集積領域検出に関する研究では、集積領域の分割自体を潜在変数と置いた上で状態推定を行っている。また、社会活動から見た機能地域を発見するためのトピックモデリングベースのアプローチが Yuan [58] らによって提案されている。

他にも、地域別の指標を推定することを目的とした研究に、市区町村ごとの自殺者数データから、自殺リスク指標としての標準化死亡比の推定を行った例 [59] が挙げられる。ここでは、

人口が少ないエリアでの偶然変動による推定への影響に対処するため、空間的な相関を考慮した CAR(Conditional AutoRegressive) 事前分布を導入した階層ベイズモデルによる推定が行われた。

## 2.2.2 人口動態分析における潜在状態推定のレビュー

ここでは、人口動態に関して状態推定を行っている既往研究について整理する。整理の方針としては、状態推定を行う目的による分類を行い、その中でデータセットや観測対象ごとにまとめ、各事例において取られている状態推定手法を紹介することとする。

### データ可視化による人口動態把握に関する研究

人口動態に関するデータの異質性や複雑性、そしてそのボリュームを理由に、目的ごとにすべて自動化した分析を行うことは簡単なタスクではない。そのため、人間を分析プロセスに統合して、人間の持つ知覚能力をデータセットに適用することが求められる [60]。すなわちデータの視覚化を通じた分析である。都市内における OD フローや人口分布の代表的なパターンなど、対象空間全体の人の流れや滞在に関する情報を解釈可能な形に縮約して視覚化するかに主軸を置いた研究が数多くなされている。これらの研究では潜在変数の導入などによる統計的な状態推定は行われていないが、クラスタリングや人口動態モデリングを通じた人口動態の状態把握が可能となる。

たとえば MobilityGraphs[61] は GPS プローブによる人の流れデータを時空間にて分類し、人口動態の状況把握を行うためのシステムとして開発された。時間および空間毎にその代表的な人口動態パターンが分かるため、事後的にその解釈を行うことで人口動態把握がより行いやすくなるという特徴を持つ。同様に大規模 OD データの可視化に向けて、Andrienko ら [62] は空間的および時間的抽象化を行うことで長期間の OD データの把握を容易にするアプローチを提案した。OD データを表すためにフローマップを用いるのではなく、ダイアグラムマップを使用して空間的な状況を表している。また、Krueger ら [63] は twitter の位置情報付き投稿から OD データを復元し、人口動態の探索や比較を行うための視覚的分析システムを開発した。メッシュごとに代表的な移動方向を可視化するとともに、階層クラスタリングを複数のセルに対して実施することで大量の情報を容易に視覚化する手法が取り入れられた。

Xu ら [64] は、都市に配置されている 9,000 台の携帯基地局の大規模なトラフィックデータを用いて、そのパターンの抽出と時系列分析に基づくモデリングを行った。観測データを規則的な要素とランダム性に関する要素に分解することで大規模データの処理を可能にするとともに、規則性とランダム性に関する要素の地理的空間分布を表示することで、そのパターンの抽出と把握を行った。また Demissie ら [65] は、セネガル国内の CDR データから対象地域内の主要 OD フローを抽出することで交通需要を推定した。既存バス路線と比較することで新規バスルートの提案した。さらに Wu らは [66]、中国国内の CDR データを用いたバイクラスタリング分析によって人の移動傾向が似ている地域の抽出を行い、その可視化システムを提案した。Sanya ら [67] はウガンダ国内の CDR データを用いて農村都市間の移動について分析を

行った。

Purnama ら [68] はロンドン市内のシェアサイクルデータを使用し、都市内における移動の特徴把握が実施された。アカウント情報に基づいてユーザ分類を行い、次の行き先スポットの予測を行った。

### データ同化を用いた人の流れの推定に関する研究

データ同化は、予測モデルと観測データとを確率的に統合する手法であり、シミュレーション技術の発展と大量データ取得可能性の高まりとにより生まれてきた考え方である。観測データを用いてシミュレーションモデルの精度・性能を改善し、さらに、シミュレーションによって将来得られるデータを予測して実観測データにおける観測の誤差を修正することができる。交通の分野においても、データ同化を用いて人の流動を高精度に推定しようとする研究が進んでいる。

例えば中村 [69] は、確率的に人の流れを推定するシミュレーションモデルと、データ同化手法を用いた観測値の融合手法を提案した。非連続で離散値をとる移動軌跡の確率分布を潜在状態に設定することで、シミュレーションモデルの種類によらないデータ同化が可能となっており、大崎駅構内と東京都市圏でのスケールの異なる人の流れの推定について検証した。災害時の人の流れをリアルタイムに推定するために、矢部ら [70] は個人ベースの災害行動モデルを用いたシミュレーションをリアルタイムに得られるメッシュ人口データと同化することで、災害時の数時間先の人々の流動の予測を行った。個人ベースで詳細な移動経路の推定をするための研究としては、長谷川ら [71] の研究がある。携帯電話基地局情報に基づく位置データを同化することで、長期間の観測履歴にみられる観測の規則性を反映した人の移動推定手法が提案された。また、原田 [72] は、個人の一日の活動全体を詳細に表現するアクティビティモデルに、観測値として一日の中で高頻度に取得可能な 1 時間ごとの滞留人口データや ETC プローブデータを同化させる手法の開発を行った。

ミクロな人の流れを対象にした研究例としては、中西 [5] は歩行者挙動モデルによるシミュレーションと動画像の統合を行うことによって、人物挙動の詳細把握に向けた人物追跡手法を開発した。

### 交通状況の推定に関する研究

交通量をはじめとする交通状況の推定を目指す研究も盛んに行われている。回帰分析やニューラルネットワークによってそれらを予測するモデルは数多く提案されているが、ここでは状態推定を通じた研究について紹介する。

Iwata ら [73] は、メッシュ人口データから OD フローを推定するための手法を提案した。データからは観測されないメッシュ間を移動している人数を潜在変数として導入したベイジアンネットワークを構築し、その有効性を実証した。また、Fiori ら [74] は対象ゾーン間の交通ダイナミクスを動的なグラフ推論問題として捉え、交通パターンの推定を行った。米国航空および NY タクシー交通に関する 2 つのオープンデータを用いた検証を実施した。

### 異常状態の推定・検知に関する研究

人口動態における異常検知の研究は多種のデータを対象に様々な研究が行われている。ただし異常状態の定義が研究によって異なっており、ゆえに手法の開発もアドホックである。対象とする異常とは何か、どのような特徴を持つデータを用いるのかなどの検証を着実に行ったうえで、異常検知手法を組む必要があることが示唆される。

例えば Candia ら [75] は、メッシュ毎に集計した携帯電話の通話記録データを対象として異常イベントの発生場所や日時について浸透理論を用いた分析を行った。Horanont [76] は同様のデータを対象とした分析を行う中で、メッシュに内挿処理を施すことでホットスポットの検出を容易にし、構築したプラットフォーム上での可視化を行った。

車両プローブデータを利用した例として、Pan ら [77] は交通ネットワーク上の運転航路に着目して交通事故等の異常検知を行った。Horiguchi ら [78] は、エリア集計 QK 曲線と実測値との乖離度を測ることで非日常的な混雑状況を持つメッシュを検出、可視化した。また、井料ら [79] は阪神高速道路への時間帯別流入交通量の週変動に着目し、個々の行動を非集計的にモデル化した上で、変動の要因を推測することを行った。井上ら [80] は空港流入交通量データに対して独立成分分析を適用することにより、欠航日に特有の交通量の時間分布特性の解明を試みた。Wang ら [81] は交通ネットワーク上における正常な交通状況というものは動的に変動するものだとその前提を置いた上での交通異常の検出方法を提案した。Li ら [82] は異常検出を含む交通状況の時系列分析は、トレンドモデリングによって統一的に記述することができる」と議論している。この他にも、GPS によって取得した大量のタクシー乗降データを元に、交通事故や悪質ドライバーなどが原因で異常な経路を走行しているタクシーの検出を行った研究 [83] などが存在する。

もう少しミクロな空間を対象に、動画像を用いた人口動態の異常検知が Mahadevan らによって行われた [84]。監視ビデオに映る群衆行動を dynamic texture と呼ばれる動画像から抽出した特徴ベクトルを利用した混合モデルとしてモデル化し、負の対数尤度を使用することで動画内の異常行動を検出する機構である。

### 移動情報を基にした都市構造の把握に関する研究

Grinberger ら [85] はエルサレムの都市構造について GPS ログとその移動目的に関するアンケート調査結果を基に回帰分析を行い、潜在的な中心地域を抽出した。Mahrsi ら [86] は IC カードデータを利用した公共交通システムにおける移動パターンの抽出を行った。駅と乗客に関する 2 つの視点から、潜在変数を導入したモデルベースなクラスタリングを実施し、各クラスタを利用形態やユーザ属性に基づいて解釈を行った。また、Zeng ら [87] は人の動きと POI(関心ポイント)の種類によって特徴づけられる地域特性を可視化するためのツールを開発した。シンガポールの大規模な公共交通データと Foursquare から得られるチェックインデータを対象に、エリアごとの地域特性のケーススタディを実施した。同様に、Krueger ら [88] は、GPS 移動データと Foursquare データを統合し、任意エリアの移動に関する地域特性をインタラクティブに可視化するシステムを提案した。

### 2.2.3 本研究の位置付け

本論文では、メッシュ人口分布データを利用した分析を行う。データカバー率が大きいデータとして日本国内における入手取得可能性も大きく、かつ細かな時空間分解能でのデータとして利用できるためである。そして扱う状態推定手法としては、メッシュ人口データが持つ時系列性の表現、潜在状態や観測状態の定義のしやすさ、拡張性の高さに着目し、状態空間モデルなどによるモデル表現による状態推定を目指す。ただし状態空間モデルといってもかなり広い表現方法であるので、第 3 章において潜在状態の設定方法の観点から適用方法の検討を行う。

また本研究は、観測される人口動態データの背後には潜在的なデータ構造や状態が存在するという立場に立っており、状態推定手法を通じてその分析を行う。そして推定された潜在状態における変化の検出を行う。見かけ上の人口値の変化ではなく、その背後に存在する潜在状態の変化を検出することで、短期的な視点では開催されたイベントがもたらした人口動態や人の動きへのインパクトの評価、そして長期的な視点では交通インフラの新設による人口動態の構造変化などができることを考える。また、推定された潜在状態の意味解釈を行うことで人口動態をより深く把握することを目指す。そしてその解釈結果を用いた変化検出へと応用することで、イベントがもたらしたインパクトとは何だったのか、どのような潜在的ニーズの変化に対して交通サービスを改善する必要があるのかなど、評価や意思決定に対してより有用なものとなることを考える。

## 第3章

# 潜在状態推定手法の基本フレームワーク

### 3.1 基本となる状態空間モデル

本章では状態推定問題の基本となる状態空間モデルについて概説する。

状態空間モデルの枠組みでは、実システム、シミュレーションモデル、観測モデルの3つを考慮する。実システムとは、解析対象とする現象についての情報である。いま、この実システムに関する情報それ自体は直接観測することができない場合を考える。この場合実システムはシミュレーションモデルにより表現されるが、シミュレーションモデルは本質的に実システムに対して誤差をもつ。また、実システムから、観測モデルに従って生起するデータを観測できると考える。この時、実システムに関する情報が状態と呼ばれ、観測データからでは直接得る事ができない。観測データを手がかりに、直接観測できない状態を推定することは、一般に潜在状態の推定と呼ばれる問題である。

#### 3.1.1 状態空間モデルの定式化

シミュレーションでは、実システムの現象が思うように表現できないことが多くある。この場合、シミュレーションの計算結果に遊びを許し、観測データを取り込める自由度を持ったものへと拡張する。同時に、シミュレーションの計算結果と観測データの間にも自由度を持った関係を構築する。以上の2つの自由度を持った関係をそれぞれシステムモデル、観測モデルと呼び、あわせて状態空間モデルと呼ぶ。これにより、観測で得られたデータをシミュレーションに埋め込み、予測精度を向上させ、予測のみでは真の状態から徐々に離れていく解析結果を、真の状態へ近づけることが可能になる。本節では、データ同化を数学的に記述したモデルである状態空間モデルおよびその一般形である一般状態空間モデルについて説明する。

線形・ガウス型の状態空間モデルの式を以下に示す。

$$\begin{aligned} z_t &= F_t z_{t-1} + G_t v_t \\ x_t &= H_t z_t + w_t \end{aligned} \tag{3.1}$$

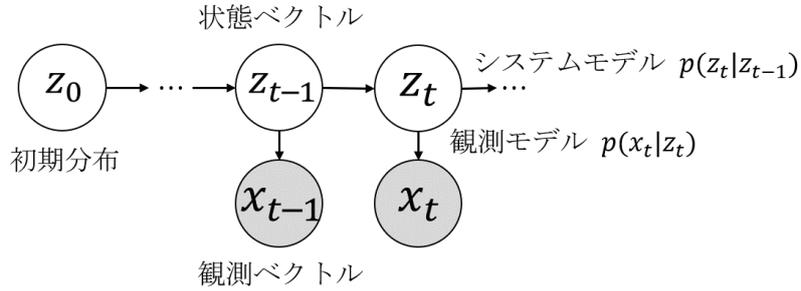


図 3.1. 一般状態空間モデル

$z_t$  は時刻  $t$  における状態ベクトル,  $x_t$  を観測ベクトル,  $v_t$  をシステムノイズ,  $w_t$  を観測ノイズと呼ぶ. 状態ベクトルは直接観測が不可能な値である. また,  $F_t, G_t, H_t$  はそれぞれ対応する行列とする. 式 (3.1) の上式はシステムモデルと呼ばれ, 状態  $z_t$  の時間発展を表す. 式 (3.1) の下式は観測モデルと呼ばれ, 状態ベクトルと観測ベクトルの関係を表す. この二式を連立させたモデルを状態空間モデルと呼ぶ. 状態空間モデルの運用には, あらかじめ下式のよ
 うに初期状態, システムノイズ, 観測ノイズの確率分布を指定する.

$$\begin{aligned}
 z_0 &\sim p(z_0) \\
 v_t &\sim p(v_t) \\
 w_t &\sim p(w_t)
 \end{aligned} \tag{3.2}$$

式 (3.1) で表される状態空間モデルを非線形・非ガウス型に対応させたモデルは下式で表される.

$$\begin{aligned}
 z_t &= f_t(z_{t-1}, v_t) \\
 x_t &= h_t(z_t, w_t)
 \end{aligned} \tag{3.3}$$

システムノイズ  $v_t$  と観測ノイズ  $w_t$  は, それぞれ確率密度関数  $p(v|\theta_{sys})$  および  $p(w|\theta_{obs})$  に従う白色雑音である.  $\theta_{sys}$  および  $\theta_{obs}$  は, それぞれの確率分布を記述するのに必要なパラメータベクトルである. また,  $f_t$  および  $h_t$  は行列ではなくそれぞれ  $z_{t-1}$  および  $z_t$  に関する非線形関数である.

この非線形・非ガウス型をさらに一般化し, システムモデルと観測モデルを条件付き分布により表現したモデルを一般状態空間モデルと呼び, 下式で表される.

$$\begin{aligned}
 z_t &\sim p(z_t|z_{t-1}) \\
 x_t &\sim p(x_t|z_t)
 \end{aligned} \tag{3.4}$$

式 (3.4) の第一式は  $z_{t-1}$  が与えられたときの  $z_t$  の条件付き分布, 第二式は  $z_t$  が与えられたときの  $x_t$  の条件付き分布である. 一般状態空間モデルのグラフィカル表現は以下の図 3.1 のようになる.

以上より, 一般状態空間モデルは初期分布, 状態ベクトル, 観測ベクトル, システムモデル, 観測モデルの 5 つの要素により構成されていることがわかる. まず, 一般状態空間モデルに

おいて計算を開始する際には、初期分布をあらかじめ設定しておく必要がある。クラスタリングなどの結果から初期分布を推定したり、理想的な初期値を設定したりするなど、状態に関する情報に従って適した分布を設定することが多いが、情報が得られていない場合は一様分布など適当な分布を仮定する。状態ベクトルには直接観測できない変量を定義することが可能である。状態ベクトルに含まれる変量の値は観測データのみからでは算出することができないが、一般状態空間モデルを用いた推定を行うことで、状態ベクトルの値を推定することが可能となる。システムモデルとは、これらの状態ベクトルの時間推移を表現したモデルである。確定的なシミュレーションを行う場合にはシステムモデルの解は一意に定まるが、状態空間モデルの枠組みでは確率モデルを利用し、解は確率分布に従って得られることとなる。一方で観測ベクトルには実際に観測が可能な変量を設定する。そして観測ベクトルと状態ベクトルの関係は観測モデルにより規定される。観測モデルもシステムモデルと同様に確率モデルを用いた表現が行われ、観測ベクトルを通じて状態ベクトルを推定していくこととなる。

### 3.1.2 バイズ推定による潜在状態の推定

直接観測できない状態ベクトルは、バイズ推定の枠組みにより事後分布として推定を行うことが可能である。バイズの定理を利用することで、以下の 3 つの条件付き分布を得ることができる。

$$\text{予測分布: } p(z_t | x_{1:t-1}) = p(z_t | x_1, x_2, \dots, x_{t-1}) \quad (3.5)$$

$$\text{フィルタ分布: } p(z_t | x_{1:t}) = p(z_t | x_1, x_2, \dots, x_t) \quad (3.6)$$

$$\text{平滑化分布: } p(z_t | x_{1:T}) = p(z_t | x_1, x_2, \dots, x_T) \quad (\text{ただし } T > n) \quad (3.7)$$

3 つの条件付き分布について説明していく。まず、 $t-1$  期までの観測データに基づく  $t$  期の状態ベクトルの分布が予測分布  $p(z_t | x_{1:t-1})$  である。そこから新たに  $t$  期における観測データが入ってきて、 $t$  期までの観測データに基づく  $t$  期の状態ベクトルの分布がフィルタ分布  $p(z_t | x_{1:t})$  である。総数  $T$  個の観測データが全て得られているときの  $t$  期の状態ベクトルの分布が平滑化分布  $p(z_t | x_{1:T})$  である。当然、平滑化分布が状態ベクトルの推定に関して一番精度が高い。

この 3 つの分布間には便利な漸化式の存在が知られている。まず、手元に  $t-1$  期のフィルタ分布  $p(z_{t-1} | x_{1:t-1})$  があるものとする。このフィルタ分布が与えられると、予測の操作をもって、 $t$  期における予測分布  $p(z_t | x_{1:t-1})$  が以下の通り計算できる。

$$\begin{aligned} p(z_t | x_{1:t-1}) &= \int p(z_t, z_{t-1} | x_{1:t-1}) dz_{t-1} \\ &= \int p(z_t | z_{t-1}, x_{1:t-1}) p(z_{t-1} | x_{1:t-1}) dz_{t-1} \\ &= \int p(z_t | z_{t-1}) p(z_{t-1} | x_{1:t-1}) dz_{t-1} \end{aligned} \quad (3.8)$$

2 行目から 3 行目への式変形は、状態空間モデルで仮定しているマルコフ性による。マルコフ性とは、将来における確率分布は現在の状態だけから決まり、過去の状態には依存しないという性質のことである。また、 $p(z_t | z_{t-1})$  はシステムモデルである。

$t$  期における予測分布が推定された状態で、 $t$  期の観測データ  $x_t$  が得られると、ベイズの定理を用いてフィルタリングを行うことで、 $t$  期におけるフィルタ分布が以下の通り得られる。

$$\begin{aligned}
 p(z_t|x_{1:t}) &= p(z_t|x_{1:t-1}, x_t) \\
 &= \frac{p(z_t|z_t, x_{1:t-1})p(z_t|x_{1:t-1})}{p(x_t|x_{1:t-1})} \\
 &= \frac{p(x_t|z_t)p(z_t|x_{1:t-1})}{\int p(x_t, z_t|x_{1:t-1})dz_t} \\
 &= \frac{p(x_t|z_t)p(z_t|x_{1:t-1})}{\int p(x_t|z_t)p(z_t|x_{1:t-1})dz_t}
 \end{aligned} \tag{3.9}$$

4行目の式の  $p(x_t|z_t)$  は  $x_t$  に対する状態ベクトル  $z_t$  の尤度関数、 $p(z_t|x_{1:t-1})$  は  $t$  期における予測分布である。以上のように、一期先予測とフィルタの操作を最後のデータ  $x_T$  まで繰り返し行うことで、全てのデータ  $x_{1:T}$  に基づいた、最後の時点  $T$  の状態ベクトルのフィルタ分布が得られる。線形・ガウス型の状態空間モデルでは、状態の分布  $p(z_t|x_{1:t})$  は全て正規分布となるので、状態推定のためには平均ベクトルと分散共分散行列だけを求めればよい。これらを逐次的に求めるのがカルマンフィルタ等のアルゴリズムである。一方、一般状態空間モデルは、条件付き分布  $p(z_t|x_{1:t})$  は一般に非ガウス分布となる。そこで、その分布表現を近似する手法として、非線形カルマンフィルタ、アンサンブルカルマンフィルタ、パーティクルフィルタ等の手法を用いて求めていくこととなる。

### 3.1.3 状態空間モデルの適用方針

ここまで一般状態空間モデルについて述べたが、人口動態の潜在状態推定の問題に適用するにあたり、以下の問題を考える必要がある。まず、人口動態の潜在状態を考えるうえで、適切なシステムモデルとは何かである。本検証では人の動きを表すシミュレーションモデルに着目し、その適用可能性を探る。そこで第3.2章にて、システムモデルとして人の一日の移動を再現する既存シミュレーションモデルを設定し、メッシュ人口データとのデータ同化を行った研究成果について概説し、その適用可能性について検証する。また、上記シミュレーションモデルの適用が困難な場合、データ指向な手法が求められることとなる。そこで第3.3章にて既存シミュレーションモデルによらないデータ指向な方法として最も簡単な場合の隠れマルコフモデルの適用し、その適用可能性について検証する。二つの検証を通じ、本論文において対象とする人口動態の潜在的状態推定のための課題の抽出と、変化検出に向けたモデル拡張方針の整理を第3.4章にて行う。

## 3.2 データ同化による人口動態の状態推定

本節では原田および福富らによる既往研究 [72][89] を基に、システムモデルとして人の動きの既存モデルを適用し、データ同化の文脈で人口動態をモデリングを行う場合を想定する。

### 3.2.1 データ同化の全体像

本検証では、一般状態空間モデルの枠組みにおける状態ベクトル  $z_t$  を、時刻  $t$  における対象ゾーン内の全個人の位置  $z_t = [z_t^1, z_t^2, z_t^3, \dots, z_t^M]^T$  とした。ここで、 $M$  は対象個人の人数である。システムモデルには各個人の時刻  $t$  における個人位置を出力するアクティビティシミュレーション PCATS を利用し、個人の位置を随時推定していく。一方、観測ベクトル  $x_t$  にはモバイル空間統計のデータを利用する。メッシュ人口データを対象ゾーン単位へと集計しなおした上で、時刻  $t$  におけるゾーン別滞留人口  $x_t = [x_t^1, x_t^2, x_t^3, \dots, x_t^L]^T$  を観測ベクトルとして定義した。ここで  $L$  は対象ゾーン数である。また、観測モデルを、システムモデルにより推計された状態（全個人の位置）から得られるゾーン別滞留人口ベクトルと、観測データから得られるゾーン滞留人口ベクトルの時刻  $t$  における類似度として広義に定義した。この類似度に基づき、パーティクルフィルタによる逐次推定を行う。このモデル化により、アクティビティモデルから予測された個人の1日の移動に対し、任意の時間帯でフィルタリングを行うことで、現況に即した個人の移動の再現が可能になる。以下、システムモデル、観測モデル、フィルタリング手法の枠組みについて簡潔に説明する。

#### システムモデル

システムモデルとして、各個人の時刻  $t$  における個人の位置を表すアクティビティシミュレーション PCATS を利用する。PCATS とは、時空間プリズム制約条件を考慮した上で、個人の生活行動に関する意思決定を時間軸上で逐次再現し、それに伴い一日を通じての生活行動の軌跡を生成する生活行動マイクロシミュレーションモデルである。PCATS を用いることで勤務条件や交通・生活環境の変化に伴う個人の活動の実行・非実行、活動時間・場所・内容そして移動時の交通機関等の変化を予測することが可能となる。

このシステムモデルにおいて、時刻  $t$  におけるある個人  $i$  の位置  $z_t^i$  が分かっているとき、これを入力データに入力することで PCATS により時刻  $t+1$  におけるある個人  $i$  の位置  $z_{t+1}^i$  が推計される。

$$z_{t+1}^i \sim p(z_{t+1}^i | z_t^i) \quad (3.10)$$

#### 観測モデル

システムモデルによって予測された時刻  $t$  における状態ベクトル  $z_t$  の尤度を観測データであるゾーン別滞在人数単位で評価する。観測データであるモバイル空間統計のゾーン別滞在人数は集計データであるため、 $z_t$  の尤度を求めるために全個人の位置  $z_t$  をゾーン単位で集計したゾーン別人口  $z_t'$  に変換する。

観測モデルはゾーン別人口  $z_t'$  と観測ベクトル  $x_t$  の類似度として定義する。類似度には両ベクトル間の重み付きユークリッド距離の逆数とした。すなわちゾーンごとの人数誤差（重み付き）の二乗和の逆数となる。

$$p(x_t | z_t) = \frac{1}{d^2(z_t', x_t)} \quad (3.11)$$

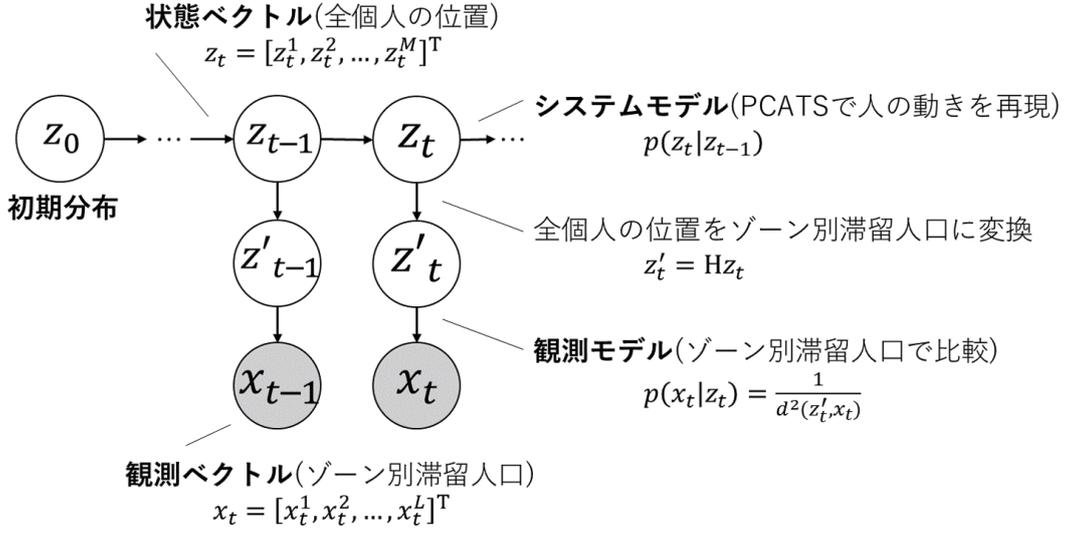


図 3.2. データ同化的アプローチの全体像

$$d^2(z'_t, x_t) = \sum_{j=1}^L w_j (z'^j_t - x_t^j)^2 \quad (3.12)$$

ここで、式中の  $d^2(z'_t, x_t)$  はベクトル  $z'_t$  と  $x_t$  のユークリッド平方距離、 $w_j$  は各変数の重みを表す。重み  $w_j$  は以下の通り定式化される。

$$w_j = \frac{1}{(x_t^j)^2} \quad (3.13)$$

### フィルタリング手法の枠組み

いま、時刻  $t$  における各個人位置のフィルタ分布  $p(z_t^i|x_t)$  が与えられているとする。この時、各個人  $i$  に対してフィルタ分布  $p(z_t^i|x_t^i)$  に従って時刻  $t$  における個人  $i$  の位置を表すパーティクルをそれぞれ  $N$  個生成する。これらのパーティクル  $z_t^i (i = 1, 2, \dots, N)$  をシステムモデル PCATS に入力し、時刻  $t+1$  における予測分布を表す予測パーティクル群  $z_{t+1|t}^i$  を得る。観測データとの比較のため各予測パーティクル  $z_{t+1|t}^i$  をゾーン別滞在人数  $z'_{t+1|t}^i$  に変換し、観測モデルを利用して各パーティクルの重み  $\beta_{t+1}^i (i = 1, 2, \dots, N)$  を算出する。

$$\beta_{t+1}^i = \frac{w_t^i}{\sum_{j=1}^N w_{t+1}^j} \quad (3.14)$$

$$w_t^i = p(x_{t+1}|z_{t+1|t}^i) = p(x_{t+1}|z'^i_{t+1|t})$$

最後に、各予測パーティクル  $z_{t+1|t}^i$  を重み  $\beta_{t+1}^i$  に比例する割合で  $N$  個復元抽出し、時刻  $t+1$  における各個人位置のフィルタ分布  $p(z_{t+1}^i|x_{t+1})$  を求める。手法全体像を図 3.2 に示す。

ゾーン番号	区名	地名
1(千1)	千代田区	大手町・丸の内など
2(千2)		永田町・飯田橋など
3(千3)		神田など
4(千4)		有楽町・霞が関など
5(中1)	中央区	日本橋など
6(中2)		日本橋・八重洲など
7(中3)		銀座など
8(中4)		築地・明石町など
9(中5)		勝どき・晴海など
10(港1)	港区	赤坂・青山など
11(港2)		六本木・虎ノ門・新橋など
12(港3)		芝浦・台場など
13(港4)		麻布・芝など
14(港5)		高輪・白金など

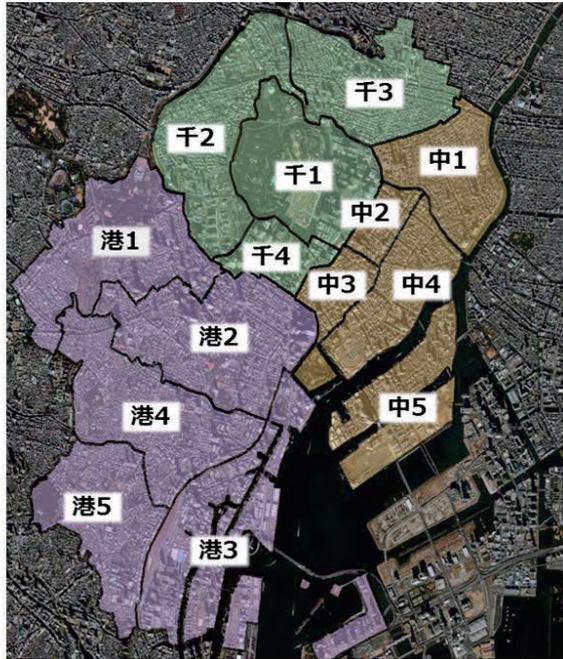


図 3.3. データ同化の適用対象ゾーン

### 3.2.2 データ同化の適用結果

#### 適用対象ゾーン

今回対象としたのは都心三区（千代田区・中央区・港区）の 14 ゾーンである。各ゾーンの範囲および位置関係をそれぞれ図 3.3 に示す。パーソントリップ調査で用いられている計画基本ゾーンレベルを採用した。本適用では、この対象ゾーンの中の個人の移動およびゾーン滞留人口の再現を目指すものとする。

#### 使用したデータ

PCATS を使用するにあたり個人・世帯属性、交通ネットワーク属性、地域属性、および固定時間帯のスケジュールを設定する必要がある。移動の再現対象とする個人のデータとして、平成 20 年に実施された第 5 回東京都市圏パーソントリップ調査のデータを利用した。本検証では対象ゾーンの内々交通を適用対象としているため、対象 14 ゾーンに居住地を持つ個人のデータに限定して抽出した。さらに、今回は対象ゾーンの内々交通のみを再現するため、対象ゾーン外に固定活動を持つ個人は対象外とした。対象人数は 253,182 人であった。また、交通ネットワーク属性として、同調査から、対象ゾーン間のトリップを代表交通手段別に抽出し、費用・時間・乗換回数等の平均値を算出した。地域属性（ゾーン別面積、人口、サービス事業所数、人口密度、サービス事業所数密度）に関しては平成 26 年商業統計調査結果を利用した。

観測データとして、モバイル空間統計を利用した。1 時間おきの 500m メッシュの人口を表すもので、個人の居住地大字別に人口が分類されている。本検証では、2015 年 6 月の東京 23

表 3.1. データ同化の適用結果

	9:00	12:00	17:00	21:00
観測ベクトルとの乖離 (同化後)	0.299	0.883	0.676	0.748
観測ベクトルとの乖離 (同化前)	0.386	0.903	0.702	0.810
同化後, 滞留人口が 観測値に近づいたゾーン数	10/14	9/14	8/14	13/14

区内のメッシュ人口の平日平均データを利用した。このデータから対象とする東京都心三区内のメッシュデータを抜き出した後、対象ゾーン内に居住地を持つ個人のゾーン別滞留人口データを抽出し、これを観測データとして用いることとした。

#### 適用条件

時間帯区分に関しては、一日を 3AM~9AM, 9AM~12AM, 12AM~5PM, 5PM~9PM, 9PM~3AM の 5 つの時間帯区分にわけ、その時間帯間でシミュレーションモデルの時間遷移を考える。うち、9AM, 12AM, 5PM, 9PM の 4 時点にて観測データとの同化を行うことにした。

初期状態 (各個人の AM3:00 での位置) は、各個人は初期時刻においては自宅に滞在しているという仮定のもと、全個人は AM3:00 において居住地ゾーンに滞在しているとした。以上の設定の下パーティクル数を 100 とし、パーティクルフィルタによる状態推定を実施した。

#### 適用結果

データ同化による効果を検証するため、観測データでの各ゾーンの滞留人口を表すベクトルと、同化前・同化後の各ゾーンの滞留人口を表すベクトルの重み付きユークリッド距離をそれぞれ各時間において算出した。また、各時間帯において同化後に、ゾーン滞留人口が観測値に近づいているゾーン数を求めた。その結果を表 3.1 に示す。結果が示す通り、全時間帯において同化後のゾーンの滞留人口ベクトルと観測データのゾーン滞留人口ベクトルの重み付きユークリッド距離が同化前に比べて減少しており、観測値に近づいていることがわかる。また、ゾーン単位でも、各時間帯において同化により観測値に近づいているゾーンが多いことがわかる。この結果より、本手法によってシミュレーション PCATS と観測データを統合することで、より現況に即した個人の移動の再現及び時間帯別ゾーン滞留人口推計を行うことが示された。

#### 考察

観測データとしてモバイル空間統計を利用して本手法を適用した場合においても、本手法により同化を行うことでゾーン滞留人口を再現性高く推定できていることが確認された。データ同化によってより現況に沿った個人の移動情報を得ることで、より再現性の高い時間帯別 OD 表や、カテゴリ別・目的別ゾーン滞留人口等の推計も可能となる。

一方で、このようなデータ同化的アプローチのためには状態ベクトルを定義したうえで、潜在状態の時系列遷移を記述するシステムモデルを構築する必要がある。本検証では、状態ベクトルに人の位置を設定し、システムモデルとしてアクティビティモデル PCATS を使用した。しかし、本論文で扱う問題は人口動態の潜在状態の推定であり、人の流れ・位置そのものではない。そのため、データ同化的アプローチを本問題に適用するためには、人口動態の潜在状態を表す状態ベクトルを定義したうえで、その時系列遷移を表現するシステムモデルを構築しなければならない。

データ同化の文脈では、状態ベクトルに人の位置や速度、密度など多くの情報を設定し、多変量の状態ベクトルをもつ状態空間モデルを構築するという方法が考えられる。ただし人口動態を考える場合、多種多様に存在するデータを考慮したシミュレーションモデルを構築することへの課題が残る。人の位置・流れ以外に対するシステムモデルの制約や、そもそもそのようなシステムモデルが欠如しているためである。一方、多種多様なデータが大量に存在していることを利用して、データ指向的にシミュレーションモデルを作成する方針も考えられる。付録 B では、大量に存在するデータ自体からシミュレーションモデルを作成する方法について検討した。ただし、予測精度の観点からはその適用可能性はいまだ低いと言わざるを得ない。従って、人口動態の潜在状態を取り扱うモデルの制約・欠如により、上記データ同化に基づくアプローチの適用可能性は本論文では限定的であると考えられる。

### 3.3 隠れマルコフモデルによる人口動態の状態推定

前節の検証では、人口動態の潜在状態の推定には既往シミュレーションモデルを基にした状態推定手法の適用が困難であることが確認された。そこで本節にて、既存シミュレーションモデルによらないデータ指向な方法として最も簡単な場合の隠れマルコフモデルの適用を考える。隠れマルコフモデルでは潜在状態に離散変数を置くため、潜在状態ベクトルの明確な定義が不要である。また、その時系列遷移は状態遷移確率として表現されるため既存モデルの制約を受けず、潜在状態の推定とともに遷移機構を学習することが可能である。以下、隠れマルコフモデルの基本原理を概説した後、メッシュ人口データへと適用し、その適用可能性について考察する。

#### 3.3.1 隠れマルコフモデルの定式化

隠れマルコフモデルとは潜在状態ベクトルに離散変数をおいた状態空間モデルであると考えられることができる。状態変数を離散値にすることで、その定義や時系列遷移の設定が一般状態空間モデルによるものよりも比較的容易に行うことができる。また、先の例ではアクティビティモデルなどをシステムモデルとして設定する必要があったが、隠れマルコフモデルによる時系列遷移は状態遷移確率によって定義される。そのため、未知の潜在状態量に対しても時系列遷移を推定することが可能であり、本論文にて扱う人口動態の潜在的状態推定への適用可能性が高いと考えられる。

### 隠れマルコフモデルの原理

隠れマルコフモデルにおける  $t$  時点における潜在状態変数を  $z_t \in \{1, 2, \dots, K\}$ , 観測ベクトルを  $x_t$  とする. ここで  $K$  は潜在状態数であり, モデル構築にあたり事前に設定する必要があるパラメータである. 潜在状態変数間の時系列遷移は以下の通り定式化される.

$$p(z_t | z_{t-1}, \{\pi_k\}_1^K) \sim \pi_{z_{t-1}} \quad (3.15)$$

上式では 1 次マルコフ性の仮定を置いたが, 一般に  $n$  次マルコフ性へと拡張することが可能である. また, これは状態遷移確率  $\pi = \{\pi_k\}_1^K$  に従って時系列遷移が規定されていることとなる.

一方, 各時刻  $t$  における潜在状態ベクトルから観測ベクトルへの出力は以下の形式で表現される.

$$p(x_t | z_t, \{\varphi_k\}_1^K) \sim F(\varphi_{z_t}) \quad (3.16)$$

ここで  $F(\varphi)$  は出力確率分布であり, カテゴリカル分布や正規分布, 混合ガウス分布など多様な分布系を設定することが可能である. また,  $\varphi = \{\varphi_k\}_1^K$  は出力確率分布を支配するパラメータ集合である.

モデルが均一であるとき, すなわち状態遷移確率  $\pi$  と出力分布パラメータ  $\varphi$  が全時刻を通じて一定であるとき, 潜在変数と観測変数の同時確率分布は以下ようになる.

$$p(X, Z | \pi, \varphi) = p(z_1 | \pi_0) \left[ \prod_{t=2}^T p(z_t | z_{t-1}, \pi) \right] \prod_{t=1}^T p(x_t | z_t, \varphi) \quad (3.17)$$

図 3.4 に, 隠れマルコフモデルのグラフィカルモデルを示す. 隠れマルコフモデルは状態変数に離散値をおいた状態空間モデルであるので, 前述の図 3.1 による表現も可能である. ただし本図では状態遷移確率  $\{\pi_k\}_1^K$  と出力分布パラメータ  $\{\varphi_k\}_1^K$  の関係を明示的に示した表現となっている.

### モデルパラメータの学習

データ集合  $X = \{x_1, x_2, \dots, x_N\}$  が観測された場合, 隠れマルコフモデルのパラメータ  $\theta$  を最尤推定で決定することができる. ここで, 隠れマルコフモデルのパラメータ集合  $\{\pi, \varphi\}$  をすべて  $\theta$  で代表させている. 同時分布の式 (3.17) を潜在変数について周辺化することで尤度関数が得られる.

$$p(X | \theta) = \sum_Z p(X, Z | \theta, \pi) \quad (3.18)$$

いま観測数が  $N$ , 潜在状態数を  $K$  としているため, 上式右辺において和をとる潜在状態は全部で  $K^N$  個存在する. そのため, 隠れマルコフモデルの尤度関数を最大化する効率的な枠組みとして EM アルゴリズムによるパラメータの推定を行うこととなる.

EM アルゴリズムではまず, モデルパラメータをある初期値  $\theta^{old}$  に設定する. 初期値の設定には, 時系列性を排除したうえで別途クラスタリングや最尤法を実施した時に得られた値を用いるなどの方法がある.

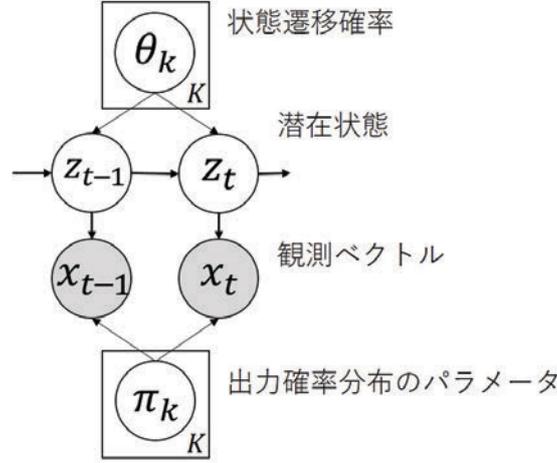


図 3.4. 隠れマルコフモデル

初期値  $\theta^{old}$  を用いて、まずは E ステップによる完全データに対する尤度関数の対数の期待値を求めていく。この期待値は以下の関数  $Q(\theta, \theta^{old})$  で定義される。

$$Q(\theta, \theta^{old}) = \sum_Z p(Z|X, \theta^{old}) \ln p(X, Z|\theta) \quad (3.19)$$

なお、潜在変数の周辺事後分布  $\gamma(z_n)$  および 2 つの連続した潜在変数に対する同時事後分布  $\xi(z_{n-1}, z_n)$  を以下のように定義することで、関数  $Q(\theta, \theta^{old})$  について下記の形式を得る。

$$Q(\theta, \theta^{old}) = \sum_{k=1}^K \gamma(z_{1k}) \ln \pi_{0k} + \sum_{n=2}^N \sum_{j=1}^K \sum_{k=1}^K \xi(z_{n-1,j}, z_{nk}) \ln \pi_{jk} + \sum_{n=1}^N \sum_{k=1}^K \gamma(z_{nk}) \ln p(x_n|\theta_k) \quad (3.20)$$

なお、 $\gamma(z_n)$  と  $\xi(z_{n-1}, z_n)$  の値はフォワード・バックワードアルゴリズムによって効率的に求めることができる。

次に M ステップにおいて関数  $Q(\theta, \theta^{old})$  の最大化を行う。 $\gamma(z_n)$  と  $\xi(z_{n-1}, z_n)$  を定数とみなし、ラグランジュ未定乗数法を用いて関数  $Q$  を最大化する解  $\theta^{new}$  を求める。 $\theta^{old} \leftarrow \theta^{new}$  とし、以上の手順を解が収束するまで繰り返す。

### 潜在状態の推定

モデルパラメータが既知である場合、隠れマルコフモデルの潜在状態の値を求めるためには Viterbi アルゴリズムを用いることにより効率的に潜在状態列を解くことができる。Viterbi アルゴリズムでは、同時分布の式 (3.17) において対数を取って最大化と和の演算を交換することにより以下を得る。

$$\begin{aligned} \ln p(X, Z) &= \ln p(z_1) + \sum \ln p(z_t|z_{t-1}) + \sum \ln p(x_t|z_t) \\ &= [\ln p(z_1) + \ln p(x_1|z_1)] + \ln p(z_2|z_1) + \ln p(x_2|z_2) + \dots \end{aligned} \quad (3.21)$$

ここで、メッセージ  $w(z_t)$  を以下の通り定義する。

$$w(z_t) = \max_{z_1, \dots, z_{t-1}} \ln p(X, Z_{1:t-1}) \quad (3.22)$$

すると、同時分布  $p(X, Z)$  を最大化する潜在状態  $Z$  は、以下に示すメッセージ  $w(z_t)$  の再帰式によって効率的に推定することができる。

$$w(z_{t+1}) = \ln p(x_{t+1}|z_{t+1}) + \max_{z_t} [\ln p(z_{t+1}|z_t) + w(z_t)] \quad (3.23)$$

なお、この再帰式の初期値は下式で得られる。

$$w(z_1) = \ln p(z_1) + \ln p(x_1|z_1) \quad (3.24)$$

潜在状態列を求めるには、 $z_{t+1}$  の  $K$  個の各々の値に対する最大化に対応する  $z_t$  の値を記録しつつ、メッセージ  $w(z_t)$  の伝搬を行う。一旦最後の観測値まで計算が終了すれば、 $z_T$  から逆順に最も確からしい状態が得られる。

### 3.3.2 隠れマルコフモデルの適用結果

最もシンプルな隠れマルコフモデルを用いて人口動態の潜在的状態推定問題に適用することを考える。隠れマルコフモデルを適用するにあたり潜在状態数  $K$  の値と、モデルパラメータの初期値が必要となる。人口動態に関する適切な潜在状態数は不明だが、今回の検証では十分であると考えられる  $K = 10$  を暫定的に使用することとする。また、以下の k-means 法によるクラスタリングを実施し、その結果を隠れマルコフモデル学習における初期値とする。

#### 使用したデータ

観測データとして混雑統計データを利用した。2012 年 10 月 30 日の 500m メッシュ人口の 1 時間ごとの平均値で、対象範囲は東京 23 区を含む計 2619 メッシュである。

$y_1^1, \dots, y_t^i, \dots, y_T^N$  を全メッシュ人口データとする。ここで添字  $i \in \{1, \dots, N\}$  はメッシュ番号、 $t \in \{1, \dots, T\}$  は時刻を示し、 $N = 2607$ 、 $T = 24$  である。モデルへの適用に当たり、メッシュ毎に平均 0、分散 1 になるように正規化したデータ  $y_t^i$  を用いた。具体的には、メッシュ毎に算出した平均値  $\mu_i$ ・分散  $\sigma_i$  を用いて、 $y_t^i = (y_t^i - \mu_i)/\sigma_i$  による計算を施した正規化方法である。隠れマルコフモデルの時刻  $t$  の観測ベクトル  $x_t^i$  は  $\{y_t^i, y_{t-1}^i\}$  を設定する。時刻  $t$  における正規化メッシュ人口値と、時刻  $t-1$  における正規化メッシュ人口値を一つの観測ベクトルとして利用することで、単なるメッシュ人口値の多寡だけでなく、メッシュの増減の様子などを推定したい潜在状態に組み込むことが可能になると考える。この設定に伴い、隠れマルコフモデルの出力分布には 2 次元正規分布を設定する。

#### クラスタリングによる初期値の決定

隠れマルコフモデルの学習時の初期値決定のために k-means 法によるクラスタリングを実施した。このクラスタリング結果から隠れマルコフモデル学習における初期値を決定する。初期分布  $\pi_0$  にはクラスタに割り当てられたデータ個数の割合を用いる。状態遷移確率  $\pi$  には、 $x_{t-1}^i$  に割り当てられたクラスタから  $x_t^i$  に割り当てられたクラスタへの遷移の回数を数え上げることによって計算する。

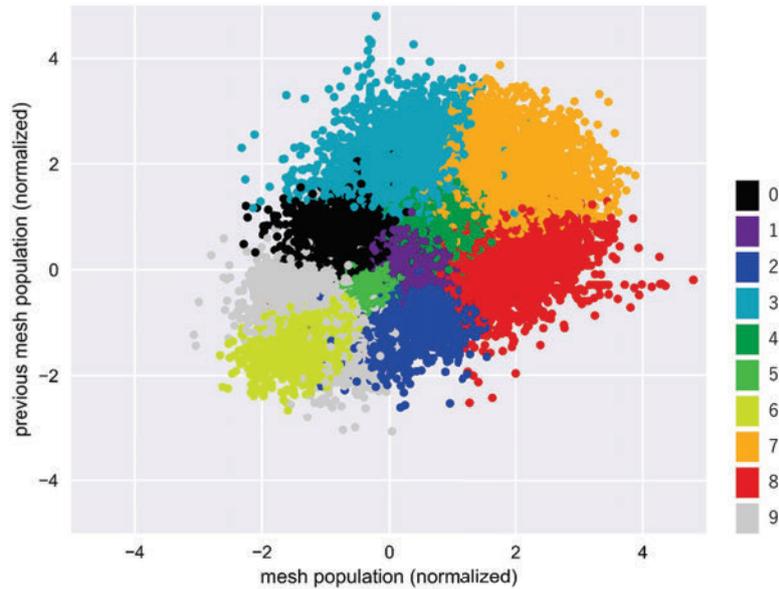


図 3.5. 潜在状態の推定結果

各時刻・各メッシュにおける潜在状態の推定結果について、観測ベクトルとの比較。横軸が時刻  $t$  における正規化メッシュ人口値  $y'_t$ ，縦軸が時刻  $t-1$  における正規化メッシュ人口値  $y'_{t-1}$  である。

#### 隠れマルコフモデルによる潜在状態の推定結果

2012年10月30日のデータを用いて隠れマルコフモデルのパラメータ学習および潜在状態の推定を行った。図 3.5 に潜在状態の推定結果を示す。横軸が時刻  $t$  における正規化メッシュ人口値  $y'_t$ ，縦軸が時刻  $t-1$  における正規化メッシュ人口値  $y'_{t-1}$  であり、各データ点の色がそのデータが属するクラスタに対応する。

ただしこの状態推定結果からは各潜在状態が具体的にどのような状態であるのかは分からない。そこで図 3.5 における観測ベクトルと潜在状態の対応を確認し、潜在状態の解釈を行う。例えば潜在状態 0(黒色)では、 $y_{t-1}$  は 0 ~ 1 の値を取っている一方で、 $y_t$  は -2 ~ 0 の値を取っている。すなわち、1 時刻前に比べ人口値が減少し、かつその時刻における人口値は 1 日の中でも少ない状態であるということである。同様に他の潜在状態の解釈を行った結果を図 3.6 に示す。現時刻での人口値がそのメッシュにおいて少ない、平常、多いの 3 通りと、1 時刻前の人口値と比較して減少、同程度、増加しているかの 3 通りの組み合わせで計 9 通りの状態を仮定した。各セルに表示されている数字がその状態に対応する、これまでの状態番号である。ただし「人口値多・減少」および「人口値少・増加」に該当する潜在状態は得られなかった。今後は各セルの背景色を潜在状態の可視化に利用することとする。

新たな凡例色のもとで、推定した潜在状態を対応付けた結果を図 3.7 に示す。横軸が時刻 0 時~23 時台、縦軸が対象 2619 メッシュをメッシュ番号昇順で並べたものであり、各時刻・各メッシュの潜在状態の推定結果を図 3.6 に定義する配色にて表している。推定結果を確認する

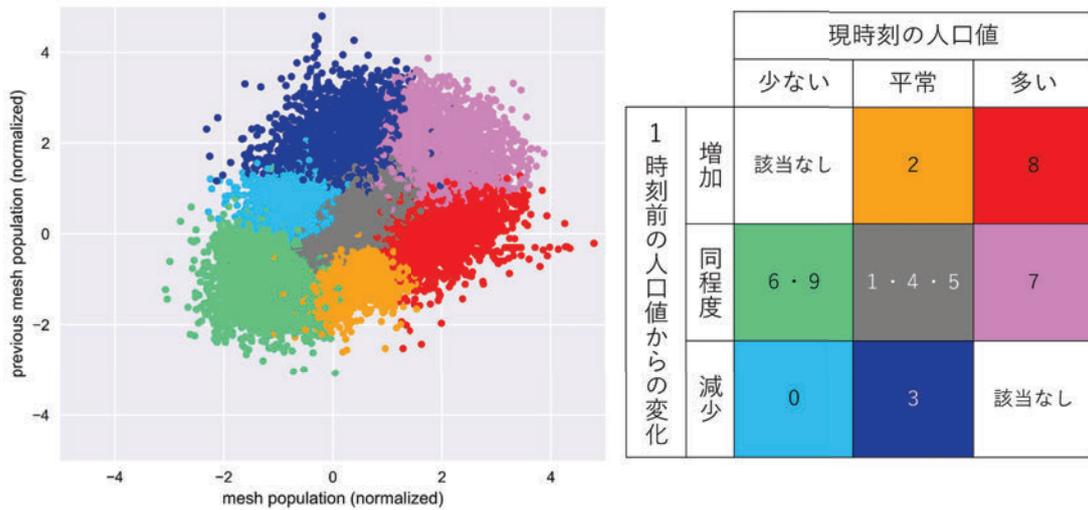


図 3.6. 潜在状態の解釈と各潜在状態に対応する色の定義

と、深夜の時間帯 (22 時～5 時台) では人口値が少なく変化 も少ない状態 (緑色) が多く推定されていることが分かる。朝ラッシュの時間帯 (6 時～7 時台) では人口値が徐々に増加し、かつ人口値が多い様子が潜在状態 (黄色, 赤色) にも現れていることが確認できた。朝ラッシュの時間帯の終盤 (8 時～9 時台) では、人口値は多いが増減に変化がない状態 (桃色) や、人口値が通常通りに戻る方向に減少する状態 (青色) が散見された。日中の時間帯 (10 時～16 時台) ではメッシュ毎に潜在状態も大きく変動しており、対象エリア全土を通じて共通したパターンは見られなかった。そして夕方のラッシュ以降 (17 時～21 時台) では、朝ラッシュほどではないものの、人口の増加状態から減少状態へと遷移する様子が確認できた。

最後に、午前 4 時台から午後 7 時台までの 3 時間毎について、推定された潜在状態を GIS 上に可視化した結果を図 3.8 に示す。午前 4 時台以外の時間帯について、東京 23 区の中央エリアと周辺部分で潜在状態が異なる傾向にあることが分かる。この境界は山手線、錦糸町および大井町周辺であり、23 区内でも日中に人が集中しやすいエリアであることが確認できる。

考察

本検証で実施したように、隠れマルコフモデルを用いて人口動態をモデリングすることで、各メッシュで潜在状態の変遷を確認することが可能となった。ただし単純な隠れマルコフモデルでは以下に挙げる課題がある。まず、隠れマルコフモデルのモデリングや潜在状態の視覚化のために状態数をあらかじめ設定する必要がある。本検証では状態数として  $K = 10$  を採用してモデリングを行ったが、メッシュ人口データの正常な状態数は未知または無限に存在するとも考えられる。

また、推定された潜在状態の解釈が困難であることも課題として挙げられる。本検証ではモデリングのために事前に設定した状態  $k = 1, \dots, 10$  の解釈を行うため、メッシュ人口  $(y'_{t-1}, y'_t)$  に関するデータ散布図から各潜在状態の対応付けを行った。情報量の多いデータへの適用を考

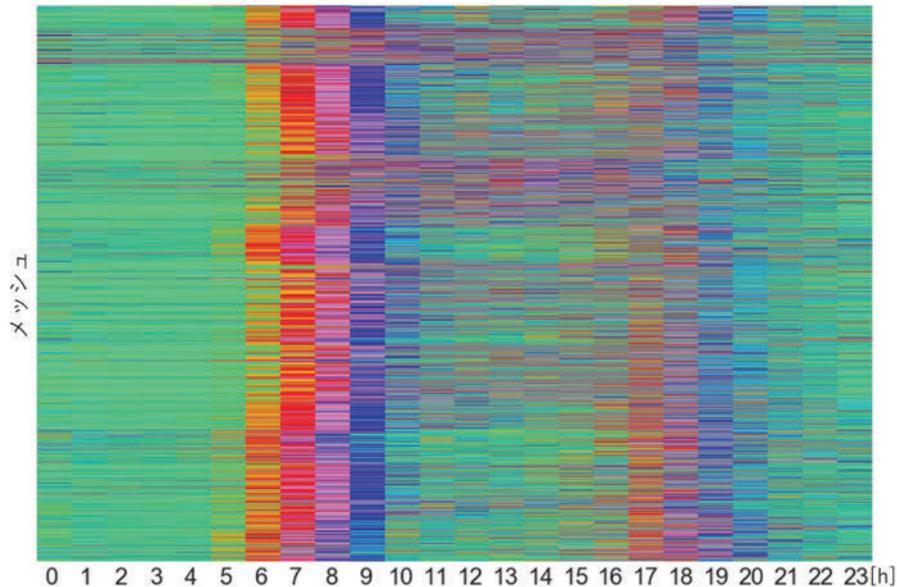


図 3.7. メッシュ別・時刻別の潜在状態の推定結果

横軸が0時～23時台，縦軸が対象2619メッシュをメッシュ番号を昇順に並べたもの。各セルの色によって各時刻・各メッシュの潜在状態の推定結果を図3.6に定義する配色にて表している。

えると，この解釈方法は必ずしも有効ではない。また，ある観測ベクトルが有する潜在状態はただ一つとの仮定を暗に置いていた。しかしクラスタ境界に位置するデータはその双方の潜在状態の解釈が可能になるなど，潜在状態をただ一つに確定させることへの制限も大きい。

### 3.4 変化検出に向けた課題の抽出とモデル拡張方針

これまでの検証により，潜在状態数の事前設定および推定された潜在状態の解釈方法が課題であることが分かった。本論文ではこれらの課題に対し，階層ベイズ法の導入による状態数の自動推定機構の構築，およびトピックモデルの導入による潜在的意味解釈アプローチの構築を行う。

人口動態の潜在状態数を求めるためには多くの学習用のデータを用意し，状態数自体をデータから推定・学習する機構を設ける必要がある。ただし学習用データ量に関わらず，検証用のデータに新たな潜在状態が含まれている場合はモデリングが正しく機能しない場合が考えられる。特にこれは変化検出の問題へと適用する際に問題となる。変化検出では一般に，大量のデータから通常値の潜在状態の学習を行い，変化が含まれると考えられる検証用データへと適用する。ゆえに学習用データと検証用データではデータ生成機構が異なるため，学習したモデルによる適用がうまく働かない可能性がある。従って，学習データから適切な潜在状態数を推定するとともに，検証データへ適用した際にも未知の潜在状態へ対応可能な柔軟なモデル構築が求められる。

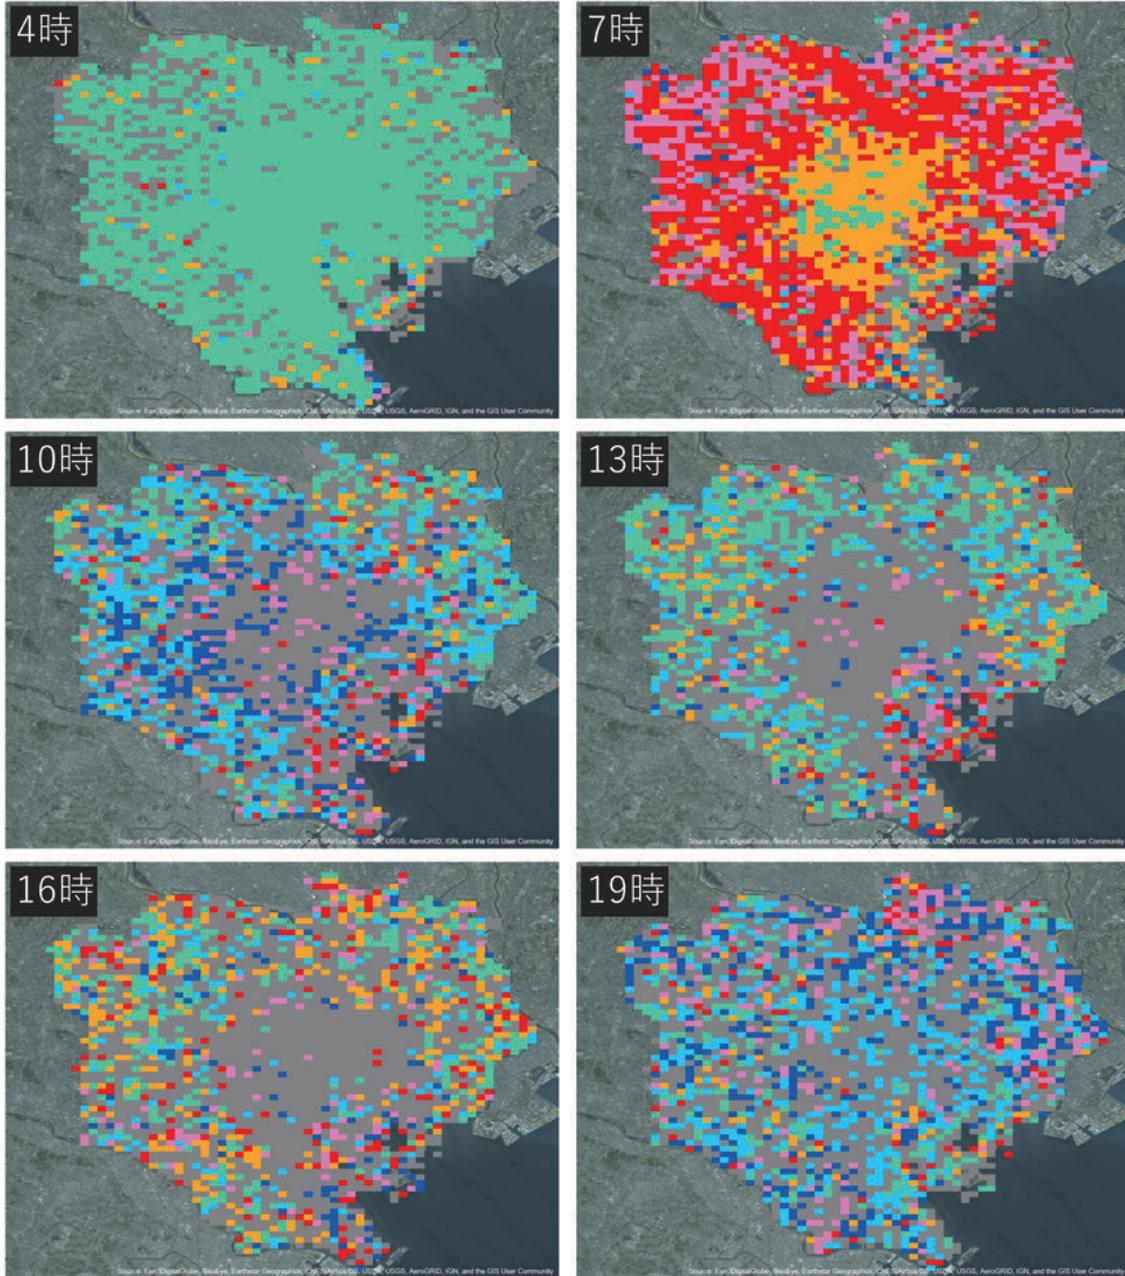


図 3.8. 推定された潜在状態の GIS 可視化結果

この課題を克服するために、階層ベイズ法の導入による潜在状態数の自動推定機構を構築する。階層ベイズ法とは、詳しくは後述するが、観測ベクトルを生成する潜在状態が、また別の潜在状態から生成されていると階層的に考えるモデルである。その中でもノンパラメトリックベイズモデルの一つである階層ディリクレ過程に基づく隠れマルコフモデルは、時系列データの潜在状態数をデータに応じて自動的に推定することが可能である。従って、状態数が未知である人口動態へのモデリングに適していると考えられる。第 4 章では本手法を用いた時空間モデリングを行い、潜在状態の推定を通じた変化検出問題への適用を考える。

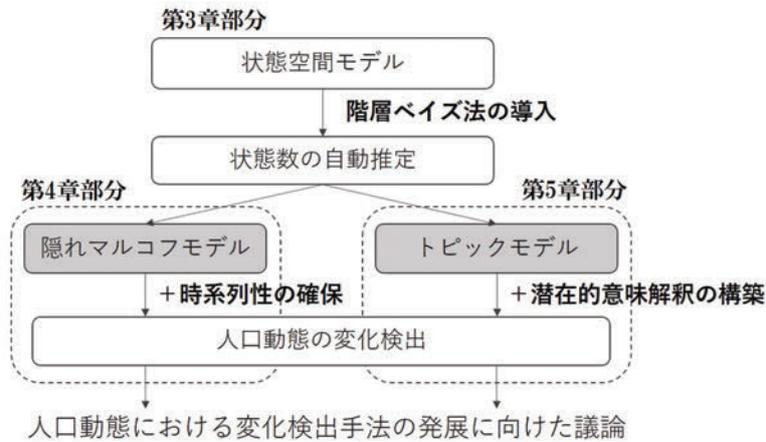


図 3.9. 変化検出に向けたモデルの拡張方針

一方，潜在状態の解釈が困難であった理由として，推定された潜在状態とデータ散布図との対応をとるなど学習機構以外での処理が必要であった．これは，潜在状態ごとに推計される出力分布パラメータ  $\{\varphi_k\}_{k=1}^K$  から潜在状態の特徴を解釈しているとみなすことができる．しかしより多次元の観測ベクトルを設定した場合にはこのアプローチ方法での状態解釈は難しい．また，このアプローチでは潜在状態に一つの値しか取れないため，複数の潜在状態を保有することを許す表現力の高いモデリングへの拡張が望まれる．さらに，流通しているメッシュ人口データには人口値以外の情報も含まれていることも多い．例えばモバイル空間統計では男女・年代別人口や居住地情報が含まれており，混雑統計データには自宅・勤務・流動（移動）別の人口情報が付加されている．これらの情報を使うことで潜在状態をより解釈可能な形で推定することが可能だと考えられる．

そこで，潜在状態をより解釈可能な形で推定するために，トピックモデルに基づく潜在的意味解釈を実施する．トピックモデルとは特に自然言語処理の分野にて頻繁に使われてきた手法である．自然言語における単語をモデルの出力と設定し，単語の集合である文書ごとにモデリングを行うことでその文書が持つトピックを潜在状態として推定することができる．この潜在状態は複数のトピックの分布で表現されており，一つ一つのトピックが，どの単語を出力しやすいかという単語分布を有しているため，トピックを分析することで文書が持つパターンの意味解釈を行うことが可能となる．なお，トピックモデルにおいても上述の潜在状態数の事前設定が問題となるため，同じく階層ベイズ法を導入する．第5章にて本手法をメッシュ人口データに適用し，推定された潜在状態の意味解釈を行う．さらに，トピックモデルを利用した変化検出手法の適用可能性の検証を行う．第4章にて構築した隠れマルコフモデルによる変化検出手法との比較を行い，人口動態の変化検出手法のさらなる発展に向けた課題を洗い出し，議論する．

図 3.9 にモデル拡張方針の概念図を示す．この二つの方針のもとで拡張したモデルに基づく変化検出を実施し，構築したモデルの適用可能性を検証することとする．

## 第 4 章

# 隠れマルコフモデルによる人口動態 の変化検出

### 4.1 メッシュ人口データに対する変化検出問題の設定

前章の議論に基づき、隠れマルコフモデルによる人口動態の潜在状態の推定、および変化検出問題への適用を行う。まず本論文で考える変化検出問題の特徴について整理・概説する。さらに、本論文で取り扱う変化の定義を行い、隠れマルコフモデルを用いた変化検出手法の構築に向けた議論を行う。

#### 4.1.1 変化検出問題の整理

変化検出とは、大概のデータが従うパターンを統計モデルにより学習し、そこからある程度の尺度を以って外れたデータを検知する問題である [45][90][91][92]。近年では、データ計測手法や計算機処理能力の発展により、変化検出はネットワーク侵入検知や画像処理、構造物ヘルスマonitoring等の多彩な分野で盛んに研究が行われている。

なお、変化検出という他に、異常検知や外れ値検出という表現もされることが多いが、明確な定義の違いはなく、扱われている手法についても共通したものが多い。ただし検出対象である変化や異常の考え方に若干の違いがあるため、以下で変化の種類やデータの性質などを整理するとともに、本論文で対象とするメッシュ人口データに対する変化検出問題の特徴を議論する。

#### 変化や異常の種類

統計的機械学習に基づく変化検出・異常検知問題が対象とする変化・異常は、外れ値、変化点、異常部位の 3 種類に分類される [93]。外れ値とは、ほかのデータとの値が相対的に外れているようなデータのことを指し、それ単独で異常なデータのことである。時系列性や空間的な関係を考慮した上で、文脈型の異常として扱うことも多い。いずれにせよ、簡単な差分処理や外れ度合いなどの指標によって検出することが可能な、最も検出が簡単な異常であるとも言え

る [90]. 人口動態データの場合, 例えばある小さな対象範囲区に数万人もの人口が集中している場合であり, 非常事態における人口の集中や入手データの不備などに相当する. 変化点とは, データ単体の値がずれているというよりは, 観測値の振る舞いに変化したタイプの異常である. そのため, データの振る舞いを表現するモデルを仮定した上でそれを学習し, 振る舞いに変化した度合いを計測することとなる. 具体例としては, ある地域における1日の人口動態の振る舞いが異なる場合であり, イベントによる集客や新規交通手段の普及による人口動態の振る舞いの変化などに相当する. そして異常部位とは異常な振る舞いをするデータ集合と解釈される. データ1点1点は外れ値もしくは変化点とはなりえないが, 複数のデータ群が連続したり同時に起きたりした場合の異常である. 例えば, 複数のエリアに普段よりも多くの人が集まる場合や, 普段は共に多くの人が集まるはずの複数の地域の一部にしか人が集まっていない場合である. 変化点と同様にイベントによる集客へや人口動態の振る舞いの変化に起因する異常だが, 複数エリアをまとめて一つの異常状態か否かを考えるものである.

ただし, これらの分類に基づく3種類の異常は完全に独立したものではなく, あるタイプの異常を検出する手法を用いて他のタイプの異常を検出することも可能である. 例えば, 外れ値はただ1点で構成されている変化点とも見ることができ, 逆に変化点検出の場合も, データの振る舞いを記述するパラメータに着目した外れ値検出と考えることができる. そのため, 後述するように, 扱うデータの種類や入手可能な学習データの質に応じて, どのようなタイプの異常と位置づけ, 手法を構築していくかが重要である.

本研究の場合, 任意の空間単位での変化検出を行う. 対象とする変化は, 事故・災害による交通渋滞の影響で生じた人口増加・減少や, 交通需要の変化等から生じるメッシュ人口値の推移パターンの変動等, 時系列中の変化点として考えることができる. 図4.1はそれらを模式的に表したものである. なお, 本研究では変化の事後的検出を主目的とする. この適用事例として, 短期的な視点では開催されたイベントがもたらした人口動態へのインパクトの評価, 長期的な視点では交通インフラの新設による人口動態の変化が挙げられる. この問題意識の下では, 単なる人口値の増減による評価ではなく, 潜在的な人口動態の状態変化をもとに評価を行うこととなる. そのため, 見かけ上は人口値に変化が無かったとしても, その背後に潜む人の移動に関する構造や要因の変化そのものを検出できる手法へと発展できると考える.

### データの性質

変化検出・異常検知問題の特徴付ける要因のひとつに入力データの性質が挙げられる. データの性質は二値, 離散値, 連続値に大別される他, 時系列データや空間データ, ネットワークデータなど入力データ間の関係性も重要な要因となる. 本論文では任意の空間(メッシュ)単位での潜在状態の推定を考えている. そのため出力される異常についても, 潜在状態の推定を行う空間(メッシュ)単位で考えたい. そこで, メッシュ人口データ中のメッシュ単位で変化検出問題を考えることとし, 入力データはメッシュ人口値がなす時系列データであると考え.

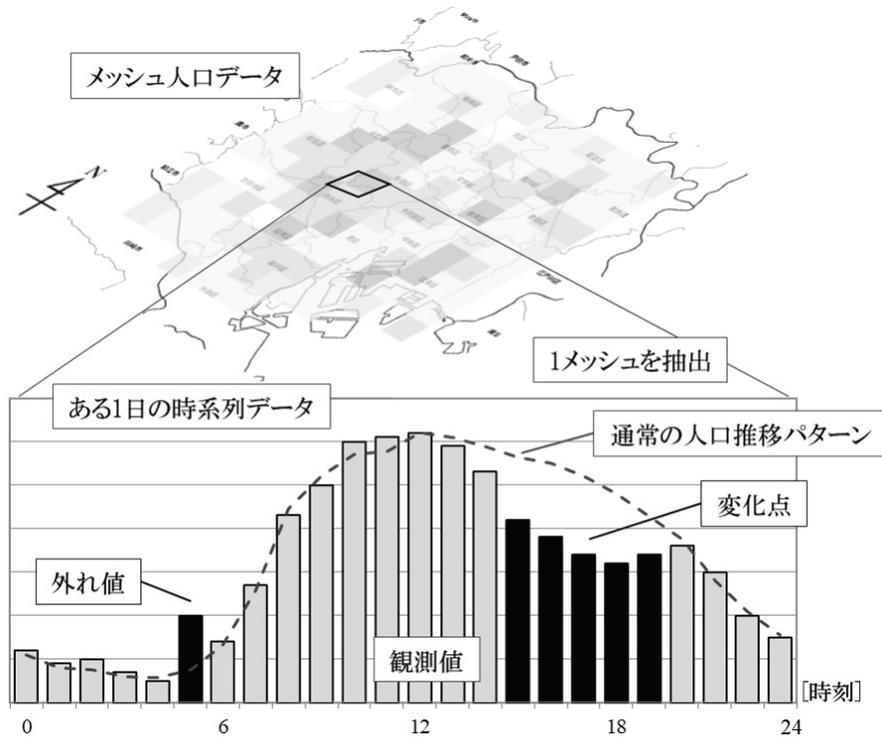


図 4.1. メッシュ人口データに含まれる変化・異常の例

### 変化検出の出力方法

変化検出の出力方法には、各データに変化スコアや異常スコアを算出する方法と、「異常」か「正常」かを表すラベルを付加する方法がある。メッシュ毎に変化スコアが算出されれば、交通管制対象の優先度の指標になり得る点で有用である。同時に、どのような状態かを示すラベル作成ができれば、その有用性は同様に高いと考えられる。従って、変化スコア及びラベルの両方が適用可能であると考えられる。

### 学習時のラベル

第三の要因は、統計モデルを学習する際の学習データに含まれる「変化」「非変化」ラベルの事前情報の有無である。学習データにどこまで教師ラベルが含まれているかによって、教師付き変化検出、半教師付き変化検出、教師無し変化検出の3手法に分類される。正常な教師データの取得は、大規模な事故や自然災害が発生していない日時・地点の観測データを用いることである程度可能である。一方変化を含む教師データの十分数の確保は現実的に不可能である。そのため、本研究では日常的なデータのみを用いた半教師付き変化検出が望まれる。

### 4.1.2 状態空間モデルによる変化検出

以上の整理結果に基づき、本研究では、メッシュ人口データに対する変化検出問題を、教師データにより半教師付き学習した統計モデルにより時系列データ中の変化点を検出する問題として設定する。なお、変化検出の出力方法はラベルと変化スコアのどちらも考えられるため、2種類の変化検出手法を提案することとする。この問題設定では、状態空間モデルを使用した変化検出手法が適用可能である。状態空間モデルは複雑に時系列変化するデータのモデリングが可能となるため、時系列データの変化検出に状態空間モデルが用いられることが多い [91]。

状態空間モデルを利用した変化検出手法は主に 2 種類存在する。一つは、変化や異常は観測値と予測値との乖離度であると仮定するもので、カルマンフィルタやパーティクルフィルタにより尤度や出力確率を計算することで検出する。もう一つは、変化や異常は潜在状態に表れると仮定するもので、隠れマルコフモデルなどにより潜在状態を推定する手法がとられる。

これまでの議論の通り、前者の手法を本研究へ適用する場合、変化検出のためのモデル構築が課題である。人口動態の予測やシミュレーションに関する研究は限定的であり、いかなるシステムモデルおよび観測モデルを扱えばよいかは不明である。一方で後者の手法では、隠れマルコフモデルの潜在状態数を事前に設定する必要がある。適切な潜在状態数の決定が常に大きな課題となるが、残念ながらメッシュ人口データが取りうる適切な状態数は未知である。そこで、階層ベイズ法の導入による潜在状態数の自動推定機構を構築する。

## 4.2 ノンパラメトリックベイズモデル

複雑なデータのモデリング、または様々な状態量のクラスタリングには混合分布が用いられる事が多く、観測されたデータのクラスタ・潜在状態の推論には、例えば尤度最大化基準に従い EM アルゴリズムが用いられ、ベイズ的に事後確率が算出されたりする。しかし、いずれの手法を用いるにしろ、事前にクラスタ数を決めておく、すなわち事前のモデル選択の問題が存在する。最適なクラスタ数を決定する手段として、赤池情報量基準 (Akaike's Information Criterion; AIC) やベイズ情報量規準 (Bayesian Information Criterion; BIC) 等の適用が考えられる。しかし、予め候補となり得るクラスタ数を全て実行しなければいけないため、オフライン処理でかつ計算量が膨大となる。これに対し、ノンパラメトリックベイズモデルではクラスタ構造をモデル化し、クラスタリングを実行する過程で最適なクラスタ数が自動決定される。

本節ではノンパラメトリックベイズモデルの一つである階層ディリクレ過程に基づく隠れマルコフモデルを導入する。このモデルは時系列データの潜在状態数を推定することができるため、メッシュ人口データに対する変化検出手法に適用することが可能となると考えられる。特に本研究では、連続的に状態が遷移するようなデータの効率的なモデリングが可能であるスティッキー階層ディリクレ過程隠れマルコフモデル (sticky Hierarchical Dirichlet Process - Hidden Markov Model ; sHDP-HMM) [94] を援用する。まずディリクレ過程について概説

した後、本研究で用いる sHDP-HMM を説明する。

### 4.2.1 ディリクレ過程

ディリクレ過程 (Dirichlet process; DP) [95] は「分布に対する分布」と呼ばれており、パラメータ空間  $\Theta$  上の基底測度  $H$  と集中パラメータ  $\alpha > 0$  によって一意に定義される。ここでは、 $DP(\alpha, H)$  と記す。端的には、基底測度  $H$  を、それに似た無限次元の離散分布によって近似した分布  $G_0$  を生成する確率過程であると換言でき [96]、 $G_0 \sim DP(\alpha, H)$  と記述される。また、 $G_0$  は具体的には以下のように立式できる。

$$G_0 = \sum_{k=1}^{\infty} \pi_k \delta(\varphi_k) \quad (4.1)$$

$$\varphi_k \sim H$$

ここで、 $\delta(\cdot)$  はディラックデルタである。なお、 $\delta(\varphi_k)$  は  $\varphi_k$  上のアトムと呼ばれ、パラメータ空間  $\Theta$  から抽出したパラメータ  $\varphi_k$  に対応する離散分布である。

また、重み  $\pi_k$  は以下の棒折り過程 (GEM) と呼ばれる確率過程から生成される。

$$\nu_k \sim \text{Beta}(1, \alpha)$$

$$\pi_k = \nu_k \prod_{l=1}^{k-1} (1 - \nu_l) \quad (4.2)$$

ここで、これらの重みをまとめて  $\boldsymbol{\pi} = \{\pi_1, \pi_2, \dots, \pi_{\infty}\}^T$  と記す。なお、 $T$  は転置である。棒折り過程ではベータ分布  $\text{Beta}(1, \alpha)$  から抽出した  $\nu_k$  分だけ、確率の総和である長さ 1 の棒を無限に切っていく、無限次元ベクトル  $\boldsymbol{\pi}$  を生成する。棒折り過程は無限次元の多項分布を生成する確率過程であり、 $\boldsymbol{\pi} \sim \text{GEM}(\alpha)$  と記される。集中パラメータ  $\alpha$  が大きいと多項分布  $\boldsymbol{\pi}$  の始めの項に重みが平均的に集中するため、基底測度  $H$  をより少ない離散分布  $\delta(\varphi_k)$  で近似することになる。

ディリクレ過程を混合分布モデルの事前分布として用いたものをディリクレ過程混合モデルと呼ぶ。そのグラフィカルモデルは図 4.2(b) に示す通りである。ここで、 $i$  番目の出力を  $\mathbf{x}_i$ 、出力分布パラメータを紐付けるインデックスを  $z_i$ 、データサイズを  $N$  とする。このモデルでは、棒折り過程  $\text{GEM}(\alpha)$  より構成された多項分布  $\boldsymbol{\pi}$  からインデックス  $z_i$  が生成され、そのインデックス  $k = z_i$  に対応するパラメータ  $\varphi_k$  が割り当てられる。その後、 $\varphi_k$  によって定義された出力分布  $F$  によって観測値  $\mathbf{x}_i$  が出力される。具体的には、以下のように立式される。

$$\boldsymbol{\pi} \sim \text{GEM}(\alpha) \quad (4.3)$$

$$\varphi_k | H \sim H \quad (4.4)$$

$$z_i | \boldsymbol{\pi} \sim \text{Multi}(\boldsymbol{\pi}) \quad (4.5)$$

$$\mathbf{x}_i | z_i, \varphi_{1:\infty} \sim F(\mathbf{x} | \varphi_{z_i}) \quad (4.6)$$

ここで、 $\varphi_{1:\infty} = \{\varphi_1, \dots, \varphi_{\infty}\}$  であり、Multi は多項分布を表す。なお、このモデルではパラメータ空間から抽出されるアトム  $\delta(\varphi_k)$  が出力毎に異なるため、潜在状態  $z_i$  は統一されていない。

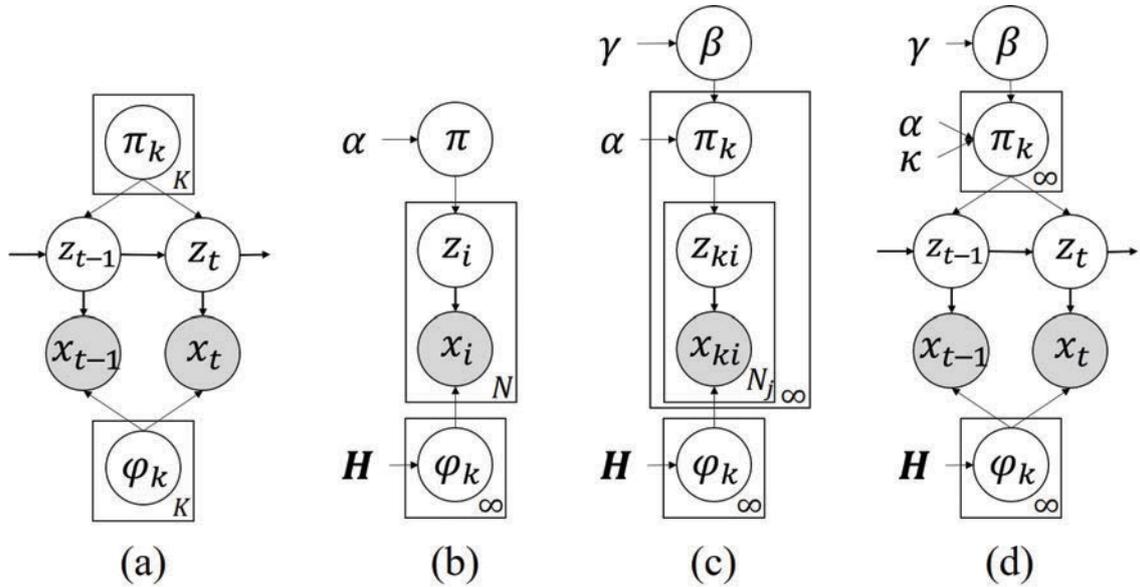


図 4.2. 各種グラフィカルモデル  
 (a) 隠れマルコフモデル (再掲), (b) ディリクレ過程混合モデル, (c) 階層ディリクレ過程, (d) スティック階層ディリクレ過程隠れマルコフモデル.

### 4.2.2 階層ディリクレ過程

階層ディリクレ過程 (Hierarchical Dirichlet Process; HDP) [97] では、ディリクレ過程を別のディリクレ過程の事前分布として設定することでアトムを共有して潜在状態の統一化を図る。まず、1 層目のディリクレ過程  $DP(\gamma, H)$  によりグローバルな確率測度  $G_0$  を生成する。さらに  $G_0$  が 2 層目のディリクレ過程  $DP(\alpha, G_0)$  の基底測度となり、ローカルな確率測度  $G_j$  が生成される。ここで、グローバルな確率測度  $G_0$  は、ローカルな確率測度  $G_j$  の平均的な分布と解釈される。ディリクレ過程の特徴により  $G_0$  は離散分布になるため、 $G_j$  はインデックス  $j$  が異なっても同様のアトム  $\delta(\varphi_k)$  を共有することになる。これにより、異なる混合分布間で同一の潜在状態集合および出力分布パラメータ集合を共有することができる。

図 4.2(c) に階層ディリクレ過程のグラフィカルモデルを示す。ここでは、棒折り過程  $GEM(\gamma)$  よりグローバルな無限次元多項分布  $\beta$  が生成され、次にローカルな無限次元多項分布  $\pi_j$  が  $DP(\alpha, \beta)$  から生成される。そして、潜在状態  $z_{ji}$  と観測値  $x_{ji}$  が DP と同様の機構で出力される。

### 4.2.3 階層ディリクレ過程隠れマルコフモデル

階層ディリクレ過程を隠れマルコフモデルに拡張したものが、階層ディリクレ過程隠れマルコフモデル (Hierarchical Dirichlet Process - Hidden Markov Model; HDP-HMM) [97] で

ある。HDP-HMM では、 $z_t$  は時刻  $t$  における潜在状態、 $\pi_j$  は状態  $j$  に対する遷移確率として働き、そして  $\beta$  はグローバルな遷移確率と呼ばれる。階層ディリクレ過程では確率測度  $G_j$  が同一の原子  $\delta(\varphi_k)$  を共有するため、各遷移確率  $\pi_j$  は同一の可算無限個の潜在状態集合を共有することとなる。換言すれば、HDP-HMM における  $\pi$  は加算無限個の行、列を持つ遷移行列として見なすことができる。計算上は全ての状態が用いられるわけではないため、観測データに応じて潜在状態数を決定することのできるモデルであると解釈可能である。この特性により、状態数が未知である場合のクラスタリング問題や変化検出問題に多く適用されている [98][99]。

HDP-HMM の課題として潜在状態がかなり頻繁に切り替わるようなモデルを学習してしまい、モデルの学習精度の低下を引き起こすことが挙げられる。この問題に対し Fox ら [94] は自己遷移確率を制御するハイパーパラメータ  $\kappa \geq 0$  を新たに導入したスティッキー階層ディリクレ過程隠れマルコフモデル (sticky Hierarchical Dirichlet Process - Hidden Markov Model; sHDP-HMM) を開発した。 $\kappa$  の値が大きいくほど自己遷移確率が大きくなり、 $\kappa = 0$  の時は通常の HDP-HMM と一致する。sHDP-HMM によるデータ生成機構は次式で与えられ、グラフィカルモデルを図 4.2(d) に示す。

$$\beta | \gamma \sim \text{GEM}(\gamma) \quad (4.7)$$

$$\varphi_k | H \sim H \quad (4.8)$$

$$\pi_j | \alpha, \beta, \kappa \sim \text{DP} \left( \alpha + \kappa, \frac{\alpha \beta + \kappa \delta_j}{\alpha + \kappa} \right) \quad (4.9)$$

$$z_t | z_{t-1}, \pi_{1:\infty} \sim \pi_{1:\infty} \quad (4.10)$$

$$\mathbf{x}_t | z_t, \varphi_{1:\infty} \sim F(\mathbf{x}_t | \varphi_{z_t}) \quad (4.11)$$

ここで、 $\pi_{1:\infty} = \{\pi_1, \dots, \pi_\infty\}$  である。

メッシュ人口データに潜む潜在状態は時間とともに徐々に遷移していくことが予想されるため、適切な自己遷移確率を持ったモデルを作成することが必要である。sHDP-HMM を利用することで、メッシュ人口データの状態変化特性を適切に把握した上で、観測データに応じて適切な潜在状態数を推定できると考えられる。

#### 4.2.4 ブロック化ギブスサンプリングによるパラメータ推定

sHDP-HMM は複雑に潜在変数が構築されているため、最尤法や EM アルゴリズムによる事後分布の推定は不可能である。そのため、潜在状態を含む sHDP-HMM の全変数の事後分布の推定には、ブロック化ギブスサンプリングを使用する。ギブスサンプリング [100] は直接サンプリングが難しい確率分布を近似するサンプル列を生成するマルコフ連鎖モンテカルロ法の一つである。特に、ブロック化ギブスサンプリングは隠れマルコフモデルのように変数間に強い相関が存在する場合に特に有効である。本研究では、Fox[101] によって整理されている sHDP-HMM のサンプリング方法に従うこととする。なお、sHDP-HMM にブロック化ギ

ブスサンプリングを適用する場合は、理論上は加算無限個存在する潜在状態を、ある十分な有限個  $L$  によって近似する必要がある。この時、棒折り過程  $\text{GEM}(\alpha)$ (式 (4.2)) は以下の  $L$  次ディリクレ分布と見なすことができる。

$$\text{GEM}_L(\alpha) \cong \text{Dir}(\alpha/L, \dots, \alpha/L) \quad (4.12)$$

#### グローバル遷移確率 $\beta$ およびローカル遷移確率 $\pi$ のサンプリング

式 (4.7), (4.9), (4.12) より、グローバル遷移確率  $\beta$  およびローカル遷移確率  $\pi_j$  の事前分布は以下のディリクレ分布によって与えられる。

$$\beta \sim \text{Dir}(\gamma/L, \dots, \gamma/L) \quad (4.13)$$

$$\pi_j \sim \text{Dir}(\alpha\beta_1, \dots, \alpha\beta_j + \kappa, \dots, \alpha\beta_L) \quad (4.14)$$

ここで、 $\beta$  と  $\pi_j$  の尤度関数は  $L$  次元の多項分布であるため、ディリクレ分布と多項分布の共役性により、事後分布は以下のように導出される。

$$\beta | \bar{\mathbf{m}} \sim \text{Dir}(\gamma/L + \bar{m}_1, \dots, \gamma/L + \bar{m}_L) \quad (4.15)$$

$$\pi_j | z_{1:T} \sim \text{Dir}(\alpha\beta_1 + n_{j1}, \dots, \alpha\beta_j + \kappa + n_{jj}, \dots, \alpha\beta_L + n_{jL}) \quad (4.16)$$

ここで、 $\bar{m}_k$  は状態  $k$  に割り当てられている観測の数であり、 $n_{jk}$  は時系列  $z_{1:T}$  の中で状態  $j$  から状態  $k$  へと遷移を起こした回数である。また、サンプリングにおける初期値には、補助変数を無視し、 $\pi_{j_0} \sim \text{Dir}(\alpha\beta_1, \dots, \alpha\beta_j + \kappa, \dots, \alpha\beta_L)$  からサンプルした実現値を与える。

#### 出力分布パラメータ $\varphi$ のサンプリング

一般に、設定した出力分布  $p(x|\varphi)$  に応じて、出力分布のパラメータ  $\varphi_j$  の事後分布は以下で与えられる。

$$\varphi_j \sim p(\varphi | \{x_t | z_t = j\}, H) \quad (4.17)$$

後述する提案手法では出力分布に正規分布  $\mathcal{N}(\boldsymbol{\mu}, \boldsymbol{\Sigma})$  を考え、その事前分布として正規逆ウィシャート分布  $\mathcal{NIW}(\kappa_0, \boldsymbol{\mu}_0, \boldsymbol{\Sigma}_0, \nu_0)$  を置いている。正規分布と正規逆ウィシャート分布の共役性により、出力分布パラメータの事後分布も以下のように正規逆ウィシャート分布として得られる。

$$p(\boldsymbol{\mu}, \boldsymbol{\Sigma} | \mathbf{x}_{1:T}, \kappa_0, \boldsymbol{\mu}_0, \boldsymbol{\Sigma}_0, \nu_0) = \mathcal{NIW}(\hat{\kappa}, \hat{\boldsymbol{\mu}}, \hat{\boldsymbol{\Sigma}}, \hat{\nu}) \quad (4.18)$$

ここで、正規逆ウィシャート分布の各パラメータの更新式は以下の通りである。なお、 $\hat{\mathbf{x}}$  は観

測値平均,  $N$  は観測数である.

$$\begin{aligned}
\hat{\kappa} &= \kappa_0 + N \\
\hat{\boldsymbol{\mu}} &= \frac{\kappa_0}{\kappa_0 + N} \boldsymbol{\mu}_0 + \frac{N}{\kappa_0 + N} \hat{\boldsymbol{x}} \\
\hat{\boldsymbol{\Sigma}} &= \boldsymbol{\Sigma}_0 + \sum_{i=1}^N (\mathbf{x}_i - \hat{\boldsymbol{x}})(\mathbf{x}_i - \hat{\boldsymbol{x}})^T + \frac{\kappa_0 N}{\kappa_0 + N} (\hat{\boldsymbol{x}} - \boldsymbol{\mu}_0)(\hat{\boldsymbol{x}} - \boldsymbol{\mu}_0)^T \\
\hat{\nu} &= \nu + N
\end{aligned} \tag{4.19}$$

### 潜在状態 $z$ のサンプリング

潜在状態  $z_t$  のサンプリングは, まずバックワードメッセージと呼ばれる補助変数  $m_{t,t-1}(z_{t-1})$  を逆方向に計算する.

$$m_{t,t-1}(z_{t-1}) = \sum_{z_t} p(z_t | z_{t-1}) p(\mathbf{x}_t | z_t) m_{t+1,t}(z_t) \tag{4.20}$$

その後, 以下の事後分布より  $z_t$  を順方向にサンプリングする.

$$p(z_t | z_{t-1}, \mathbf{x}_{1:T}, \boldsymbol{\pi}, \boldsymbol{\varphi}) \propto p(z_t | \boldsymbol{\pi}_{z_{t-1}}) p(\mathbf{x}_t | \boldsymbol{\varphi}_{z_t}) m_{t+1,t}(z_t) \tag{4.21}$$

### ハイパーパラメータ $\alpha, \gamma, \kappa$ のサンプリング

実装の簡便性より, ハイパーパラメータ  $\alpha, \gamma, \kappa$  をそれぞれ  $\alpha + \kappa, \gamma, \rho = \kappa / (\alpha + \kappa)$  と再定義しサンプリングを行う.  $\alpha + \kappa$  および  $\gamma$  の事前分布には無情報ガンマ分布を設定し,  $\rho$  の事前分布には無情報ベータ分布を設定する. 各分布からランダムに生成した値をブロック化ギブスサンプリングにおける初期値と設定し, 事後分布のサンプリングを行う. 詳細は Fox による整理結果 [101] を参考にされたい.

## 4.3 sHDP-HMM を援用した変化検出手法の提案

本節ではメッシュ人口データに対する統計的変化検出手法を提案する. sHDP-HMM を用いてメッシュ人口データの通常時の潜在状態とその数を学習した後, 検証データの潜在状態を先の状態と比較することで変化を検出する. また前述の通り, ラベルによって変化を出力する手法と変化スコアによって変化を出力する手法の両方を提案する. 以下, 提案手法の概要を述べた後, sHDP-HMM のパラメータ推定方法について説明する.

### 4.3.1 提案手法の概要

提案手法は以下の 3 つのステップによって構成されている. はじめに, 教師データを用いて通常時の潜在状態をと sHDP-HMM の各パラメータを推定する (ステップ 1). 次に, 学習したパラメータをセットした sHDP-HMM を変化を含み得る検証データに適用して潜在状態を推定する (ステップ 2). 最後に, 2 つの潜在状態を比較することにより変化を検出する (ス

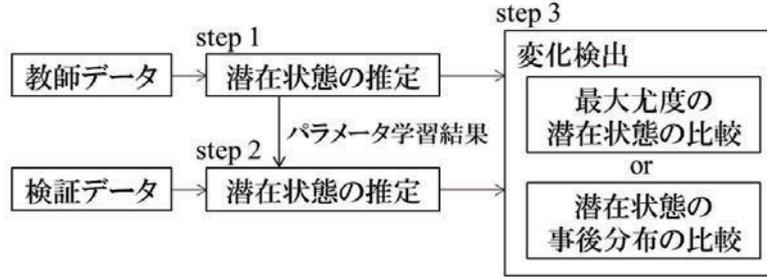


図 4.3. sHDP-HMM による変化検出手法の概略

ステップ 3). この時, 最大尤度の潜在状態を比較するか, 潜在状態の事後分布を比較するかで 2 種類の手法を構築する. 前者がラベルによる変化の出力方法に, 後者が変化スコアによる変化の出力方法に対応している. 本手法における提案手法の概略を図 4.3 に示す.

ステップ 1 では, 教師データとして変化を含まない時系列データ  $\mathbf{x}_{1:T} = \{\mathbf{x}_1, \dots, \mathbf{x}_T\}$  を sHDP-HMM の観測値系列に設定する. ただし,  $T$  は時系列長である. なお, 時刻  $t$  における観測値として,  $d$  次元ベクトル  $\mathbf{x}_t = \{x_t^1, \dots, x_t^d\}^T$  が得られるとする. また, 潜在状態  $k$  に対応した出力分布にはパラメータ  $\theta_k = \{\boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k\}$  で定義される  $d$  次元ガウス分布  $\mathcal{N}(\boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)$  を設定し, その事前分布  $H$  として共役事前分布である正規逆ウィシャート分布  $\mathcal{NIW}(\kappa_0, \boldsymbol{\mu}_0, \boldsymbol{\Sigma}_0, \nu_0)$  を置く.

$$\begin{aligned} & \mathcal{NIW}(\boldsymbol{\mu}, \boldsymbol{\Sigma} | \kappa_0, \boldsymbol{\mu}_0, \boldsymbol{\Sigma}_0, \nu_0) \\ & \propto |\boldsymbol{\Sigma}_k|^{-(\nu_0+d+2)/2} \exp\left\{-\frac{1}{2}\text{tr}(\boldsymbol{\Sigma}_0\boldsymbol{\Sigma}^{-1}) - \frac{\kappa_0}{2}(\boldsymbol{\mu} - \boldsymbol{\mu}_0)^T\boldsymbol{\Sigma}^{-1}(\boldsymbol{\mu} - \boldsymbol{\mu}_0)\right\} \end{aligned} \quad (4.22)$$

また, sHDP-HMM のハイパーパラメータ  $\alpha, \gamma, \kappa$  は未知であるため無情報事前分布を与える. 以上のように設定した sHDP-HMM に対し, ブロック化ギブスサンプリングによって潜在状態  $z_t$  の事後分布  $p(z_t | \mathbf{x}_{1:T})$  など, ハイパーパラメータを含む全てのパラメータの事後分布のサンプリングを実行する. なお, サンプリングにおける初期値は事前分布よりランダムに取得した値を用いる.

ステップ 2 では, 検証データ時系列  $\mathbf{x}'_{1:T}$  における潜在状態  $z'_t$  を推定する. この時, ステップ 1 での教師データの推定時に最大の尤度をとったサンプリングでのパラメータ  $\hat{\boldsymbol{\pi}}, \hat{\boldsymbol{\beta}}, \hat{\boldsymbol{\theta}}$  を本推定の初期値として用いる. sHDP-HMM のハイパーパラメータ  $\hat{\alpha}, \hat{\gamma}, \hat{\kappa}$  はステップ 1 での最大尤度のサンプリング結果を用いることとし, ステップ 2 ではサンプリングを行わない.

最後に, ステップ 3 では 2 つの潜在状態  $z_t, z'_t$  の比較を行い, 変化の検出を行う. 最大尤度の潜在状態を比較することでラベルによる変化の出力を行う提案手法 1 と, 潜在状態の事後分布を比較することで変化スコアによる変化の出力を行う提案手法 2 に分かれる.

#### 提案手法 1: 最大尤度の潜在状態の比較

ステップ 1 およびステップ 2 の推定時に最大の尤度をとったサンプリング結果を正常状態  $z_{1:T}$  および検証状態  $z'_{1:T}$  とし, それらの一致性を確認する. ただし, ステップ 2 におけるパ

ラメータの再推定によって各状態に割り当てられた番号が最終的に変わり得るため、ハミング距離をコストとする割当問題をハンガリー法 [102] を用いて解く。その後、割り当てられた状態を時刻  $t$  毎に比較し、 $z_t \neq z'_t$  ならば変化と判断する。

#### 提案手法 2 : 潜在状態の事後分布の比較

正常状態  $z_t$  と検証状態  $z'_t$  の事後分布  $p(z_t|\mathbf{x}_{1:T}), p'(z'_t|\mathbf{x}'_{1:T})$  間の距離を時刻  $t$  毎に比較し、各時刻での変化スコアを算出する。確率分布間の距離を測る尺度として、カルバック・ライブラー (KL) 距離、ピアソン距離、相対ピアソン距離、 $L^2$  距離などが存在する [103]。いま距離を測りたい二つの分布は多項分布であり、その多くの次元に 0 を含むような分布である。そのため、統計学や機械学習の分野でよく用いられている距離尺度である KL 距離やその二乗損失版であるピアソン距離を用いる場合、密度比関数  $p/p'$  が有界でなくなり、距離が正しく計算できない恐れがある。また密度非関数が有界でないという問題を解決すべく提案された相対ピアソン関数の場合は、混合比をどのように決めるかが問題となる。そこで提案手法では、安定性が高く実用上扱いやすい  $L^2$  距離を採用する。二つの事後分布  $p, p'$  は多項分布であるため、これら分布間の  $L^2$  距離は以下で定義される。

$$L^2(p, p') = \sum_k (p(k) - p'(k))^2 \quad (4.23)$$

以下ではこの値を時刻  $t$  における変化スコア  $s(t)$  とし、 $s(t)$  がある閾値を超えたら変化と判断する。なお、 $\sum_{z_t} p(z_t) = \sum_{z_t} p'(z_t) = 1$  より  $\{p(k)\}^2$  の最大値が 1 となるため、変化スコアの最大値は 2 となる。なお提案手法 2 では、ステップ 1 で観測値が割り当てられていた  $\theta_k$  の値を固定し、ステップ 2 で  $\theta$  の再推定によって各状態に割り振られた出力分布パラメータが変化するのを防ぐ。

#### 4.3.2 メッシュ人口データへの適用方法

これまでに説明した提案手法は一つのメッシュ内で得られる 1 本の時系列データのみで考えられている。提案手法を複数のメッシュで構成される対象領域に適用する場合、各メッシュごとに隠れマルコフモデルに基づく時系列遷移を考えることとなる。ただし各メッシュについて独立に潜在状態を考えてしまうとメッシュ間での状態比較ができなくなるため、対象空間全体で取りうる状態が同じである必要がある。そのためには階層ディリクレ過程の枠組みにおいて、グローバル遷移確率  $\beta$  を共有化させることで実現される。その概念図を図 4.4 に示す。全メッシュにて共通のグローバル遷移確率  $\beta$  および出力分布パラメータ  $\varphi$  を保有しているため、各潜在状態の定義はすべてのメッシュで統一される。一方で任意のメッシュにて異なるローカル遷移確率  $\pi$  の存在を許すことで任意のメッシュ毎に異なる時系列遷移をモデル化することが可能となる。パラメータ推定では式 (4.16) におけるローカル遷移確率  $\pi$  のサンプリング時のみメッシュ独立で考えればよく、他の変数のサンプリング方法は変わらない。

なお、隣接するメッシュ間や交通ネットワークで密につながった地域間では人口動態に相互影響が存在している。そのため潜在状態間にも相関や相互影響が含まれていると考

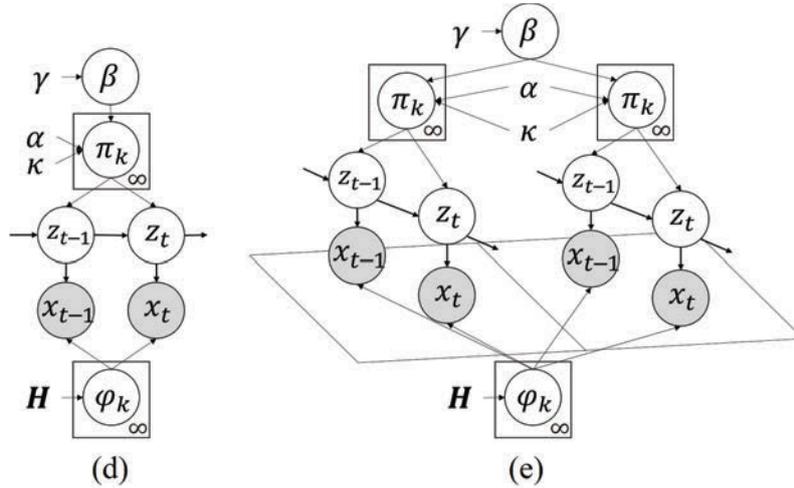


図 4.4. スティッキー階層ディリクレ過程隠れマルコフモデルの複数メッシュへの適用  
 (d) スティッキー階層ディリクレ過程隠れマルコフモデル (再掲), (e) 複数メッシュへと適用する場合.

えられるため、その影響を表現するモデル構造に発展させることが望まれる。具体的には、時刻  $t$  におけるメッシュ潜在状態の  $z_t$  出力が、時刻  $t-1$  における潜在状態  $z_{t-1}$  およびその周辺メッシュの潜在状態  $z_{t-1}^j$  による分布  $p(z_t|z_{t-1}, z_{t-1}^j, \pi)$  から得られると構造化することが考えられる。また、ローカル遷移確率  $\pi$  のサンプリングにて周辺メッシュとの相関が高くなるように、ハイパーパラメータ  $\alpha, \kappa$  をさらに階層化させるなどの間接的な方法も考えられる。さらに、メッシュ人口データというデータの性質を活かし、異なるメッシュ分解能で潜在状態の推定を行ったのちに、それらを統合するという方法も考えられる。しかしいずれのアプローチ方法においても、適切なモデル表現の検証や推定の安定性・実現性の確保など、多くの課題を克服する必要がある。そのため本研究では空間方向へのモデル拡張を見据えるものの、まずは時間方向にのみ影響が伝搬している簡潔な状況をモデル化することとし、このモデル下での変化検出性能を検証する。

#### 4.4 提案手法の適用と結果の考察

シミュレーションデータ及び実データに提案手法を適用し、その変化検出性能を検証する。なお本研究では推定プログラムの実装に、Fox ら [94] が公開している MATLAB HDP-HMM Toolbox を使用した。

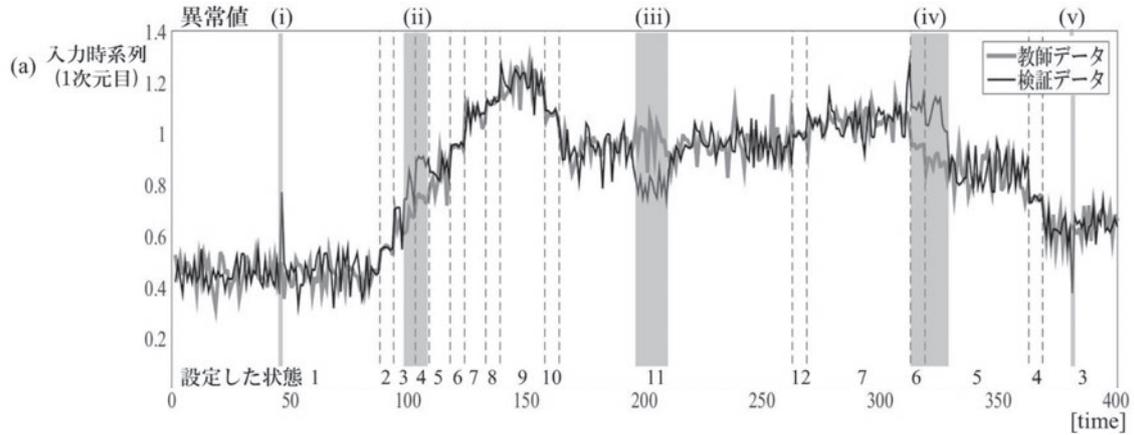


図 4.5. 作成したシミュレーションデータ  
 入力データについては 1 次元目の人口値のみ表示. 上段 (i)~(v) は混入した異常値, 下段 1~12 はシミュレーションデータ作成時に設定した状態を指す.

#### 4.4.1 シミュレーション実験による性能評価

##### 実験データおよび実験条件

本シミュレーション実験にあたり, 図 4.5(a) に示す時系列長  $T = 400$  の教師データおよび検証データを作成した. 時系列データの作成にあたっては, 図中の「設定した状態」欄の番号で示されている計 12 個の状態を設定し, 各状態毎に定義した正規分布から i.i.d. サンプルを並べている. 正規分布の平均および分散は, 人口データの 1 日の挙動に倣うように適宜設定した. また, 検証データとして別サンプルを並べて時系列データを作成し, 明示的な変化としてデータの 10% に対して変化値 (i)~(v) を手動で加えた. 加えた変化値の場所と大きさはそれぞれ, (i)  $t = 46(5\sigma)$ , (ii)  $t = 98 \sim 108(3\sigma)$ , (iii)  $t = 196 \sim 210(3\sigma)$ , (iv)  $t = 311 \sim 328(3\sigma)$ , (v)  $t = 381(5\sigma)$  である. なお,  $\sigma$  は各状態で設定した正規分布の標準偏差に等しい.

モデルの観測値  $\mathbf{x}_t$  は, 生成したデータ値  $y_t$  と 1 時刻前からの増減率  $\delta y_t = (y_t - y_{t-1})/y_{t-1}$  の 2 次元値とした. 本実験では当該メッシュの人口の大小とその増減をモデルの観測値として設定した. また, 教師データから平均値  $\mathbf{m}$  と共分散行列  $\mathbf{S}$  を求め, 正規逆ウィシャート分布のパラメータに  $\kappa_0 = 0.01$ , 自由度  $\nu_0 = 3$ ,  $\boldsymbol{\mu}_0 = \mathbf{m}$ ,  $\boldsymbol{\Sigma}_0 = 0.75 \times \mathbf{S}$  を設定した. 上記の設定の下, シミュレーションデータに対して sHDP-HMM を適用し, ブロック化ギブスサンプリングによる推定を行った. この時, サンプリング回数は 10,000 回とし, 状態数の最大値を  $L = 50$  により近似した. また, 開始 100 回のサンプリング結果をバーンイン期間として除外した.

##### 潜在状態の推定および変化検出結果

図 4.6(b) にステップ 1 における教師データのサンプリングの過程で, 最大の尤度を取得した時の潜在状態  $z_{1:T}$  の推定結果を示す. 推定された潜在状態をアルファベット a~g および背

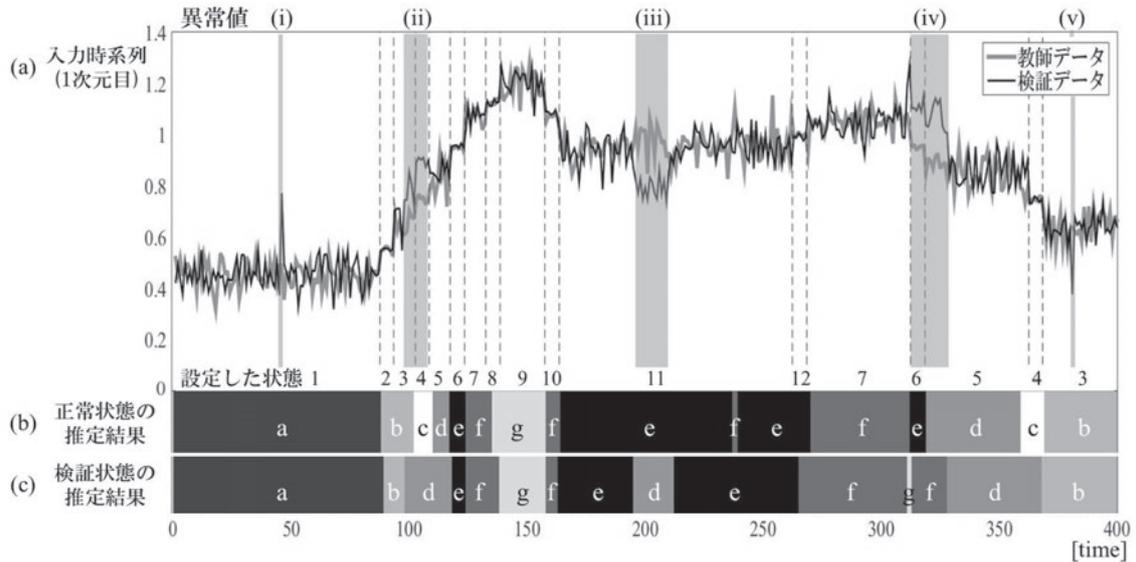


図 4.6. シミュレーションデータでの潜在状態の推定結果  
 (a) 入力データ (再掲), (b) 教師データの状態推定結果, (c) 検証データの状態推定結果

景の濃淡によって示している. データ作成時には計 12 個の状態を設定したが, 本推定では状態数は計 7 個と推定された. 事前に設定した状態 2 と 3 が状態 b として, 状態 6 と 11 が状態 e として推定されるなど, 複数の状態が一つの状態に統合されて推定された. ただし, 出力分布パラメータの推定結果を確認すると, 事前に設定したパラメータと大きく相違することはなかった. また, ステップ 2 における検証データのサンプリングの過程で最大尤度を取得した時の潜在状態  $z'_{1:T}$  の推定結果を図 4.6(c) に示す. 状態 a, b, d~g の計 6 個の潜在状態が推定された.

ここで, sHDP-HMM を用いることでメッシュ人口データの潜在状態を適切に推定できているかを確認するため, 通常の HDP-HMM との状態推定結果の比較を行う. 図 4.7 上段には sHDP-HMM による状態推定結果 (図 4.6(b) の再掲), 下段には通常の HDP-HMM による状態推定結果を示している. HDP-HMM による実験の際は, ハイパーパラメータ  $\kappa$  を 0 に固定した以外は同じ条件で推定を実施した. HDP-HMM で推定を行った場合, 図中の太枠で囲っている箇所のように高頻度で状態が切り替わっていることが確認された. 変化検出モデルとして HDP-HMM を適用した場合, このような箇所では誤検出が多く発生することが予想される. 一方で, 自己遷移確率を持つ sHDP-HMM を利用することでこのような状態の切り替わりを防ぐことができている. ゆえに, 潜在状態が時間とともに徐々に遷移していくことが予想されるメッシュ人口データへの適用には sHDP-HMM が比較的適していると考えられる.

次に, 提案手法 1 により変化を検出した結果を図 4.8(d-1) に示す. 図中の黒く示した箇所が, 変化が検出された時刻である. これは, 図 4.8(b) の正常状態と図 4.8(c) の検証状態が異なる箇所に等しい. 変化値 (ii)~(iv) に関しては対応する時刻に正しく変化が検出された. しかし, 変化値 (i) および (v) に関しては, 検証状態は正常状態から変化することなく, 未検出



図 4.7. 状態推定結果の比較

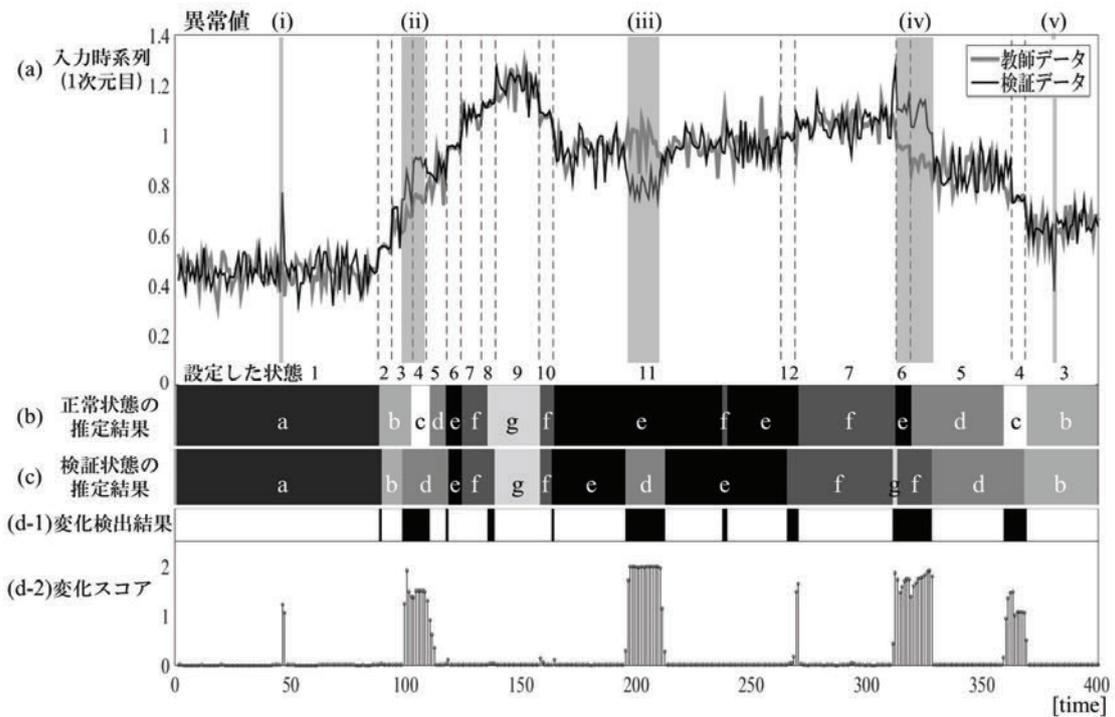


図 4.8. シミュレーションデータへの変化検出結果

(a) 入力データ (再掲), (b)(c) 状態推定結果 (再掲), (d-1) 提案手法 1 による変化検出結果, (d-2) 提案手法 2 による変化スコア算出結果

であった。また、正常状態列と検証状態列で推定された状態の区分が若干異なっていたため、状態が切り替わる境界付近で特に多くの誤検出が確認された。実際、サンプリングの過程では状態が切り替わる境界が頻繁に変化している様子が確認された。

図 4.8(d-2) に、提案手法 2 により変化スコアを算出した結果を示す。事後分布間の距離から算出した変化スコアの最大値は 2 であることに注意されたい。また、本手法によって求められる変化スコアは、変化度合いの大きさや教師データと検証データの解離度を表しているものではなく、推定した潜在状態がどれ程の確度で異なっているかを示す指標である。結果について見ていくと、変化値 (ii)~(iv)、および提案手法 1 では検出できなかった変化値 (i) において高い変化スコアが算出された。なお、変化値 (v) については提案手法 2 でも変化スコアは低い

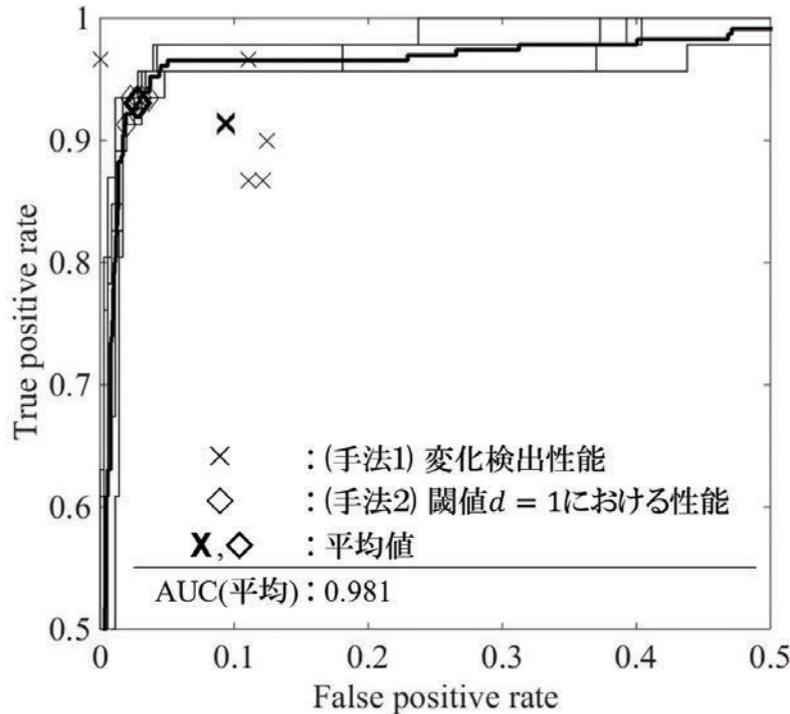


図 4.9. 提案手法の精度検証結果

結果であった。また、提案手法 1 では誤検出が散見された状態の切り替わる境界付近でも、提案手法 2 ではほとんどの場合で低い変化スコアが算出されていることが分かる。変化スコアの算出に事後分布を用いることにより推定のゆらぎを許容したことで、ステップ 2 において出力分布パラメータを固定することにより推定の変動を軽減したことが、高精度な変化検出結果に繋がったと考えられる。

#### 提案手法の比較検証

上述の実験により提案手法 2 の変化検出能が優れていることが示唆されたが、その性能を定量的に把握するため、2 つの提案手法の変化検出性能の比較検証を行う。2 つの提案手法を上述のシミュレーションデータに 5 回ずつ適用し、それぞれの試行から変化検出率、偽陽性率、精度の平均値を算出し、それらと比較する。ここで、変化検出率とは「検出すべき変化のうち、正しく検出することができた割合」、偽陽性率とは「検出すべきでない正常なデータのうち、変化として検出してしまった割合」、精度とは「検出した変化のうち、それが本当に変化である割合」である。また、提案手法 2 については ROC 曲線および AUC 値を用いて変化検出性能評価を行う。ここで、ROC (Receiver Operating Characteristic) 曲線とは任意の閾値に対して変化検出率と偽陽性率を計算し、それらの変化検出率-偽陽性率平面上へのプロットを繋いだ曲線である。AUC (Area Under the Curve) 値は ROC 曲線の下側の面積であり、変化検出器の性能の良さを表す指標である。なお、提案手法 1 との比較の際には、変化スコアの最大値の  $1/2$  に相当する  $s = 1.0$  を閾値として用いる。

提案手法 1 の平均的な性能は、変化検出率が 91.3%、偽陽性率が 9.4%、精度が 50.8% であった。一方、提案手法 2 に関してそれぞれの試行毎に ROC 曲線を描き、そこから平均的な ROC 曲線を算出した。この時、AUC 値の平均値は 0.981 を得た。また、閾値を  $s = 1.0$  と設定したときの平均的な変化検出率は 93.0%、偽陽性率は 2.8%、精度は 72.8% であった。これらの結果をまとめて図 4.9 に示す。提案手法 1 では変化検出率は高い性能を示しているが、前述の誤検出の影響により、精度が低下することが確認された。一方、提案手法 2 でも変化検出率において高い性能を示すと同時に、偽陽性率および精度では大幅な性能の向上が確認された。

さらに本手法の変化検出性能を比較するために、最も典型的な手法の 1 つである隠れマルコフモデル (HMM) を用いた変化検出手法との比較実験を行った。事前に HMM の数を固定する必要があるため、3~10 個の状態数を持つ 8 種類のモデルを用意し、それぞれ独立に同様のシミュレーションデータへと適用した。教師データから出力分布パラメータ  $\varphi$  と状態遷移確率  $\pi$  を学習する際には EM アルゴリズムを使用した。そして、viterbi アルゴリズムを用いて教師データおよび検証データの潜在状態を推定し、提案手法 1 と同様に、推定した潜在状態の直接比較を通じて変化検出を行った。

結果を表 4.1 に示す。HMM の状態数  $N$  が 3~10 の場合、ならびに提案手法 1 および 2 における変化検出率 (Recall)、疑陽性率 (False Positive Rate)、精度 (Precision) について整理した。HMM の状態数が増えるほど変化検出率が増加することが分かる。より多くの状態数を有する HMM は時系列をより細かく分類することができるため、教師データと検証データ間の不一致が検出され、検出率が向上している。一方、状態の数が大きすぎる場合、誤検出も同時に増加してしまうことが分かる。そのため、検出率と精度の両立が可能な適切な HMM の状態数を設定する必要があるが、扱うデータに応じてアドホックに設定しなければならず、一概には難しい。

sHDP-HMM に基づく提案手法では、6 つ以上の状態を有する HMM と同程度の高い検出率を示した。精度に関しては、HMM の結果よりも低いケースも存在したが、過度の精度低下を回避することができたことが確認できる。これは、sHDP-HMM の枠組みに応じて適切な状態数を推定することができたためだと考えられる。人口動態のような状態数が未知である問題の場合、sHDP-HMM に基づく変化検出を使用することの利点の 1 つであることが実証できた。さらに、HMM に基づく変化検出手法では図 4.8(a) における変化値 (i) を検出することができなかったが、提案手法 2 では検出することができている。sHDP-HMM に基づく方法では検証データの状態推定時でも新たな潜在状態を生成することができる。ゆえに、学習データに含まれていない未知のデータまたは未知の状態に対して、提案手法を用いることで変化検出を正しく行うことができたと考える。

#### 4.4.2 実データへの適用

最後に、実際のメッシュ人口データへ提案手法を適用する。ここでは、異なる 2 つの実データに適用することにより提案手法の特性を確認する。まず一つ目の実験として、短期間・狭領

表 4.1. 従来手法と提案手法の比較検証結果

	Recall [%]	False Positive Rate [%]	Precision [%]
HMM(N=3)	63.0	1.2	85.3
HMM(N=4)	69.6	2.4	76.2
HMM(N=5)	89.1	3.1	75.9
HMM(N=6)	93.5	5.6	65.2
HMM(N=7)	93.5	13.8	43.0
HMM(N=8)	93.5	18.8	35.5
HMM(N=9)	84.8	22.5	29.5
HMM(N=10)	87.0	22.5	26.0
our method 1	91.3	9.4	50.8
our method 2	93.0	2.8	72.8

域を対象とした場合のデータを用いる。具体的には、東武伊勢崎線周辺の計 60 個のメッシュを対象とし、2012 年 10 月 30 日と翌週 11 月 6 日のデータを比較する。11 月 6 日の早朝に同線で人身事故による運転見合わせが確認されており、この影響で生じたと思われる異常状態の検出によって手法の有効性の検証を行うものである。二つ目の実験では、長期間・広領域を対象とする。千代田区・港区・中央区に含まれる計 214 メッシュについて着目し、2014 年 10 月平日平均と 2015 年 6 月平日平均のデータを比較する。9 か月の経年経過によって人口動態にいかなる変化が生じたかを検証するとともに、データの違いによる変化検出結果の違いを比較することを目的とするものである。

#### 短期間・狭領域を対象とした場合

本実験では 1 時間間隔に取得された 2 分の 1 地域メッシュの人口データである混雑統計データを用いる。このデータは、携帯電話ユーザの利用許諾を得た上で送信される位置情報を統計的に加工したものであり、個人特定はできないよう配慮されている。対象期間として 2012 年 10 月 30 日 (火) 及び同年 11 月 6 日 (火) のデータを使用する。10 月 30 日には大きな災害や社会的イベント等が確認されず、一方で 11 月 6 日には午前 6 時頃東武伊勢崎線北千住 - 浅草間等で約 1 時間半の運転見合わせが確認されているため、前者を教師データ、後者を検証データとして用いる。対象メッシュとして図 4.10(a) に示す当該沿線を含む計 60 個の 500m メッシュに着目する。なお、この図は国土交通省国土政策局「国土数値情報」をもとに筆者が編集・加工し作成した。

観測値  $\mathbf{x}_t$  として、各時刻  $t$  におけるメッシュ人口値 (万人) と、1 時間前からの増減率の 2 次元ベクトルを設定する。正規逆ウィシャート分布のパラメータやサンプリング条件などはシミュレーション実験時と同様である。なお、異なるメッシュ間で同一の状態を共有させるため、各メッシュを独立して推定するのではなく、全 60 メッシュの状態推定を同時に行う。また、前述の通り任意のメッシュ毎にローカル遷移確率  $\pi$  を独立させることが可能である。た

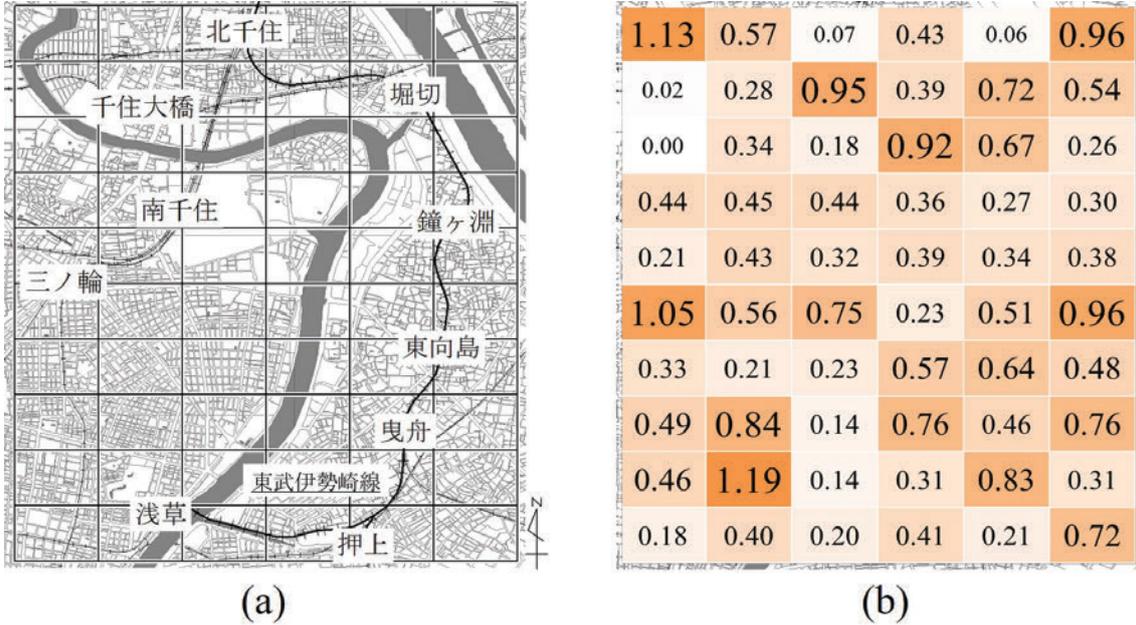


図 4.10. 対象とする狭領域と変化スコアのメッシュ平均  
 (a) 対象とする 2 分の 1 地域メッシュ, (b) 算出された変化スコアのメッシュ平均.

だし今回の検証においては、推定の安定性の向上、および対象範囲が狭領域であることを踏まえ、全てのメッシュにおいて同一のローカル遷移確率  $\pi$  を共有させることとする。上述の比較検証結果より提案手法 2 を適用することとし、各メッシュの変化スコアを算出する。

図 4.11(上段) に各時刻における変化スコアの平均値を示す。0 時~1 時における変化スコアは全体平均である 0.48 程度であったが、その後変化スコアが上昇し、運転見合わせが発生した 6 時~7 時では最大値である 0.74 を出力した。その後変化スコアは平均以下まで減少したが、夕方の帰宅ラッシュに差し掛かる 16 時~18 時には再び変化スコアが増加し、平均値以上の値となった。また、図 4.11(下段) には 2 時点のメッシュ人口値の差分を示す。差分を計算した場合、最も乖離が大きくなったのは 7 時~8 時の時間帯であり、運転見合わせが発生した時間帯とは異なることが分かる。メッシュ人口値の差分のみに着目した場合、メッシュ人口値の大小に強く影響を受けてしまうため、データの背後に潜む潜在的な変化を検出できない可能性があることが示唆される。一方、潜在状態の推定を介した本手法ではそのようなメッシュ人口値の大小そのものには影響を受けにくく、差分分析からでは検出しにくい変化や異常を捉えることができると考えられる。

また、図 4.10(b) に各メッシュにおける変化スコアの平均値を示す。東武浅草駅を含む 9 行 2 列目のメッシュ (A) では変化スコアが 1.19 と地域内で最も高かった。一方で、北千住駅を含む 1 行 3 列目のメッシュ (B) は地域内で人口密度が最も大きな地域であったが、変化スコアは 0.07 と小さかった。それぞれのメッシュ人口値と変化スコアの算出結果を図 4.12 に示す。(A) のメッシュでは二日間の人口値に乖離が存在し、それに合わせて変化スコアが大きく算出

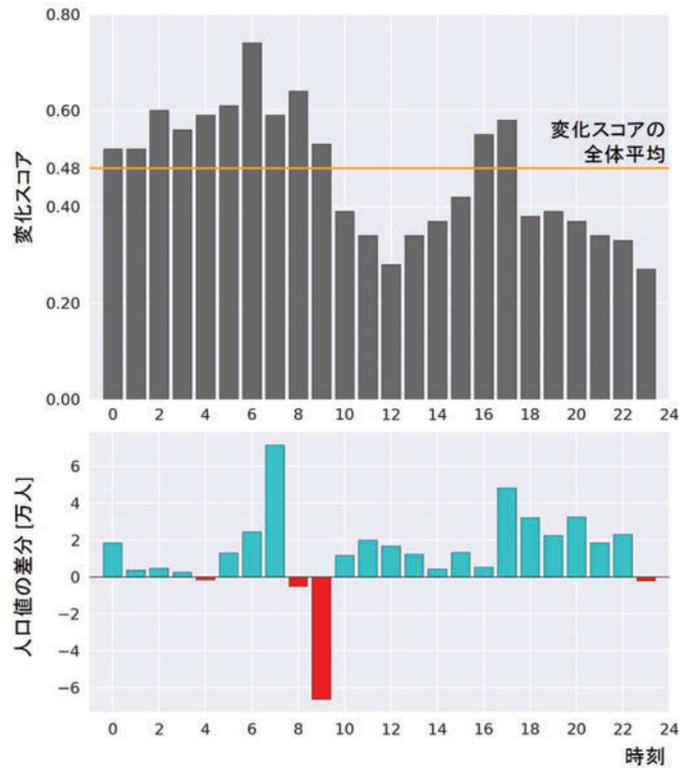


図 4.11. 変化スコアの時刻平均  
(上段) 算出された変化スコアの時刻平均, (下段) メッシュ人口値の差分

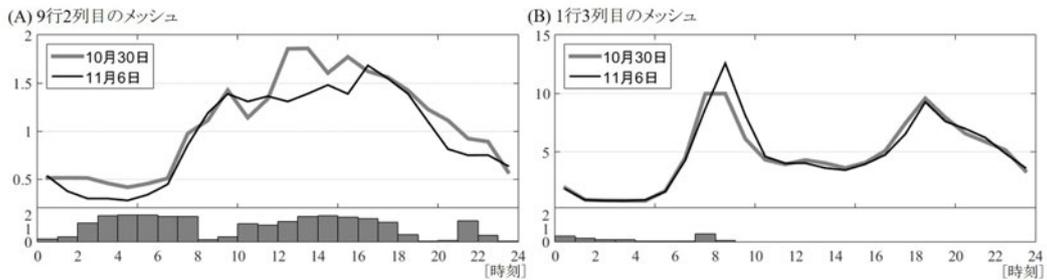


図 4.12. 特定メッシュにおける人口値と変化スコアの比較  
(A) 東武浅草駅を含む 9 行 2 列目のメッシュ, (B) 北千住駅を含む 1 行 3 列目のメッシュ, (上段) 当該グリッドの人口値, (下段) 算出された変化スコア.

されていた。また、(B) のメッシュでは運転見合わせの影響のためか、11 月 6 日の朝ピークの人口値が 10 月 30 日のものよりも大きかった。しかし、人口値の乖離が発生した時間が比較的短かったことが、変化スコアが大きく算出されなかったことの要因であると考えられる。これらの結果より、学習データと検証データ間の乖離が比較的長く続くことで変化スコアが上昇する傾向にあると考えられる。

図 4.13 に示すのは、対象 60 エリアすべてに対する変化スコアの可視化結果である。左側に

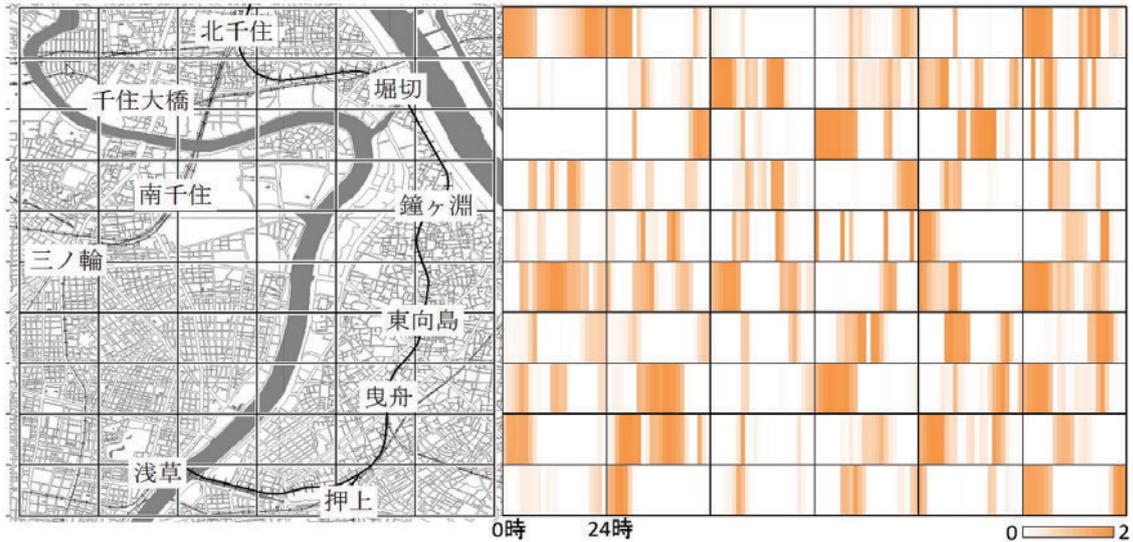


図 4.13. 伊勢崎線沿線のメッシュ別・時刻別の変化スコア算出結果

対象 60 メッシュを示し、右側のカラーバーで各メッシュ・各時刻における変化スコアを橙色の濃淡で表している。各セルの左端がそのメッシュにおける 0 時、右端が 24 時を示し、橙色が濃いほど変化スコアが高いことを意味する。この結果から分かるように、多くのメッシュで高い変化スコアが算出されている。今回の実験では学習に 1 日分のデータのみを使用しているため、メッシュ人口の日間変動を考慮できておらず、変化スコアが過大に評価された可能性がある。さらに、24 時から深夜 1 時にかけての連続性を考慮できていない点においても、状態数が過大に推定されている可能性がある。複数日にわたる大規模なデータを用いた検証を実施する必要がある。また、500m メッシュでは人口動態の変動が激しく、ノイズに多く影響されてしまった可能性がある。メッシュ空間分解能に対する変化検出結果の感度分析を行い、想定する変化状態や変化に合わせたメッシュデータの作成が望まれる。なお、隣接するメッシュ間で変化状態や変化が伝搬する明らかな様子は確認されなかった。変化が多く検出されてしまったことに加え、電車運休による数十分単位での人口動態の変化をとらえるには 1 時間間隔のデータでは困難であったことが考えられる。さらに状態推定において空間相関やメッシュ間の相互影響を考慮できておらず、メッシュ間で変化が独立に検出されてしまう。そのため空間方向で変化の解釈を行う際に、連続性や伝搬の様子が確認できなかつたと考えられる。今後、複数日にわたる大規模なデータへの適用を通じ、モデル修正も行ったうえで上述の課題について検討する必要がある。

#### 長期間・広領域を対象とした場合

次に、広領域を対象とした変化検出実験を行う。モバイル空間統計データを用いて、学習データに 2014 年 10 月平日平均メッシュ人口値を、検証データに 2015 年 6 月平日平均メッシュ人口値を適用する。今回の実験では月平均のデータを用い、学習データと検証データには

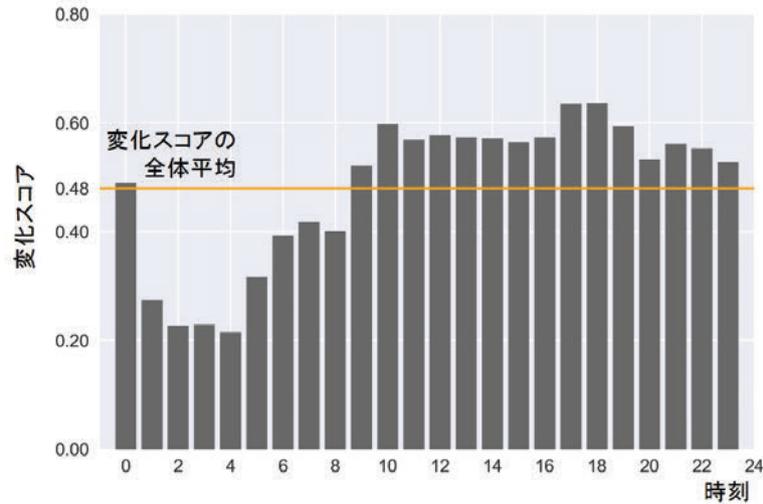


図 4.14. 広領域対象エリアにおける時刻別平均変化スコア

1年弱のブランクが存在する．そのため前節では列車運行による短期的な変化状態の検出を試みたが，今回の実験では都市再開発による人口構成の変化や通勤・通学形態の変化など，長期的な人口動態への変化抽出を試みる．対象領域は第 3.2 章にて扱ったエリアであり，計 214 メッシュで構成される．sHDP-HMM への観測値の設定方法，ハイパーパラメータの設定方法，状態推定および変化検出方法は前節での実験と同じである．

前節での分析と同様に，時刻別平均変化スコア，メッシュ別平均変化スコア，全時刻・メッシュの変化スコアを用いた分析を行う．全時刻・全メッシュでの平均変化スコアは 0.48 であり，これは狭領域での結果と同様であった．図 4.14 に示す時刻別平均変化スコアに着目すると，0 時台において高い変化スコアが確認できる．その後，朝の通勤ラッシュ時間帯を含む午前 2 時～午前 8 時台では変化スコアは平均以下であった．午前 9 時以降は局所的なピークは存在しないものの，変化スコアは平均以上の値をとり続けた．メッシュ別平均変化スコアを図 4.15 に示す．また，代表的な時刻として午前 4 時から午後 7 時まで 3 時間おきに計 6 時刻の変化スコアを GIS 上に可視化した結果を図 4.16 に示す．午前 4 時および午前 7 時では局所的な変化スコアの増加を除き，対象領域の全体で変化スコアが低い状態であった．午前 10 時以降になると特に北側地域を中心に対象領域の全体で変化スコアが上昇する様子が確認された．このように，対象エリア全体にて高い変化スコアが検出されたが，高スコアが集中している場所など特徴的な空間パターンは存在しなかった．

対象エリア全体にて高い変化スコアが検出された理由として，教師データ (2014 年 10 月) と検証データ (2015 年 6 月) 間の 1 年弱のブランクにより人口値自体に変動あった可能性が考えられる．図 4.17(a) に示すのは全メッシュ・全時刻における変化スコア，(b) に示すのは両データ間の人口値の差分の可視化結果である．ともに，横軸が 0 時から 24 時までの各時刻であり，縦軸に対象 214 メッシュについてメッシュ番号を上から昇順で並べている．変化スコアが高く計算された午前 9 時以降で，複数のメッシュにおいて比較的大きな差分値が数時間以上

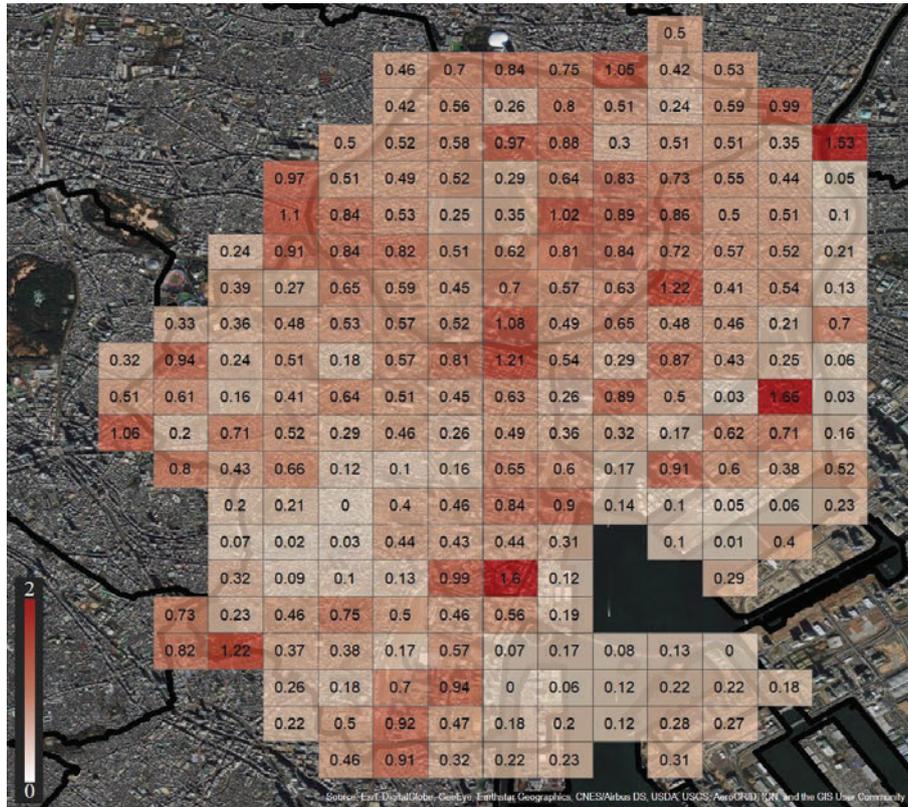


図 4.15. 広領域対象エリアにおけるメッシュ別平均変化スコア

にわたって存在している。学習データと検証データ間の乖離が比較的長く続いていることが確認でき、ゆえに変化スコアが上昇したのだと考えられる。なお、人口値の差分の絶対値をメッシュ毎に合計した値と、メッシュ別変化スコアについて相関係数を計算すると 0.53 であった。従って、対象空間全体の人口値の変化に大きく影響を受けて、広範囲にて高変化スコアが算出されたものと考えられる。

### 考察

以上より、短期間・狭領域を対象とした実験では運転見合わせや朝夕の通勤ラッシュに影響とするメッシュ人口の短期的な異常が発生していたことが示唆される。長期間・広領域を対象とした実験では人口構成や通勤・通学形態に変化が存在していたことが示唆される。提案手法を適用することでこれらの異常状態・変化を抽出することが可能となる。

ただし、狭領域・広領域いずれを対象とした実験においても、高変化スコアが複数のメッシュで検出された。これらの変化状態の原因は必ずしも自明なものばかりではない。シミュレーションによる検証でも明らかとなったが、提案手法では 30% 弱の割合で誤検出が発生してしまう。ゆえに実データの実験にて検出された変化も同程度の割合で誤検出を含んでいるものと考えられる。精度向上・誤検出削減に向けた方針として、前述した日間変動の学習、24 時から 1 時への連続性の確保が挙げられる。そのためにはこれらの学習機構を組み込んだモデル

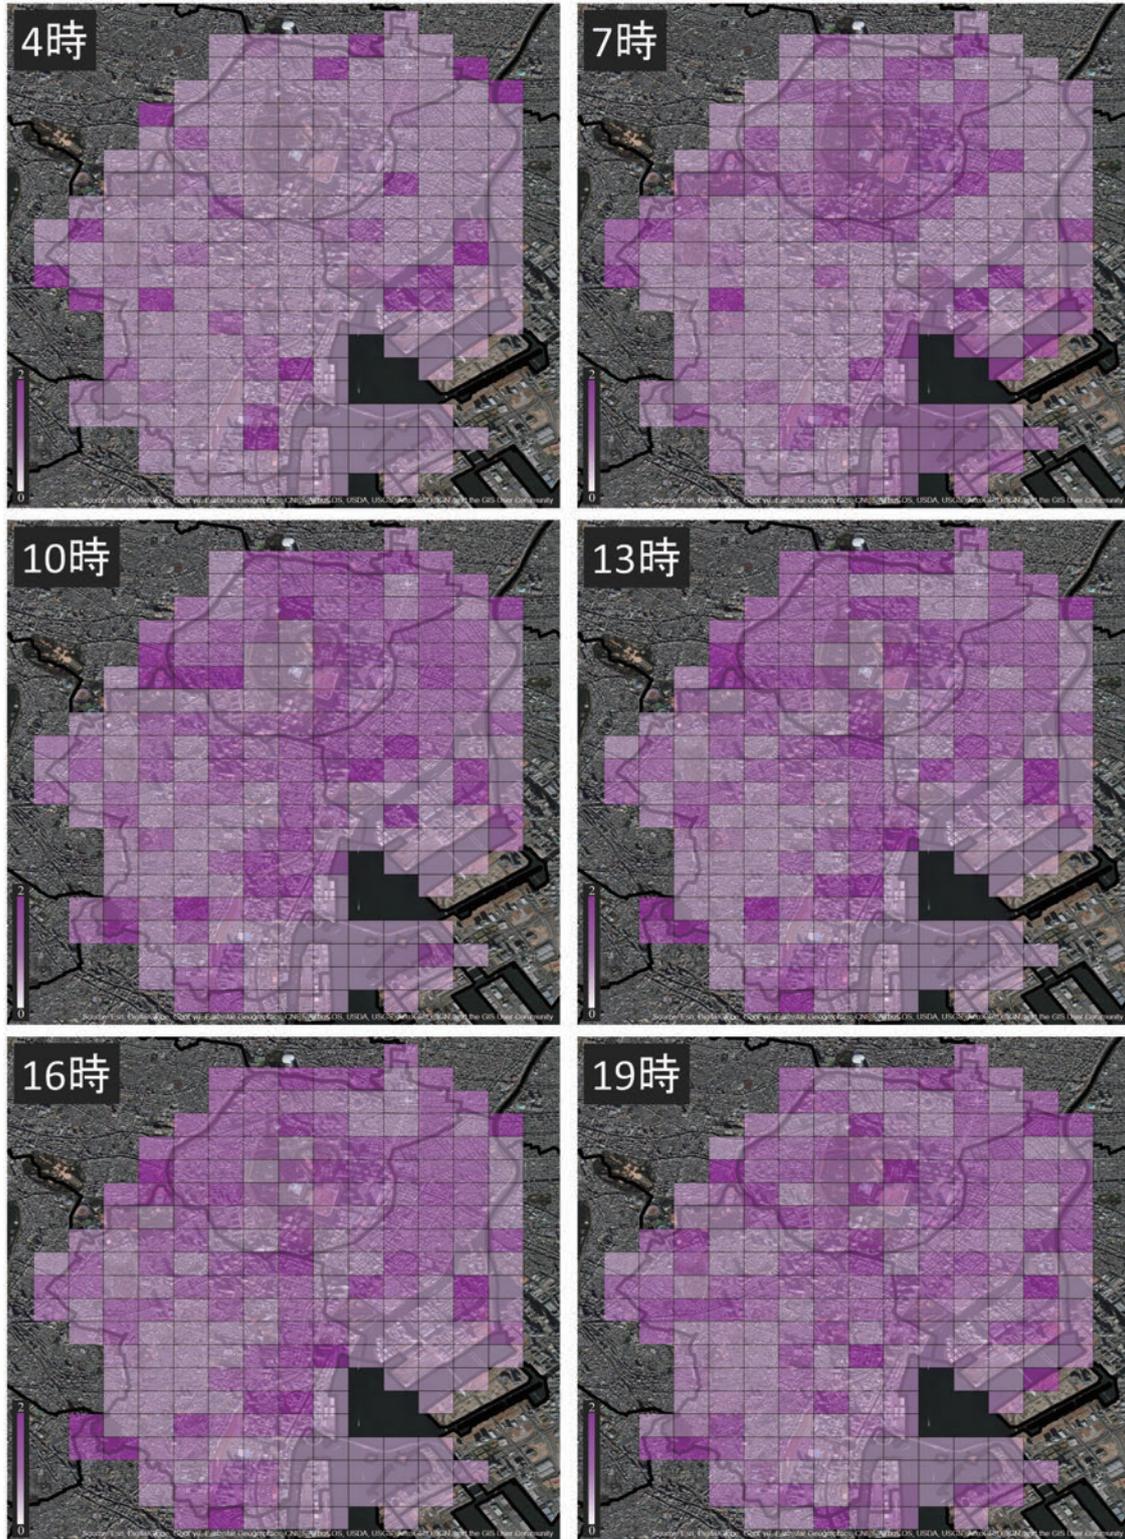


図 4.16. 広領域対象エリアにおける変化スコアの GIS 可視化結果

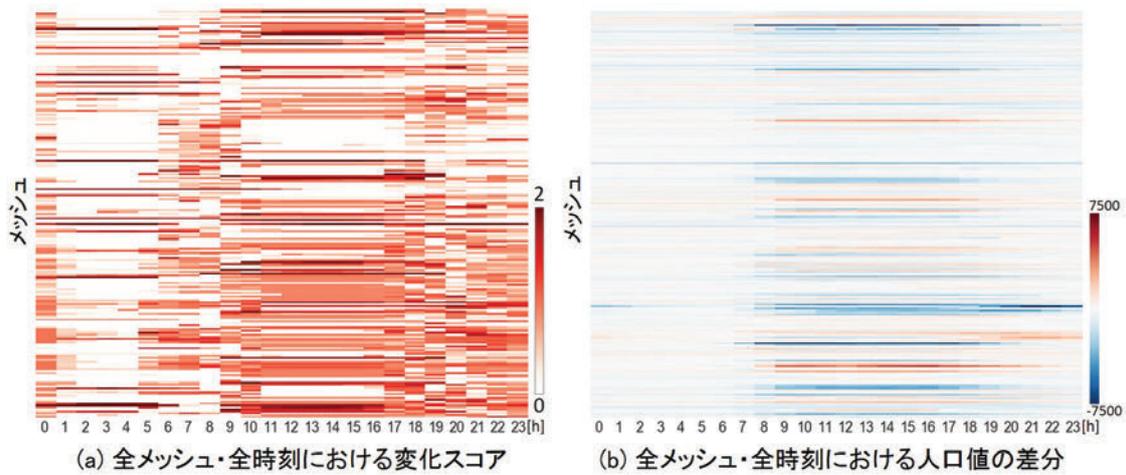


図 4.17. 広領域対象エリアにおける変化スコアと人口値の差分の比較

学習機構の開発を行うとともに、複数日にわたる大規模なデータを用いた検証を実施する必要がある。

また、今回の適用では約 500m 四方のメッシュを対象としたが、地域によって人口密度は異なるため、もしくは検出対象とする変化の種類に応じて着目すべき空間分解能も異なると考えられる。特に今回適用した 500m メッシュでは人口動態の変動が激しく、ノイズに多く影響されてしまった可能性があり、異なるメッシュサイズのデータに対する分析も進める必要がある。さらに、上記の分析では対象メッシュの潜在状態を共有させた上で同時推定を行っているが、メッシュ間の空間相関や相互依存関係を考慮したモデルへと発展させることが望まれる。そのための適切なモデル表現や推定方法の構築など理論的な発展が求められる。

また、本手法で求められる変化スコアは実際の当該メッシュにおける混雑度などとは完全には一致していない。ゆえに推定された潜在状態や検出された変化状態や変化が実交通ネットワークにおいてどのように解釈可能か分析を行う必要がある。各潜在状態に紐づいた出力分布パラメータ  $\varphi_k$  を確認することで状態の解釈が可能となる。しかし今回の実験では観測ベクトルに人口値と増減率の 2 次元正規分布を設定しているため、得られる解釈は各状態における平均的な人口値とその平均増加率のみである。従って、このモデル設定では潜在状態を実交通ネットワーク上で解釈するには不向きであると考えられる。

一方、流通しているメッシュ人口データには人口値以外の情報も含まれていることも多い。例えばモバイル空間統計では男女・年代別人口や居住地情報が含まれており、混雑統計データには自宅・勤務・流動(移動)別の人口情報が付加されている。これらの属性を観測ベクトルに使用することで潜在状態をより解釈可能な形で推定することが可能だと考えられる。そこで次章にて、トピックモデルに基づく潜在的意味解釈をメッシュ人口分布データへと適用する。

## 第 5 章

# トピックモデルによる人口動態の変化検出

### 5.1 トピックモデル

本章ではトピックモデルに基づく潜在的意味解釈をメッシュ人口データにて実施するとともに、トピックモデルを利用した変化検出手法を構築する。トピックモデルはもともと文書の確率的生成モデルとして提案されたモデルである。ただし、文章の順序は無視し、Bag of Words(BoW) 表現と呼ばれる単語と出現頻度のペアの集合をモデル化するものである。ここで、BoW 表現は単語が共起している現象を表しており、この共起性を用いて単語や文書をクラスタリングする手法であるとも換言できる。トピックモデルでは自然言語における単語がモデルの出力と設定され、単語の集合である文書ごとに潜在状態としてのトピック分布が割り当てられる。トピックとは例えば政治や芸能、科学などの文書カテゴリである。このトピック毎に、どの単語がどれくらいの確率で生成されるかが異なるため、高い出力確率を持つ単語から連想される上位概念をトピックの解釈とすることになる。ゆえに文書ごとに推定されたトピックを確認することで、その文書が「どのような文書なのか」に関する意味解釈が可能となる。このようなアプローチ方法は潜在的意味解釈と言われており、自然言語処理をはじめ、画像や購買データなどの大規模かつ非構造化データに対して盛んに適用されている。

トピックモデルの中でも表現能力の高さや推定方法の簡便さ、モデル拡張の容易さから最も代表的な手法として位置づけられているのが Latent Dirichlet Allocation(LDA)[20] である。以下、参考文献 [19][20][104] に基づき、LDA 生成モデルを定式化する。なお、これまでに議論したように LDA においても潜在状態数の事前設定が問題となる。そこで階層ディリクレ過程の枠組みをトピックモデルに応用した HDP-LDA[97] の導入を行う。

#### 5.1.1 Latent Dirichlet Allocation

LDA では、文書中の一つ一つの単語が対応する潜在変数(トピック)を保有していると仮定する。そして単語集合である文章は複数のトピックから構成されると考え、その構成比を離散分

布であるトピック分布として保有することとなる。いま、文書数を  $M$ 、文書  $d$  の文章長を  $n_d$ 、総単語数を  $V$ 、総トピック数を  $K$  とする。文書  $d$  の  $i$  番目の単語を  $w_{d,i}$  とすると、その単語に対応する潜在変数 (トピック) が  $z_{d,i}$  と定義される。トピックの添字集合を  $\{1, 2, \dots, k, \dots, K\}$  とすると、各潜在状態は 1 から  $K$  までの値をとることとなる ( $z_{d,i} \in \{1, 2, \dots, K\}$ )。  $\pi_{d,k}$  を文章  $d$  でトピック  $k$  が出現する確率 (文章  $d$  でのトピック  $k$  の構成比率) とすると、それらを並べたベクトルが文書  $d$  におけるトピック分布を  $\pi_d = (\pi_{d,1}, \dots, \pi_{d,K})$  とする。また、  $\varphi_{d,v}$  をトピック  $k$  における単語  $v$  の出現確率とすると、トピック  $k$  における単語分布は  $\varphi_k = (\varphi_{k,1}, \dots, \varphi_{k,V})$  で定義される。

トピック分布  $\pi_d$  および単語分布  $\varphi_k$  は Dirichlet 分布による生成を仮定する。  $\pi_d$  は文書ごとに、  $\varphi_k$  はトピックごとに生成されるため、以下の通り定式化される。

$$\pi_d \sim \text{Dir}(\alpha), d = 1, \dots, M \tag{5.1}$$

$$\varphi_k \sim \text{Dir}(H), k = 1, \dots, K \tag{5.2}$$

ここで  $\alpha = (\alpha_1, \dots, \alpha_K)$  は  $K$  次元ベクトルであり、トピック分布生成過程におけるハイパーパラメータとなる。通常、トピック間の重みに関する事前情報は得られないため、  $\text{Dir}(\alpha)$  が無情報事前分布となるように  $\alpha$  を設定することが多い。  $H$  は単語空間上に張る  $V$  次元ベクトルであり、単語分布生成過程におけるハイパーパラメータとなる。  $\text{Dir}(H)$  が無情報事前分布となるように  $H$  を設定するか、または全文書での単語出現確率に基づいて  $H$  を設定することも可能である。

また、単語  $w_{d,i}$  や潜在トピック  $z_{d,i}$  は離散値であるため多項分布を生成分布として仮定する。文書  $d$  上の単語  $i$  ごとに、トピック分布  $\pi_d$  に従って潜在トピック  $z_{d,i}$  が生成され、そして潜在トピック  $z_{d,i}$  が持つ単語分布  $\varphi_{z_{d,i}}$  に従って単語が出力される。すなわち以下の通り生成過程が定式化される。

$$z_{d,i} \sim \text{Multi}(\pi_d), i = 1, \dots, n_d \tag{5.3}$$

$$w_{d,i} \sim \text{Multi}(\varphi_{z_{d,i}}), i = 1, \dots, n_d \tag{5.4}$$

LDA の生成過程のグラフィカルモデルを図 5.1(a) に示す。

### 5.1.2 階層ディリクレ過程 LDA

上記の LDA モデルでは、総トピック数  $K$  を事前に設定する必要がある。そこで第 4.2 章で議論した階層ディリクレ過程を LDA に拡張し、加算無限個のトピック数を許容したものが Hierarchical Dirichlet Process Latent Dirichlet Allocation (HDP-LDA) [97] である。計算上は全てのトピックが用いられるわけではないため、前章における階層ディリクレ過程隠れマルコフモデルと同様に、HDP-LDA では観測データに応じてトピック数を自動的に推定することが可能である。そのため、トピック数を事前に設定することが難しいと考えられるメッシュ人口データに対する適用が有効であると考えられる。

HDP-LDA では 1 層目のディリクレ過程  $\text{GEM}(\gamma)$  によりグローバルなトピック分布  $\beta$  を生成されると考える。これは全文書の平均的なトピック分布としての役割を持つ。次に 2 層目の

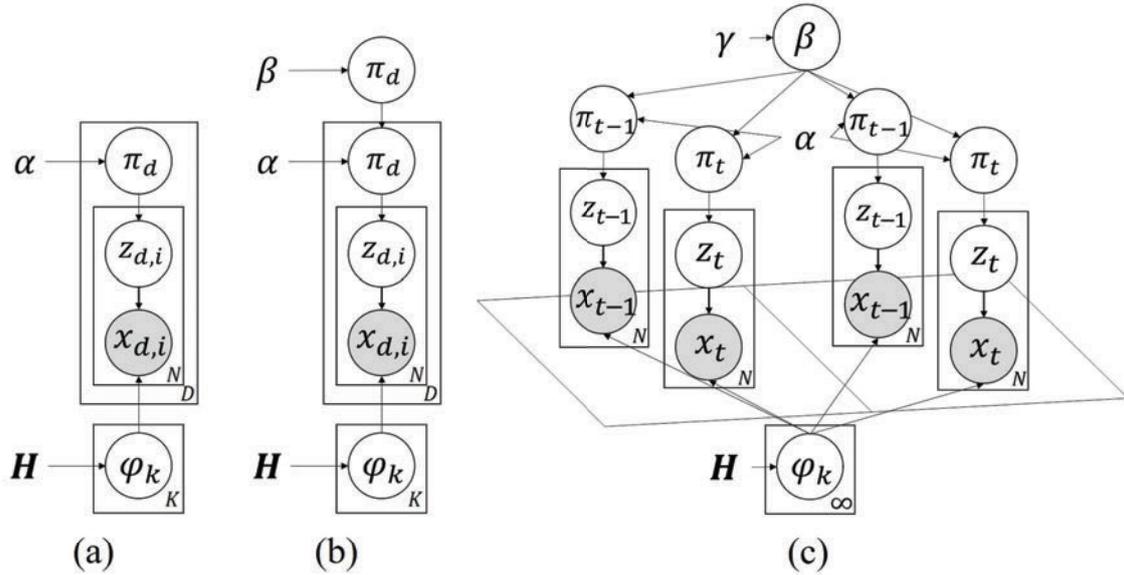


図 5.1. LDA のグラフィカルモデル表現  
 (a)LDA, (b)HDP-LDA, (c) メッシュ人口データへと適用する場合の概念図

ディリクレ過程  $DP(\alpha, \beta)$  によってローカルなトピック分布  $\pi_d$  が生成される。各文書におけるトピック分布であり、これは前節で議論したトピック分布としての役割を持つ。なお  $\alpha$  はディリクレ過程におけるハイパーパラメータである。この階層ディリクレ過程の枠組みによって、トピック分布  $\pi_d$  が無限次元ベクトルとなるため、加算無限個のトピック数を保有したモデルとして解釈できる。

一方、単語分布  $\varphi_k$  は単語空間上の事前分布  $H$  から多項分布  $\varphi_k$  のサンプリング  $\varphi_k \sim \text{Dir}(H)$  を加算無限回行う。その後の、トピック  $z_{d,i}$  の生成、およびそのトピックに紐づいた単語分布  $\varphi_{z_{d,i}}$  からの単語の生成過程は通常 LDA と同様である。

まとめると、HDP-LDA による生成モデルは以下のように定式化され、グラフィカルモデルは図 5.1(b) の通りである。

$$\beta | \gamma \sim \text{GEM}(\gamma) \tag{5.5}$$

$$\varphi_k | H \sim H \tag{5.6}$$

$$\pi_d | \alpha, \beta \sim \text{DP}(\alpha, \beta) \tag{5.7}$$

$$z_{i,d} | \pi_d \sim \text{Mult}(\pi_d) \tag{5.8}$$

$$x_{i,d} | z_{i,d}, \varphi_{1:\infty} \sim \text{Multi}(\varphi_{z_{i,d}}) \tag{5.9}$$

### 変分ベイズ法によるパラメータ推定方法

LDA のパラメータ推定の場合、変分ベイズを使ったパラメータ推定方法 [20] や Gibbs sampler を使ったパラメータ推定法 [105] が使われるほか、collapsed 変分ベイズ法による推定

方法 [106] [107] などが存在する. 前章で取り扱った HDP-HMM の場合でも collapsed 変分ベイズ法による推定方法など複数の方法が提案されている [106] [107] [108]. 変分ベイズ法とは確率モデルの潜在変数およびパラメータの事後分布を求める手法の 1 種であり, 事後分布を近似することで計算を簡単にしている特徴を持つ. 以下, 変分ベイズ法によるパラメータ推定方法について概説する.

HDP-LDA を変分ベイズ法でパラメータ推定を行う場合には, グローバルトピック分布  $\beta$  を  $K$  次元で, ローカルトピック分布  $\pi_d$  を  $T$  次元で近似する必要がある. なお, 文書全体のトピック数はある一つの文書に含まれるトピック数よりも多いため  $K \ll T$  である. この時, 式 (5.5) から式 (5.9) にわたる HDP-LDA の生成モデルは補助変数  $c_{d,t}$  を導入することで以下の通り有限次元で近似される.

$$\beta \sim \text{Dir}(\gamma/K, \dots, \gamma/K) \quad (5.10)$$

$$\varphi_k \sim \text{Mult}(H) \quad (5.11)$$

$$c_{d,t} \sim \text{Mult}(\beta) \quad (5.12)$$

$$\psi_{d,t} = \varphi_{c_{d,t}} \quad (5.13)$$

$$\pi_d \sim \text{Dir}(\alpha/T, \dots, \alpha/T) \quad (5.14)$$

$$z_{i,d} \sim \text{Mult}(\pi_d) \quad (5.15)$$

$$x_{i,d} \sim \text{Mult}(\psi_{d,t}) \quad (5.16)$$

この補助変数  $c_{d,t}$  には, 次元数の異なるグローバルトピック分布  $\beta$  とローカルトピック分布  $\pi_d$  を繋げる役割がある. グローバルトピック分布  $\beta$  上の  $K$  個のトピックの中から,  $T$  個のトピックが式 (5.12) にて選択される. そして出力分布パラメータの対応付けを式 (5.13) で行うことにより, 式 (5.14) で独立に得られた  $T$  次元ディリクレ分布の第  $t$  トピックが  $\beta$  における第何トピックに対応しているかの情報を保有することになる.

以上のように有限次元で近似した HDP-LDA の変分ベイズ推定を考える. いま, 推定したいパラメータはグローバルトピック分布  $\beta$ , ローカルトピック分布  $\pi_d$ , 単語分布  $\varphi_k$ , 各単語の潜在トピック  $z_{i,d}$ , そして補助変数  $c_{d,t}$  である. また, ハイパーパラメータ  $\alpha, \kappa$  は今回は推定対象とはしない. ゆえに事後分布  $p(\beta, \pi, c, z, \varphi|X)$  の近似関数  $q(\beta, \pi, c, z, \varphi)$  について, 以下の変分近似が得られる.

$$q(\beta, \pi, c, z, \varphi) = q(\beta)q(\pi)q(c)q(z)q(\varphi) \quad (5.17)$$

また, 対数周辺尤度  $\log p(X)$  についてイェンセンの不等式を用いて下から評価すると, 以下が得られる.

$$\begin{aligned} \log p(X) &= \log \left[ \int p(\theta, Y) d\theta \right] \\ &= \log \left[ \int q(\theta) \frac{p(\theta, X)}{q(\theta)} d\theta \right] \\ &\geq \int q(\theta) \log \frac{p(\theta, X)}{q(\theta)} d\theta \\ &= F(q(\theta)) \end{aligned} \quad (5.18)$$

$F(q(\theta))$  を変分下限と呼び、変分下限を最大化することが事後分布の最大化と等価となる。なお、式 (5.18) においてパラメータをまとめて  $\theta = (\beta, \pi, c, z, \varphi)$  とおいた。各パラメータについて適切な更新式を求め、収束するまで更新を繰り返すことで変分下限の最大化が達成される。

なお、後述する実験においては、大規模データへの適用が可能であるオンライン型変分ベイズ法による推定手法 [108] を使用する。詳細な学習方法・更新式については [108] を参考にされたい。

## 5.2 メッシュ人口データへのトピックモデルの適用方針

本研究においてトピックモデルの枠組みをいかにメッシュ人口の潜在状態推定に利用するかを議論する。まず各変数の設定方法を検討を実施した後、その設定に基づいたモデル構造についてを説明する。

### 5.2.1 多分野におけるトピックモデルの変数設定の整理

自然言語へトピックモデルを適用する場合、以下の仮定に基づいたモデリングを行っている。

- 文書は互いに独立である
- 文書内での単語の順番は無視し、一つの文書を単語出現回数による特徴ベクトルで表現する
- 各トピックは文書カテゴリとして解釈され、文書は複数のトピックを潜在的に保有している

自然言語以外のデータに対してトピックモデルを適用する場合、上記想定を対象データで再定義する必要がある。メッシュ人口データへの適用に向けて、まずは他分野での設定方法を簡単に整理する。

自然言語以外のデータへと応用先としては画像・動画画像が代表的である。画像への適用の場合、Bag of Visual Words(BoVW) で画像を表現し、画像単位でのモデリングが行われることが多い。BoVW 表現とは一般物体認識において現在最も広く普及している画像特徴表現である。画像中の多数の局所特徴を k-means などによる量子化を施したものが Visual Word と呼ばれる「単語」に相当し、Visual Word のヒストグラムでベクトル化した BoVW が「文書」に相当する。この表現方法を用いることで画像データを次元圧縮して扱うことができ、計算量削減や機械学習技術との連携が取りやすくなる。このような設定方法を基盤に、他の観測情報との結合モデルを構築することで画像のシーン分類や物体認識が行われている [109],[110]。これらの問題設定下では、画像シーンや画像中の物体クラスが「トピック」に相当する。

動画画像に対してもトピックモデルの適用は可能であり、その場合は一つの動画を「文書」として設定されている。BoVW 表現と同様に時空間上でベクトル量子化された「単語」によって、その動画に映り込む動きとしての「トピック」が推定される例がある [111]。また、動画

像から抽出されたオプティカルフローとその位置を「単語」、オプティカルフローの集合へと変換した動画を「文書」とみなすことで、「トピック」として群衆行動パターンの推定が行われている [112].

音声データに対してトピックモデルを適用した例では、会議室内に設置されたマイクから発話者の推定が行われている [113]. 各時刻におけるマイク応答を「文書」とみなしたうえで、各時刻の「トピック」としての話者を推定する。「単語」には、音が聞こえてくる方向ごとの応答を離散化した Bag of Angle Words(BoAW) 表現が用いられている。他にも、歌声特徴量を利用した歌手分類 [114] や音階毎の出現頻度を利用した楽曲の調推定 [115] などが挙げられる。

EC サイトには各ユーザの購買・閲覧履歴に関する大量のログデータが得られており、トピックモデルを利用した分析も盛んである。例えば、購買ログデータを用いて時間変化するユーザの興味および商品の流行を追跡するためのトピックモデルが提案されている [116]. 「文書」としてのユーザを分析単位に、そのユーザが起こした購買や閲覧などアクション対象となった商品が「単語」となる。「トピック」としてユーザの興味商品カテゴリが得られ、時系列性を考慮したトピックモデルを利用することで興味カテゴリの追跡や購買行動の予測が可能となる。

位置情報データを用いたトピック分析も行われている。例えばユーザの過去の行動履歴から次の行動を予測し推薦するためのジオトピックモデル [117] では、各ユーザを「文書」、ユーザがこれまでに訪れた場所(カフェや公園、スポーツ施設など)を「単語」、さらに近隣施設への訪問しやすさをモデリングすることで、「トピック」として訪問先ジャンルの推定が行われている。また、携帯電話通信時に得られる位置情報履歴を用いて有意位置の検出を行った研究 [118] では、位置情報の時間的な近接性に着目し、通信基地局を「単語」、ある一定の時間窓に含まれる位置情報履歴(通信基地局群)を「文書」とみなすことで、有意位置としての「トピック」が推定される。

他にも、サッカーのプレーデータから攻撃パターンを分類し類似した一連の攻撃を抽出する手法 [119] や、法案と投票行動の関連性から投票パターンの分析を行った研究 [120], ファッションコーディネート推薦システム [121] など、幅広いデータを対象にトピックモデルの適用がなされている。

表 5.1 に、他分野におけるトピックモデルの変数設定方法をまとめた。以上まとめると、「単語」の設定方法によって、単語集合である「文書」や単語生成分布としての「トピック」の解釈が定まるといえる。さらにその他補助情報を潜在変数や観測変数に追加することで複雑なモデリングや興味対象の推定を行うことができるようになる。これら整理結果をもとに、人口分布データでの変数設定方法を表中のように設定した。詳しい検討内容を次節にて述べる。

### 5.2.2 メッシュ人口データにおける変数設定方法の検討

メッシュ人口データをトピックモデルを適用するにあたり、自然言語における「文書」と「単語」に対応する変数の設定方法を検討する。そして文書と単語の設定の下で推定される「トピック」にはどのような解釈となりえるか議論する。

表 5.1. 多分野におけるトピックモデルの変数設定方法の例

自然言語	画像処理	音声処理	購買データ分析	位置情報	本研究
文書	画像	時刻 小節	ユーザ	位置情報履歴	メッシュ
単語	BoVW オブティカルフロー	BoAW 音階	商品	訪問場所 通信基地局	居住地
トピック	画像シーン 群衆行動	話者 調	商品カテゴリ	訪問先ジャンル 有意位置	人口特性
既往研究例	[109],[110],[111],[112]	[113],[114],[115]	[116]	[117],[118]	

### 文書に対応する変数の検討

メッシュ人口データはメッシュ × 時刻ごとに人口値データが格納されている形式を持つ。分析単位の候補としては、(1) 全メッシュ 24 時間をまとめて一つのデータとする、(2) 全メッシュについて時刻ごとに異なるデータとする (時間断面データ)、(3) メッシュ毎に 24 時間分のデータを一つのデータとする (空間断面データ)、(4) 各メッシュ・各時刻で独立したデータとする、の 4 パターンが考えられる。(1)、(2) のような設定方法は、本論文で扱う詳細な空間単位における潜在状態の推定問題とは異なる問題意識となる。対象全メッシュを一つの分析単位として扱うため、詳細な空間分解能で取得されているメッシュ人口データをより粗い空間分解能にて再集計することとなり、データ情報量の欠損も大きい。一方、画像データにおけるトピックモデル適用例のように、対象エリア (画像) はメッシュ (ピクセル) で構成されていると考え、局所特微量の抽出・モデル適用を行うというアプローチ方法も考えられるが、人口動態データにおける局所特微量の定義・抽出が困難となる。(3) の設定方法では時刻に関する情報が失われる点が問題である。各メッシュで潜在状態を推定することができるが、これまで議論してきたように潜在状態自体の時間遷移も重要な観点である。音響データのような時系列データに対する適用例を見ても、時間方向へ集計したデータ表現での分析はあまり行われていない。

そこで本研究では、(4) で示す設定方法を採用する。各時刻および各メッシュをそれぞれ独立した「文書」と考える。すると全メッシュ × 時刻にてトピック分布が割り当てられるため、時間方向および空間方向での類似トピックの伝搬の様子などを分析することが可能となる。図 5.1(c) には、この設定下で HDP-LDA を適用する場合の概念図を示した。

ただし、グラフィカルモデルからも分かるように、同一メッシュ内での時系列遷移がモデル構造から欠落しており、モデリング改善の余地があると考えられる。なお、トピックモデルで時系列データ分析を行うために、Dynamic topic model[122] や Topics over time[123], Topic tracking model[124] など複数のモデルが提案されている。ただしこれらのモデルでは、グローバルトピック分布  $\beta$  に時間マルコフ性を考慮するか、時間そのものを別の観測値としてモデリングするかなど、時系列性の表現方法が大きく異なる。さらに、HDP-LDA によるトピック数の自動推定機構と時系列性の考慮を同時に考慮している事例は現在筆者の限り存在せず、理論構築から行わなければいけない点が課題である。同様に、空間方向に対するモデル拡

張も望まれる。位置に関する補助変数を導入する、トピック分布のサンプリング  $\pi_d \sim \beta$  過程を拡張するなどのアイデアが考えられるが、時系列性と同様に階層ディリクレ過程との理論統合が大きな課題となる。

そこで本研究では時空間系列性をモデル内に考慮することはせず、まずはメッシュ・時間ごとに独立した「文書」として分析を行う。そして推定されたトピック分布などの変数を空間方向・時間方向で比較することによって時空間系列性を考慮することとする。

### 単語に対応する変数の検討

各時刻・各メッシュに存在する人口値データから「単語」たる離散変数を作成する必要がある。人口値データに含まれる情報として人口値そのものに注目すると、人数・増減率・平均値との乖離・混雑率などが挙げられる。しかしトピックモデルに適用のためにはこれらの値を量子化する必要がある、その過程で値の大小関係が失われてしまう。また、作成される単語数も少ないため、トピックモデルを用いるメリットが失われる可能性がある。

一方、流通しているメッシュ人口データには人口値以外の情報も含まれていることも多い。例えばモバイル空間統計では男女・年代別人口や居住地情報が含まれており、混雑統計データには自宅・勤務・流動(移動)別の人口情報が付加されている。

そこで本研究では、滞在者の居住地を「単語」に対応する概念と考える。メッシュに滞在する人数は所与のものとし、各人に対して「どこから来たか/どこに住んでいるのか(居住地)」を割り振っていくという流れである。滞在者の居住地とは1日のトリップの始発地点とも考えることができるため、そのため、個々の移動情報が存在しないメッシュ人口データでも、移動情報を含む人口動態を表現することが可能になると考えられる。

この時、単語空間は居住地全体、すなわち(国内のみで考えるのなら)日本全土であり、トピック  $k$  に対応する単語分布  $\varphi_k$  は単語出現確率としての重みをもった部分地域集合となる。この単語分布を用いることで地域(居住地=単語)をカテゴリ化することができるため、メッシュ滞在という移動情報を基にした地域分割・地域クラスタリングが可能となる。

ただし、上記の単語設定では、メッシュに存在する人口値をそのままモデルに組み込むことができている。地域別の来訪者数の割合が全く同じメッシュであってもメッシュに存在する人数が異なれば、それらのメッシュが持つトピックや潜在状態は異なるものと考えられる。そのため、居住地とは別の観測情報として人数そのものをモデル出力として組み込み、複数の単語分布を許容できる Multiple-Source Latent-Topic[125]などを参考にモデル拡張を行うこととなる。本研究ではまずは居住地を単語として設定した場合のモデル構築方法の検討を行うこととし、複数情報を統合したモデル拡張および拡張したモデルと HDP-LDA との理論統合は今後の課題である。

### トピックに対応する変数の解釈

以上の設定の下では、「トピック」に該当する変数は「地域集合」として解釈される。そして各メッシュ・各時刻(文書)で推定されたトピック分布  $\pi_d$  に注目すると、「どの地域集合からの滞在者が潜在的に多いか」などといった人口特性に関する解釈が可能である。また、どの

地域にも大勢が存在するような居住地はトピックモデルの枠組みによって特徴的な単語とはならないため、単なる OD データの大小に基づく分析では得られない潜在的な人口特性が得られると考えられる。このトピック分布に対する解釈を、ここではメッシュの潜在状態として考える。ここで、第 4 章では観測値に対応する潜在変数  $z_t$  をメッシュの (時刻  $t$  における) 潜在状態として考えていたが、本章ではトピック分布  $\pi_d$  をメッシュの潜在状態として考える点に注意されたい。

### メッシュ人口分布データの生成過程の考え方

これまでに議論した前提のもとで、メッシュ人口分布データにおけるトピックモデルによるデータ生成過程について、以下の仮定を設ける。

- 本研究では各時刻・各メッシュを独立に取り扱う
- 各メッシュは、複数のトピックの重み付き和 (人口特性) を保有する
- 各メッシュに存在する人口そのものの値については分析対象とせず、所与のものとする
- トピックに応じて滞在者の「居住地」がサンプリングされる機構とする

図 5.2 は本研究におけるメッシュ人口データの生成過程を模式的に表したものである。まず、第 1 層のディリクレ過程によってグローバルトピック分布  $\beta$  がサンプリング  $\beta \sim \text{GEM}(\gamma)$  される。この  $\beta$  は全時刻・全メッシュにて共通したものである。そして各時刻・各メッシュでそれぞれトピック分布  $\pi_d$  が  $\pi_d \sim \text{DP}(\alpha, \beta)$  に従って  $T \times D$  回生成される。ここで  $T$  は時刻分割数、 $D$  はメッシュ数である。メッシュ  $d$  に存在する人数を  $N_d$  とすれば、トピック分布  $\pi_d$  に基づいてトピック  $z_{i,d}$  が  $N_d$  回サンプリングされ、各トピックに紐づけられた単語分布  $\varphi_{z_{i,d}}$  に従って居住地  $x_{i,d}$  が生成される。図中の人型シルエットの濃淡の違いが居住地の違いを表しており、その濃淡 (居住地) の共起性をもとにした人口特性を推定することとなる。

## 5.3 HDP-LDA による人口動態の潜在的意味解釈

### 5.3.1 適用データと実験条件

東京 23 区を対象とし、2014 年 10 月平日の平均値を表す約 500m メッシュのモバイル空間統計データを使用した。対象範囲は 2,607 メッシュで構成され、1 時間平均の居住地別人口が得られている。本研究では各時刻・各メッシュを独立した文書として扱うため、文書数としては 2,607 メッシュ  $\times$  24 時間 = 62,568 文書相当である。単語として用いる居住地としては、モバイル空間統計のデータ性質上、都道府県レベル、市区町村レベル、町丁目レベルでの入手が可能である。トピックの意味解釈を行う上ではなるべく高分解能が望まれ、一方で安定した推定のためには単語数が少ない、すなわち低分解能が望まれる。そこで、本研究では市区町村レベルを居住地の単位として利用した。

HDP-LDA の実装には python 用ライブラリ gensim を使用した。また、HDP-LDA のパラメータ事後分布の推定にはオンライン変分推定手法 [108] を用いた。理論上は無次元で行

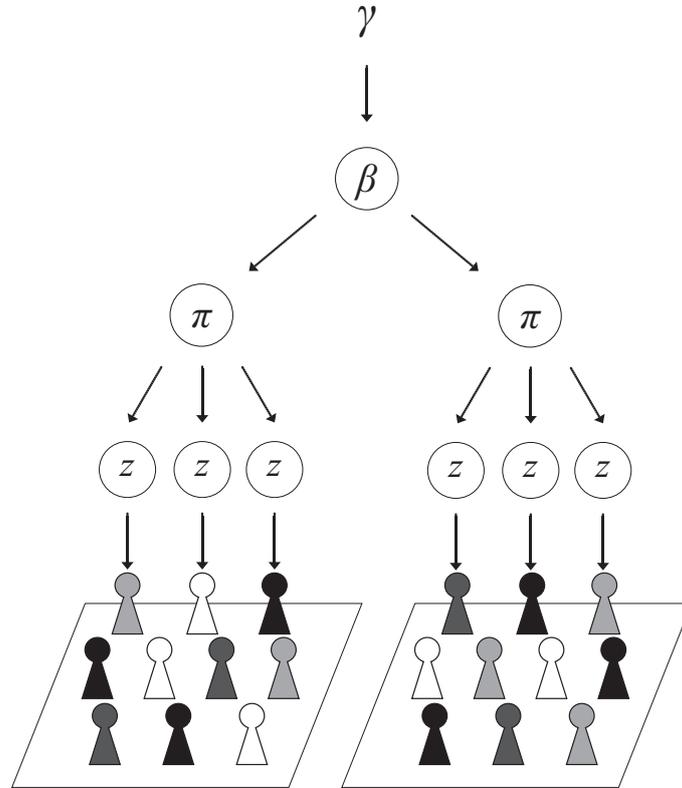


図 5.2. HDP-LDA を用いたメッシュ人口データの表現方法

われる第 1 層および第 2 層のディリクレ過程を，十分な大きさのトピック数上限値  $K$  および  $T$  を設定し，ディリクレ分布として近似する過程を含む手法である．今回の実験においては， $K = 150$ ， $T = 15$  を採用し，学習係数  $\kappa = 0.6$ ，ミニバッチサイズ  $S = 1024$ ，学習制御パラメータ  $\tau_0 = 64$  とした．また，ハイパーパラメータについては  $\gamma = 1.0$ ， $\alpha = 1.0$  とした．これらのパラメータは学習データ推定時の尤度が最大となるよう，複数のパラメータ値の組み合わせの検証を通じて決定したものである．各パラメータの詳細については，参考文献 [108] を参考にされたい．

### 5.3.2 手法の適用とその結果の分析

上記の設定の下，HDP-LDA をメッシュ人口データに適用し，モデルの推定を行い，各トピックにおける単語分布  $\varphi_k$ ，および各文書（メッシュ）におけるトピック分布  $\pi_d$  を推定した．

#### トピック数の推定結果

まず，推定されたトピック数について確認する．図 5.3 は，各トピックがいくつのメッシュから採択されたのかを示している．横軸が各トピック番号  $k = 1, \dots, K = 150$  であり，縦軸がそのトピックが割り振られたメッシュ数である．すなわち， $\sum_d \text{sign} [\sum_i f(z_{i,d}, k)]$  で与えら

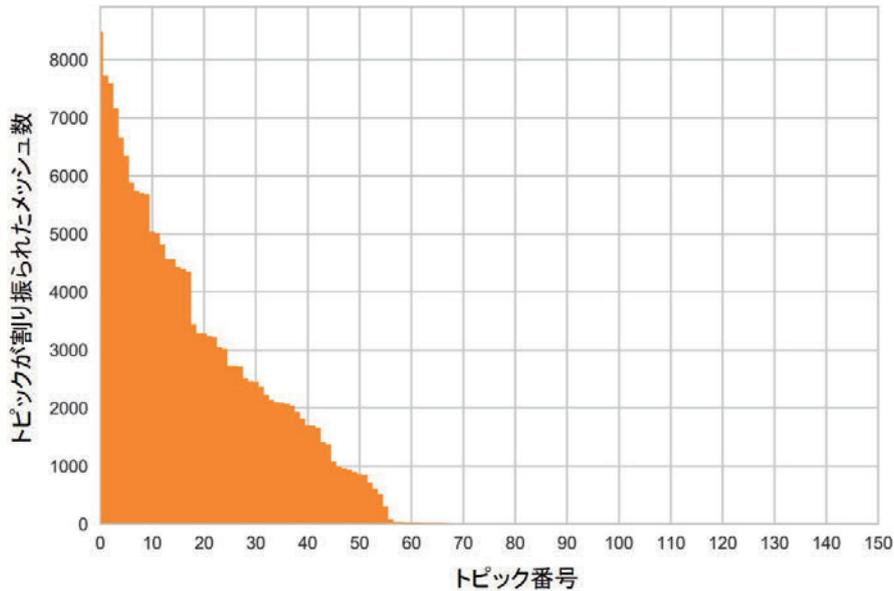


図 5.3. HDP-LDA によるトピック数の推定結果

れる値である．ここで関数  $f(x, y)$  は  $x = y$  で 1, それ以外 0 を出力する関数である．なお, トピック番号  $k$  自体は意味を持たないため, 計算した縦軸の値が降順に並ぶようトピック ID を振りなおしている．

この結果, 上位 56 個のトピックが 100 を超える文書の構成トピックとなっていることが確認された．92 個のトピックについては数文書から数十文書の構成トピックとなっていることが確認されたが, これらは主要なトピックではないと考えられる．残る 2 個のトピックについてはどのメッシュの構成トピックともなっていない．すなわち階層ディリクレ過程の枠組みによって確率が付与されずに使用されなかったトピックである．以上より, 56 個の主要なトピックが HDP-LDA により自動推定されたことが確認された．

#### 推定された地域集合の意味解釈

次に, 推定された地域集合を構成する市区町村を確認する．すなわち, 各トピック  $k$  においてどのような単語分布  $\phi_k$  が得られたのかを確認する．ただし, 56 個の主要な地域集合すべてについて分析・可視化することは困難である．そこで上位 10 個の地域集合 (以下, トピック 0, ..., トピック 9) について単語分布  $\varphi_k$  を通じた意味解釈を行っていく．図 5.4 に, その単語分布の可視化結果を示す．また, 図 5.5 に各トピックについて出力確率が上位 5 個の単語を示す．

図 5.4 において, 濃い緑色で塗られた市区町村 (単語) がその地域集合 (トピック) における高い出現確率を有していることを意味する．すなわち, その地域集合の中でも代表的な市区町村であることを意味する．上位出現単語を確認することで, 各トピックがどのような意味を持つトピックであるのかを解釈することが可能である．例えば, トピック 0 においては足立区や

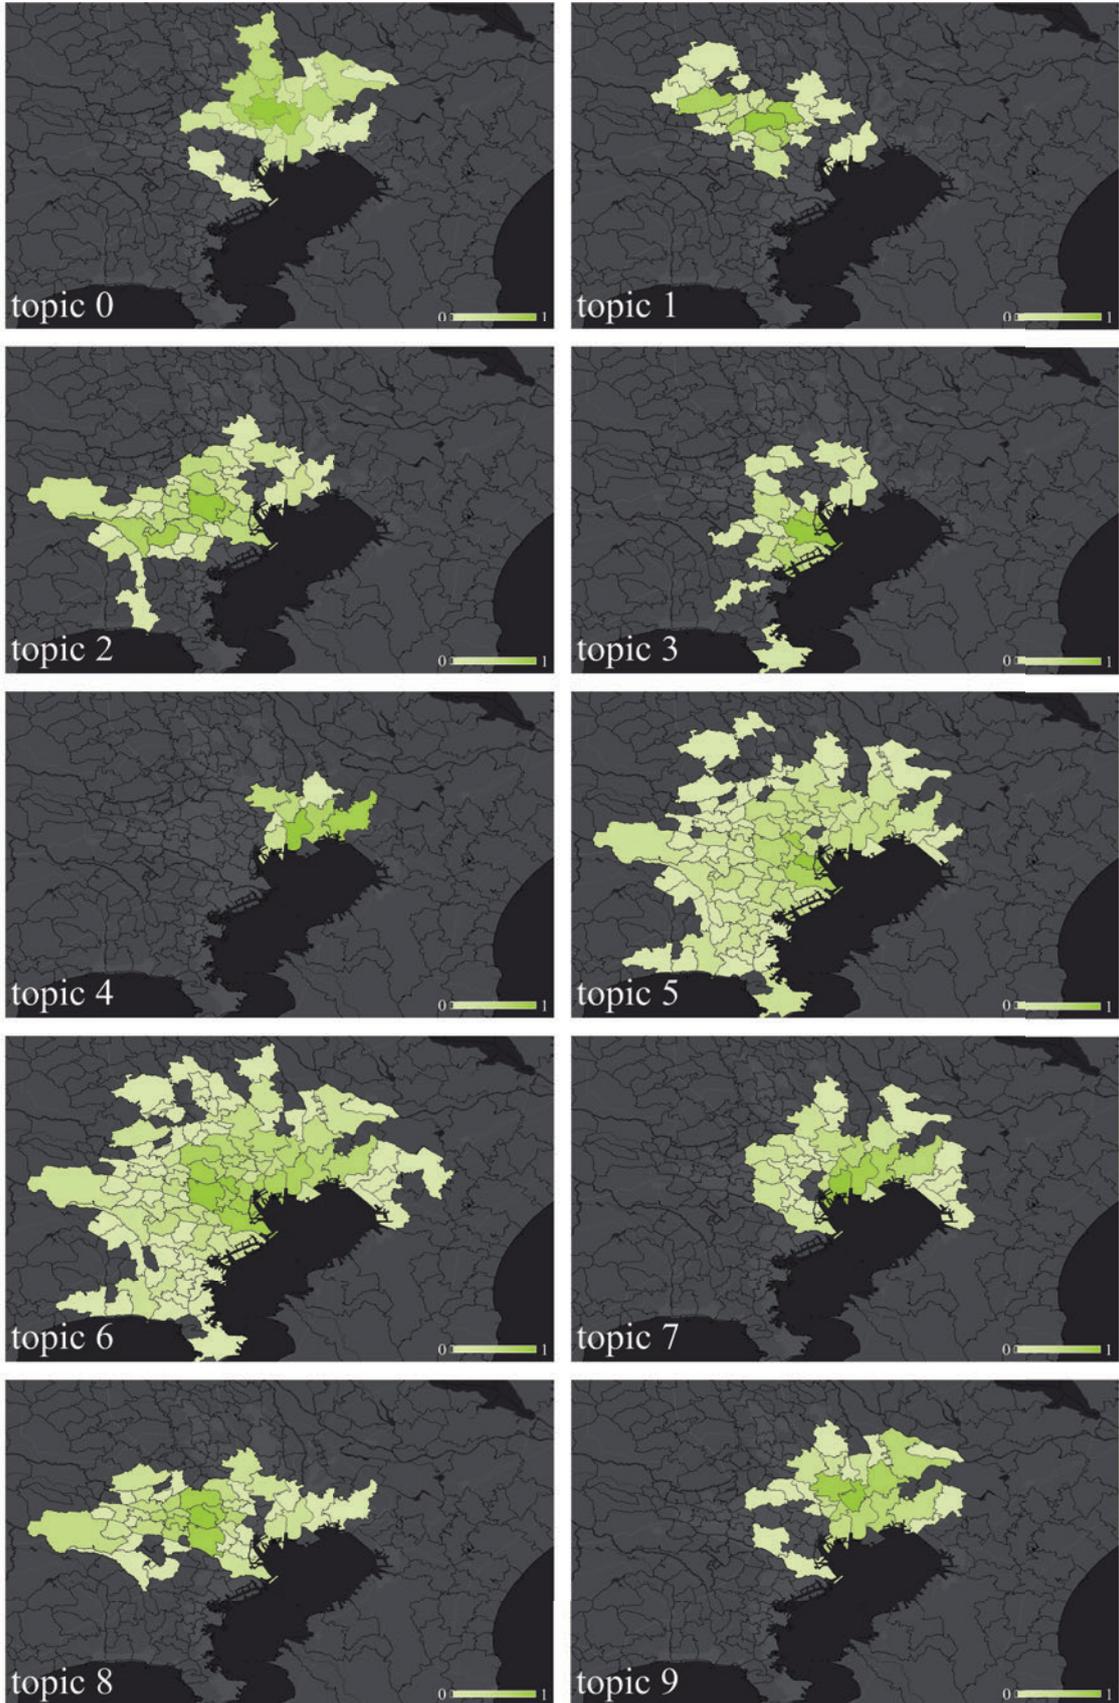


図 5.4. 推定された地域集合の可視化結果

トピック0	トピック1	トピック2	トピック3	トピック4
足立区	練馬区	世田谷区	大田区	江戸川区
葛飾区	板橋区	目黒区	品川区	船橋市
草加市	西東京市	横浜市青葉区	横浜市鶴見区	市川市
北区	中野区	町田市	川崎市川崎区	足立区
荒川区	所沢市	杉並区	世田谷区	葛飾区

トピック5	トピック6	トピック7	トピック8	トピック9
品川区	渋谷区	江東区	杉並区	葛飾区
渋谷区	世田谷区	江戸川区	中野区	足立区
大田区	品川区	墨田区	練馬区	松戸市
世田谷区	大田区	市川市	世田谷区	江戸川区
目黒区	杉並区	船橋市	三鷹市	柏市

図 5.5. 各トピックにおける上位出単語

葛飾区，そして埼玉県草加市など，東京都心から見て北部に位置する市区町村が集まる地域集合である解釈できる．また，トピック 1 では練馬区，板橋区，西東京市などの北西部に位置する地域集合であると考えられる．トピック 2 では世田谷区や目黒区，横浜市青葉区などを含む南西部側地域，トピック 3 では大田区や品川区，横浜市鶴見区などの南部側地域などに相当する．それ以降の主要トピックにおいても，都心から見て同一の方向に存在する地方が同じトピックに集中する様子が確認された．一方，57 番目以降のマイナーなトピックに関しては，日本全域に単語出現分布が広がっているなど，地理的に顕著な傾向は見られなかった．そのため，主要なトピックとして抽出された 56 個のトピックが地理的にみて有意なトピックであると考えられる．ここで，あるトピック内でもともに高い出現確率を有する関係にある市区町村は，その居住者の滞在先や移動先に共起性があるということである．これらの推定結果を用いることで移動情報を基にした地域の分類を行うことが可能となると考える．

#### トピック分布を用いたメッシュ潜在状態の推定

次に，上記の地域集合がどの時間のメッシュへと影響しているかを分析する．すなわち，各文書におけるトピック分布  $\pi_d$  側からの分析である．ただしこの分析においても，全メッシュ全時刻について全トピック分布を確認することは困難である．ここでは，足立区や葛飾区などを含む北側地域を表すトピック 0 と，東京 23 区の中でも渋谷区や世田谷区など南西側地域を表すトピック 6 に着目して考察を進めることとする．この 2 つのトピックに着目する理由としては，後述するように，この 2 つの地域集合がメッシュへと影響する様子には明確な違いがあるためである．

まず図 5.6 に示すのは，午前 4 時から午後 7 時までの 3 時間ごとのトピック 6 の重み，すなわち，この地域集合からの来訪者による影響度合いをメッシュ毎に可視化したものである．濃

い青色のメッシュほどトピック 6 の重みが大きいことを表している。また、背景の白黒の濃淡は図 5.4 におけるトピック 6 と同一のものであり、明るい市区町村ほど単語分布中の出現確率が高いことを示している。この地域集合からの来訪者が与える影響の様子を確認していくと、午前 4 時台における分布では、トピック 6 の影響度ほとんど存在しなかった。午前 7 時台では渋谷区、千代田区および中央区に含まれるメッシュへ影響が確認できる。そして午前 10 時台、午後 1 時台、午後 4 時台では上記 3 区内のメッシュを中心として 23 区全体においてトピック 6 の発現が確認され、午後 7 時ではその影響範囲は狭まっている。これらの結果より、渋谷区や世田谷区方面の在住者が、通勤によって主に渋谷区、千代田区および中央区の滞在者として日中の時間帯において影響したと考えられる。

トピック 6 に着目した場合は通勤によるメッシュへの影響度の伝搬が明確に表れたが、一方でトピック 0 に着目した場合にはそのような伝搬は確認されなかった。図 5.7 に示すのは、トピック 0 の重みを同様に可視化したものである。濃い赤色のメッシュほどトピック 0 の重みが大きいことを表している。この結果では、すべての時間帯において、足立区や葛飾区を中心とするトピック 0 の影響のほとんどは足立区に集中していることが確認できる。日中の時間帯のみならず深夜・早朝においても、トピック 0 の最上位単語である足立区内のメッシュに集中している。なお、トピック 0 以外の複数のトピックにおいても、そのトピックの上位単語である市区町村内のメッシュでのみトピックが発現している現象が確認された。このようにある特定の区にのみ影響を及ぼす地域集合が推定された理由として、メッシュ内に多く存在する居住者の影響が考えられる。今回推定に用いたデータにおいて、メッシュ外からの滞在者とメッシュ内の居住者の区別は行わずにトピックモデルの推定を行った。特に住宅地ではメッシュ滞在者の多くは、そのメッシュ居住者が占めることが予想される。そのため、これらの地域集合では同一メッシュや同一区内への移動・滞在が多くを占めているものであると推察される。一方で上述したトピック 6 は千代田区や中央区などオフィス街を中心としたメッシュに影響を強く及ぼすトピックであったため、メッシュ居住者の影響を受けることなく通勤による来訪者の影響の伝搬を可視化することができたのだと考えられる。

## 考察

500m メッシュのモバイル空間統計に対して本手法を適用したところ、地理的に集中した市区町村が同じ単語分布に集中する様子が確認された。今回の実験において、各単語間、すなわち居住地である市区町村間の距離や近接性などの情報は与えていない。あるトピック内でともに高い出現確率を有する関係にある市区町村は、その居住者の滞在先や移動先に共起性があるということである。さらに、メッシュ毎にトピック毎の影響度合いがどれくらい強いかを時間別に知ることができる。従って、市区町村レベルでの OD 情報に基づく分析よりも、より詳細な移動情報をもとにした人口特性把握となると考えられる。特に本実験では 500m メッシュ人口データを用いているため、より細かな移動情報に基づくある地域集合からの潜在的な交通需要を発掘などが期待される。

なお本分析では、滞在先と居住先が一致する、すなわち自宅に滞在しているのみでトリップを起こしていない人の位置情報が含まれている。特に早朝深夜帯において他の地域からの来訪

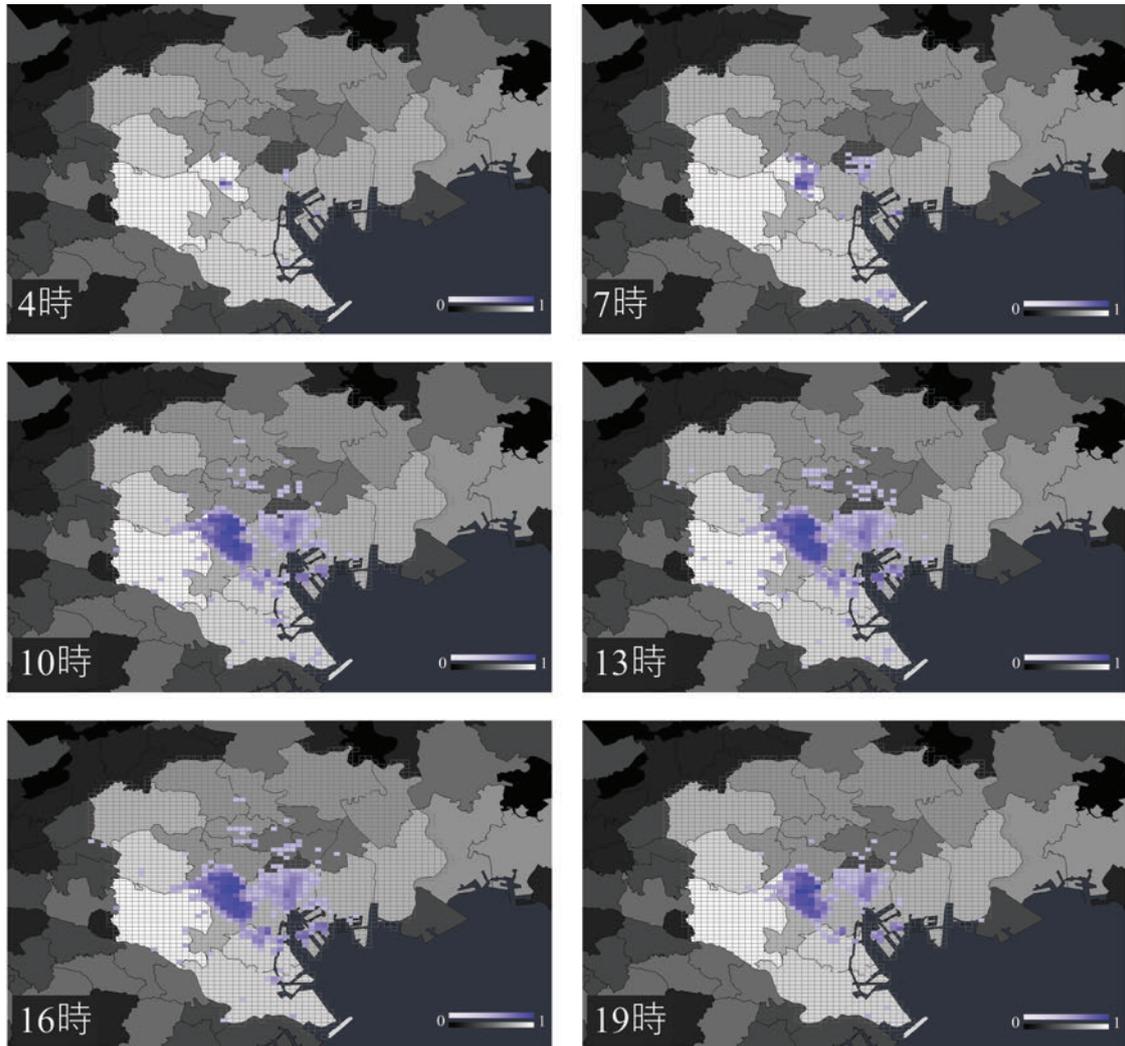


図 5.6. 対象エリアにおける西側地域からの来訪者による影響度の可視化結果

者が存在しない場合には、当該メッシュはただ一つの居住地情報のみを有することとなる。そのため、複数のトピックが混合しているとの仮定を置くトピックモデルにおいて、このような文書の存在は、他の時間帯におけるトピック分布の推定に対しても影響を与えることとなる。特に移動情報をもとに上述の交通需要発掘を行おうとする場合には、改善すべき課題である。そのためには、夜間人口に関する情報やモバイル空間統計データに含まれる町丁目レベルの居住者情報を用いることで、トリップを起こしていない人を文書から排除するなどの対策が考えられる。また、HDP-LDA によって自動的なトピック数の推定が実施できたが、今回の結果における 56 個の主要トピックおよび 24 時間分すべてについて上記の分析を行うことは困難である。ハイパーパラメータの調整によって生成されるトピック数の制限を加えるなどの検討が必要である。さらに、前述したとおり居住地とは別の観測情報として人数そのものをモデル出力として組み込み、複数の単語分布を許容できる Multiple-Source Latent-Topic[125] など

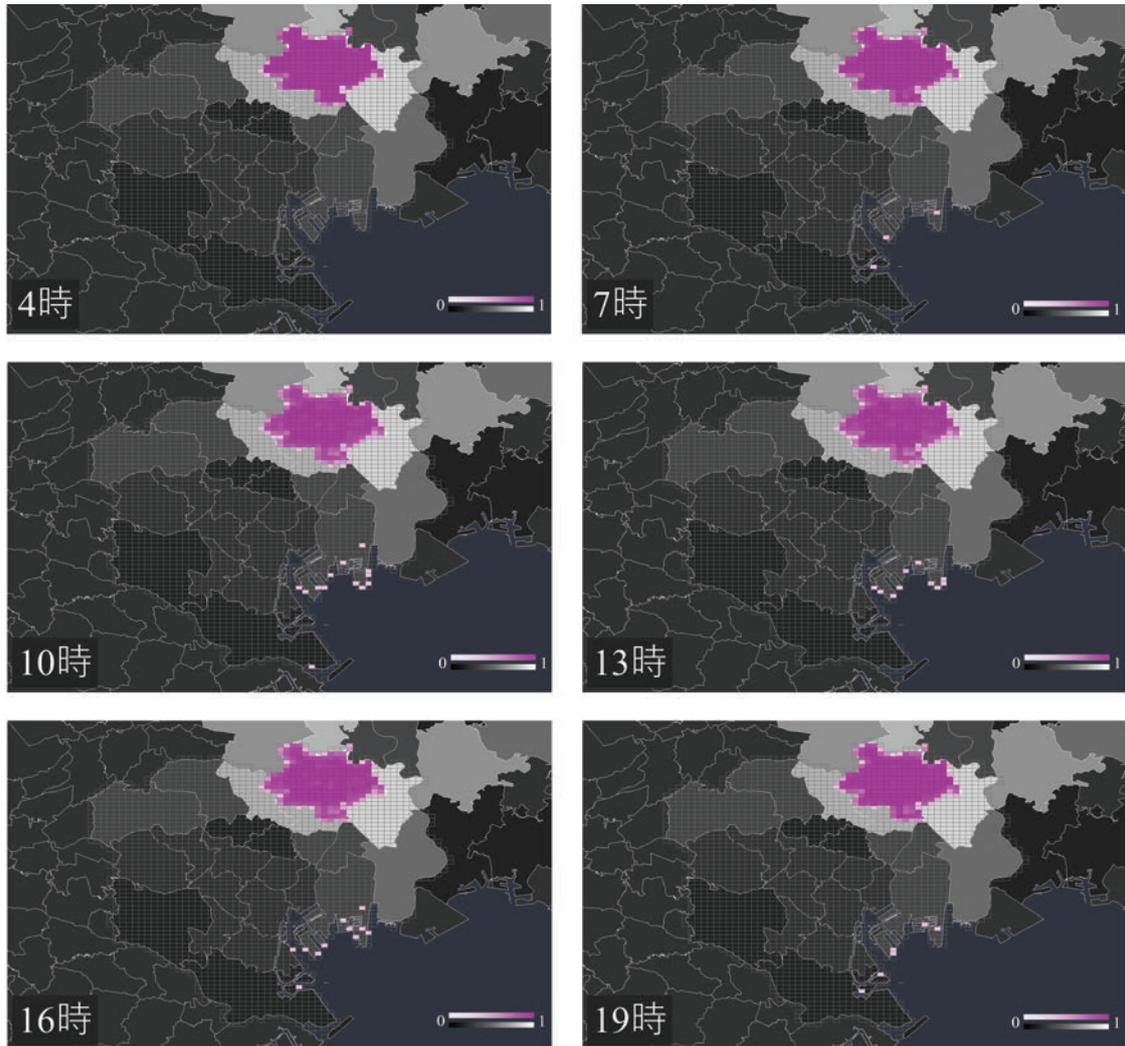


図 5.7. 対象エリアにおける南西地域からの来訪者による影響度の可視化結果

参考にモデル拡張を行うことも今後の課題である。

## 5.4 トピックモデルを用いた変化検出手法の提案

次に、トピックモデルを用いた変化検出手法を提案し、その手法の検証および検出された変化の潜在的意味解釈を行う。

### 5.4.1 変化検出手法の提案と検証

#### 変化検出手法の概要

提案手法は以下の 3 つのステップによって構成される。はじめに、教師データのトピック分布  $\pi_d$ 、単語分布  $\varphi_k$  およびグローバルトピック分布  $\beta$  を推定する (ステップ 1)。次に、学習

した HDP-LDA を用いて、比較対象である検証データのトピック分布  $\pi'_d$  を推定する (ステップ 2). なおステップ 2 では HDP-LDA に関するパラメータ, すなわち単語分布  $\varphi_k$  およびグローバルトピック分布  $\beta$ , ハイパーパラメータ  $\alpha$  は変更しない. 最後に, 二つのトピック分布  $\pi_d, \pi'_d$  を乖離度を測定することにより変化を検出する (ステップ 3). 乖離度の測定には, 第 4 章にて用いた  $L^2$  距離や, トピックモデルで頻繁に用いられるコサイン類似度の逆数を用いる方法などが挙げられる.

この手法 (以下, LDA 手法) は第 4 章の sHDP-HMM を利用した統計変化検出手法 (以下, HMM 手法) と同様のステップを踏んでいる. なおステップ 3 にて, HMM 手法では潜在変数  $z_t$  の比較によって変化を検出しているのに対し, LDA 手法ではトピック分布  $\pi_d$  の比較によって変化を検出している点で異なる. 前者の HMM 手法は観測値ごとに変化を考えるのに対し, 後者では観測値集合を与える文書ごとに変化を考えることに相当する. 人口動態データ上の解釈としては, どちらも各時刻・各メッシュで変化を考える点で共通した概念を持つ手法であるといえる. ただし HMM 手法は人口値の変動や時系列振る舞いに着目しているのに対し, LDA 手法は人口構成の変化に着目して変化検出を行うものである.

### 使用するデータ

教師データには 2014 年 10 月平日の平均値を表す約 500m メッシュのモバイル空間統計データを使用した. これまでの実験で用いていたデータと同様のものである. 一方, 比較対象である検証データとして 2015 年 6 月平日平均値を表すモバイル空間統計データを使用する. 対象範囲は第 4.4.2 章にて変化検出実験を行った千代田区などの計 214 メッシュである.

ここで, 両実験において学習データの対象エリアが異なっている点に注意されたい. 第 4.4.2 章における変化検出では, 学習データと検証データともに 214 メッシュから構成されるデータを使用した. これは, sHDP-HMM によって推定される潜在状態が過度に増加し, 変化が過剰に検出されるのを防ぐためである. 一方, HDP-LDA を用いる本実験では, 学習データは東京 23 区内の全 2607 メッシュであり, 検証データは比較対象エリアの 214 メッシュである. 学習データに 214 メッシュのみのデータを用いた場合, そのメッシュに滞在する人の居住地にはそこまで大きな違いはないと想定される. そのため文書に含まれる単語頻度の違いが少なくなり, 推定されるトピック間の違いを解釈することが困難になると考えられる. ゆえにトピックモデルを用いる本手法では, 東京 23 区全域のデータを用いてパラメータ推定を行い, その後検証データと共通するメッシュのみを取り出してトピック分布の比較を行うこととする.

### 実験結果と考察

これまでの実験にて学習した HDP-LDA を用いて, 検証データとして 214 メッシュ  $\times$  24 時間 = 5,136 文書のトピック分布の推定を行った. その後,  $L^2$  距離を用いて各文書間の乖離度を計算した. 図 5.8 にその結果を示す. 横軸が時刻であり, 縦軸がメッシュ番号を昇順に並べたメッシュ, 各セルの明度が乖離度を表す. その結果, メッシュ番号 533936403, 533936504, 533936902, 533936904 の 4 メッシュにて深夜～朝の時間におけるトピック分布の乖離度が特に大きく計算された. また, メッシュ番号 533936724 にて日中の時間帯でトピック分布の乖

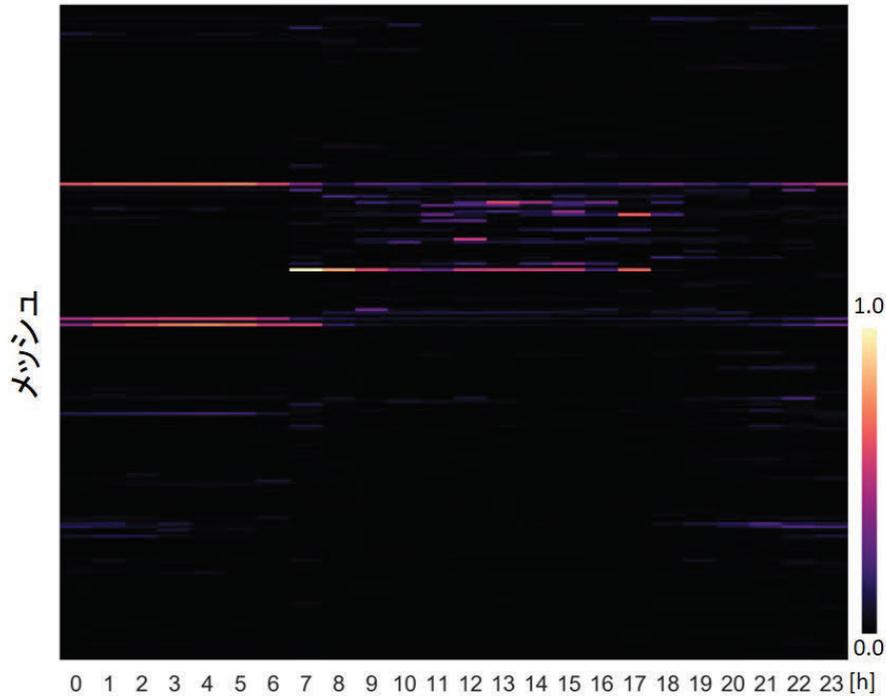


図 5.8. トピック分布の乖離度に着目した変化検出結果

離度が高く計算された。

この結果を HMM 手法による変化検出 (図 4.16 など) と比較する。HMM 手法では複数の時刻・メッシュにて変化が検出されていたのに対し、LDA 手法ではほとんど変化は検出されなかった。メッシュ人口値の差分計算結果 (図 4.17) を確認すると、二つのデータ間には朝 9 時以降に比較的大きな差分が存在している。観測値にメッシュ人口値と増減率を設定した HMM 手法では、上記の差分の影響を受けた結果、多くの変化が検出されたと考えられる。また、HMM 手法では一つの観測値に対して一つの潜在状態を推定して変化検出を行うため、観測データのノイズや少しの変化に対して状態推定および変化検出が敏感であると考えられる。一方、LDA 手法ではメッシュ人口値に関する情報は利用しないため、メッシュ人口値の差分の存在は変化検出結果に影響を及ぼさない。メッシュ滞在者の居住地構造が変化したときなど、人口値の変化よりもメタな構造変化への変化抽出に有効な手法であると示唆される。また、LDA 手法では複数の観測値集合としての「文書」に対して推定されるトピック分布を用いて変化検出を行うため、観測値のノイズや微小変化に対しては過度に反応しにくい手法であると考えられる。

次に、変化が検出されたこれらメッシュにおいて、具体的にどのトピックからどのトピックへと変化したことによる影響であるのか、変化内容の解釈を実施する。メッシュ番号 533936403, 533936504 および 533936724 はそれぞれりんかい線天王洲アイル駅、品川ふ頭およびゆりかもめ線市場前駅周辺の臨海部であった。メッシュ滞在者も他のメッシュと比較すると極端に少ないことから、この 3 メッシュについては分析対象からは除外する。一方でメッシュ番号

533936902(以下, メッシュ A) および 533936904(メッシュ B) は新橋駅・汐留駅を含む南北に連続したメッシュである. そこでこれらの 2 メッシュに対してトピック分布に着目した変化の解釈を行う.

図 5.9 に示すのは, 当該 2 メッシュについて 2014 年 10 月 (教師データ) と 2015 年 6 月 (検証データ) の 24 時間分の文書に対して推定されたトピック分布である. 各図において横軸が時刻, 縦軸が確率密度であり, 各トピックの重みを積み上げ面グラフで色別に表している. また, 各トピックの内容についてそれぞれの上位単語を示しており, others とは凡例に含まれないトピックを集計したものである. メッシュ A の 2014 年 10 月データに関して見ると, 深夜早朝の時間では主にトピック 28 およびトピック 40 の 2 つが支配的であることが分かる. 同メッシュの日中の時間帯ではトピック 6, トピック 11, トピック 22 そしてトピック 40 によってトピック分布が構成されている. 同様にメッシュ B の同年データでは, 深夜早朝の時間ではトピック 40 がやや支配的なトピックであり, 日中ではトピック 6, 11 の 2 つが分布の過半数を占めている.

対して 2015 年 6 月のデータから推定されたトピック分布を確認すると, いずれのメッシュにおいてもトピック 40 の構成比率がほぼ無くなり, トピック 22 およびトピック 28 構成比率が増加していることが分かる. ここで, 構成比率が減少したトピック 40 とは中央区や江東区, 江戸川区など, 該当メッシュが位置する地域よりも東側の市区町村を中心とするものである. 一方で構成比率が増加したトピック 22 とトピック 28 はいずれも港区を筆頭とする地域集合であり, 該当メッシュの新橋・汐留は港区内に位置する. この変化が特に深夜早朝の時間帯に強く表れているということは, 2014 年 10 月から 2015 年 6 月にかけて, 該当メッシュ内に居住する夜間人口の増加という人口動態の変化が発生したのではないかと推察される. 今後, 当該メッシュ内においてタワーマンション建設などが行われていないかなど, 上記変化内容の原因を確認し, 手法の妥当性を評価することが必要である. また, 新規交通路線の開設や都市再開発の前後など, 明らかに人口動態に変化があったと考えられるデータへの分析・適用も期待される.

#### 5.4.2 人口動態の変化検出手法の更なる発展に向けた議論

第 4 章では sHDP-HMM によって推定される潜在状態の比較に基づく統計的变化検出手法を構築した. 時系列モデリングを行うことで時系列データとしてのメッシュ人口分布データの 1 日における時系列遷移を表現することができ, 時系列的振る舞いにおける変化点の検出を行うことができた. ただし推定された潜在状態の意味解釈, および検出された変化の特徴や原因を知ることは困難であった. モデル出力に設定した観測変数はメッシュ人口値およびその増減率だけであり, 結局, 変化内容の解釈は人口値の乖離によって説明するしかなかった.

この問題に対し, 第 5 章ではトピックモデルによって人口動態の潜在的意味解釈を行った. この手法ではメッシュ毎に推定される潜在状態について, メッシュ滞在者の居住地など設定した単語情報に基づいて意味解釈を行うことが可能であった. また, このモデリング方法を用いてトピック分布の比較に基づく変化検出手法を提案し, その適用可能性の検証を行った. その

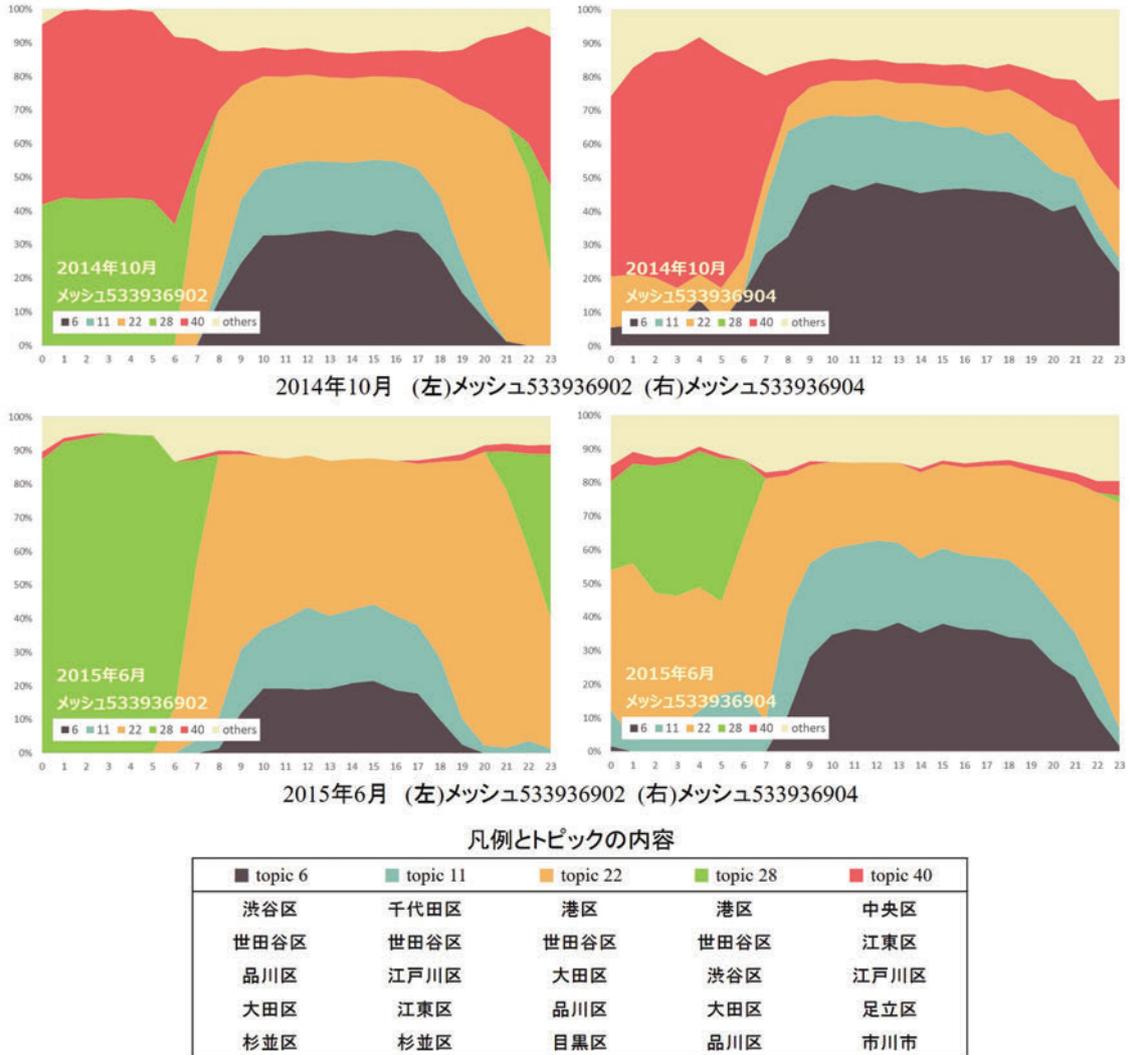


図 5.9. トピック分布の変化内容の可視化結果

結果，検出された変化をトピック分布上の変化分で把握できるため，どのトピックからどのトピックへと変化したことによる影響であるのか，変化内容の解釈を行うことが可能であった。トピックモデルを利用した変化検出手法への発展可能性が明らかとなった。

ただし，人口動態の変化検出手法の更なる発展に向けて，次の点を解決する必要がある。まず，時系列表現の再確保である。図 5.10 に HMM 手法と LDA 手法のグラフィカルモデルをそれぞれ示した。グラフィカルモデルからも分かるように，HMM 手法では同一メッシュ内での時系列遷移がモデル化されていたのに対し，LDA 手法では時系列性が構造から欠落している。時系列データであるメッシュ人口分布データをから変化点を検出するうえでは，時系列モデリングが必須であると考えられる。そのため，Dynamic topic model[122] や Topics over time[123]，Topic tracking model[124] など時系列トピックモデルを基盤に，本モデルを拡張することが必要である。なお，これらのモデルでは時系列性の表現方法が異なるが，HMM 手

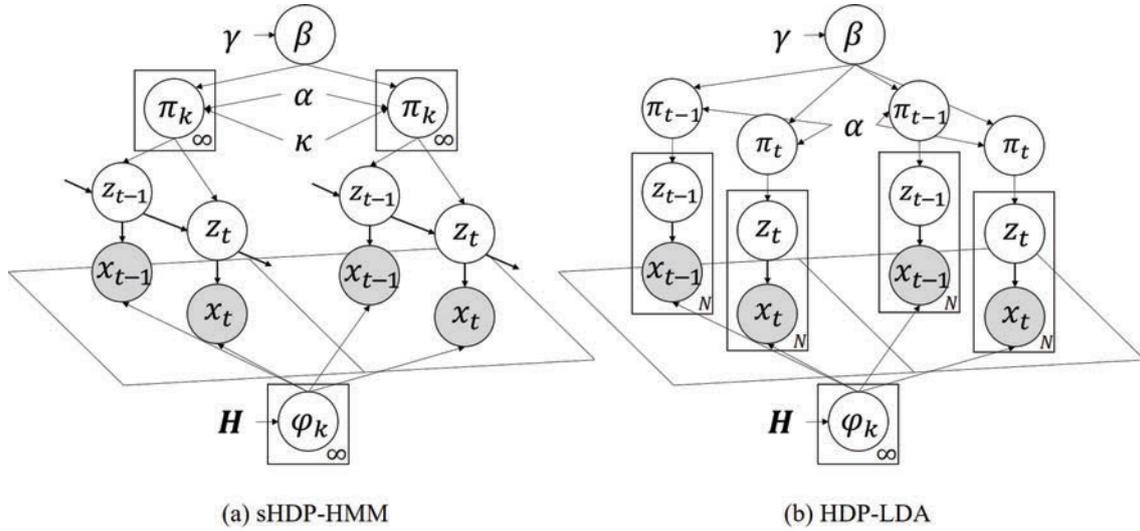


図 5.10. HMM 手法と LDA 手法のグラフィカルモデルの比較

法にてメッシュ潜在状態が時系列遷移すると表現したことを踏まえれば，トピック分布  $\pi$  に時間遷移を考慮した Topic tracking model との親和性が比較的大きいと考えられる。

さらに，時系列性の考慮と同様に，空間方向に対するモデル拡張も望まれる．隣接するメッシュ間や交通ネットワークで密につながった地域間では人口動態に相関および相互影響が存在しており，潜在状態間にも相関や相互影響が含まれていると考えられるためである．モデルによってその影響を表現する場合は，位置に関する補助変数を導入する，トピック分布のサンプリング  $\pi_d \sim \beta$  過程において隣接するメッシュとの相関を考慮できるようハイパーパラメータをさらに階層化させるなどアプローチ方法が挙げられる．また，異なる空間分解能のメッシュ人口データに対して本手法を適用し，階層クラスタリングの枠組みを利用することによって，複数分解能での潜在状態に関する情報を保有できる機構を構築するなどのアプローチ方法も考えられる。

また，LDA 手法ではメッシュに存在する人口値そのものをモデルに組み込むことができていない．HMM 手法では人口値の増加・減少を原因とした変化が複数検出されていたが，一方で LDA 手法では人口値の変化をトピック分布上の変化として検出されていなかった．地域別の来訪者数の割合が全く同じメッシュであってもメッシュに存在する人数が異なれば，それらのメッシュが持つトピックや潜在状態は異なるものと考えられる．そのためには，居住地とは別の観測情報として人数そのものをモデル出力として組み込む必要がある．さらに今後のデータ取得可能性の高まりから，交通量データや鉄道利用データなど，交通状況を表す多様なデータを統合することも考えられる．また，道路総延長や商業施設数など，静的な地理情報データを追加することで人口動態の精緻化につながるとも考えられる．この考えのもとでは，複数の単語分布を許容できる Multiple-Source Latent-Topic[125]などを基盤に，複数データ統合のためのモデル拡張を行うこととなる。

そして，上記モデル拡張のアプローチについて，トピック数・潜在状態数の自動推定が可能

な枠組みを構築しなければならない。つまり、階層ディリクレ過程および時空間系列モデリング、複数データ統合について理論統合を行う必要がある。生成モデルの定式化、学習方法の構築、そしてモデル実装が人口動態の変化検出手法の更なる発展に向けた課題である。

上述のモデル拡張を行ったうえで人口動態の変化検出手法の更なる発展が実現できれば、人口動態の変化点を検出し、その原因・要因を解釈可能な形で推定することができる。都市開発や新規交通サービスのアウトカム、および社会的イベントのインパクトを知ることができ、人口動態メカニズムの解明に資する手法たると考える。また、トピックモデルに基づいた変化検出手法そのものの新規性も大きい。この手法は人口動態分析以外の分野へも適用することが可能であり、多種多様なデータが取得される多岐にわたる分野への波及効果も大きいと期待される。そのため本論文で構築した隠れマルコフモデルおよびトピックモデルによる変化検出手法は、上記の観点からはまだ限定的なものではあるが、上記モデル拡張に向けた重要かつ基礎的な検証と位置づけられる。

## 第6章

# 結論

### 6.1 本研究の成果

本論文では、メッシュ人口データによる人口動態の変化検出に向けた潜在状態の推定を実施した。隠れマルコフモデルとトピックモデルに基づくモデリングを行うとともに、変化検出問題への適用と潜在状態の意味解釈を行い、提案手法の有用性を確認した。具体的な成果を以下に示す。

#### 6.1.1 人口動態の潜在状態を推定する枠組みの整理と基本モデルの検証

潜在状態の推定手法の基本となる状態空間モデルに着目し、そのモデルについてメッシュ人口データへの適用に向けた課題を整理した。まず、システムモデルや観測モデルを利用する一般状態空間モデルを利用したデータ同化的アプローチの検証を行った。人の動きを表すシミュレーションモデルとメッシュ人口データとの同化を行うことで、潜在状態として人物位置の推定が可能となり、再現性の高い時間帯別 OD 表やカテゴリ別・目的別ゾーン滞留人口等の推計も可能となることを確認した。一方で、このようなデータ同化的アプローチのためには適切なシステムモデルおよび観測モデルの設定が必須であり、本論文で想定する人口動態の潜在状態推定への本アプローチ方法の適用は困難であることが明らかとなった。

次に、既存シミュレーションモデルによらないデータ指向な方法として隠れマルコフモデルの適用可能性の検証を行った。潜在変数に離散変数を置き、その時系列遷移を学習可能な隠れマルコフモデルを基本モデルとして、人口動態のモデリングが可能であることを確認した。ただしメッシュ人口の潜在状態の推定および視覚化への適用を通じ、状態数を事前に設定する必要があること、および推定される潜在状態の解釈が困難であることが課題であることが分かった。

そしてこれら二つの検証を通じ、本論文において対象とする人口動態の潜在的状態推定のための課題の抽出と、モデル拡張方針を整理した。

### 6.1.2 人口動態に対する変化検出手法の構築

上述のモデル拡張方針に従い、状態数を自動的に推定可能な階層ディリクレ過程隠れマルコフモデルに基づいた変化検出手法を構築した。構築した手法は、事故・災害による交通渋滞の影響で生じた人口増加・減少や交通需要の変化等から生じるメッシュ人口値の推移パターンの変動等、時系列中の変化点を検出するものである。具体的には、平常時のメッシュ人口時系列から平常状態およびモデルパラメータを学習し、そのモデルを用いて検証用メッシュ人口時系列の潜在状態を推定した上で変化スコアを算出する手法である。また、そのモデルをメッシュ人口データへと適用するにあたり、データの設定方法やメッシュ間での潜在状態の共有化方法などについて理論的に整理した。

次に、構築した提案手法をシミュレーションデータへと適用し、その適用可能性の検証を行った。従来手法として、最も典型的な手法の1つである隠れマルコフモデルを比較対象とした精度検証を実施した。その結果、潜在状態の事後分布の乖離度を計算する手法を用いることで、従来手法よりも高い検出率および精度を達成することを確認した。

そして短期間・狭領域および長期間・広領域の2種類の実データへと提案手法を適用した。前者への適用では運転見合わせや朝夕の通勤ラッシュに影響とするメッシュ人口の短期的な異常が発生していたことが示唆され、後者での実験では人口構成や通勤・通学形態の違いが存在していたことが示唆された。ただし、いずれの適用においても想定以上の変化を検出してしまいうなどの実用に向けての課題を確認した。

### 6.1.3 人口動態の潜在的意味解釈

推定された潜在状態の意味解釈を容易にすることを念頭に、自然言語の分野でよく用いられるトピックモデルによるアプローチを実施した。状態数の事前設定の問題を解消するため、階層ベイズ法を導入したトピックモデルとしてモデルの構築を行い、人口動態の状態推定を行った。人口動態をトピックモデルとして捉えるため、他分野における事例を収集・整理し、メッシュ人口データでの変数設定方法を検討した。その結果、各時刻における各メッシュを一つの文書、そのメッシュ内に存在する滞在者の居住地を一つの単語、「ある地域集合からの来訪者が潜在的に多い」などといった潜在的な構造としての人口特性をトピックして扱うこととした。

実データに対して提案手法を適用し、分析結果の考察を行い、推定された地域集合およびその地域集合がメッシュに与える影響について分析・考察した。潜在状態の構成要素となる各トピックに着目すると、地理的に集中した居住地情報が同じトピックに集中する様子が確認された。詳細な移動情報をもとにした人口特性把握に資することが示唆された。

さらに、トピック分布の比較に基づく変化検出手法を提案し、その手法の検証および検出された変化の潜在的意味解釈を行った。この手法ではメッシュ毎に推定される潜在状態について、メッシュ滞在者の居住地など設定した単語情報に基づいて意味解釈を行うことが可能であることが分かった。どのトピックからどのトピックへと変化したことによる影響であるのか、

変化内容の解釈を行うことが可能であるため、トピックモデルを利用した変化検出手法への適用可能性が明らかとなった。

#### 6.1.4 人口動態の変化検出手法の更なる発展に向けた検討

最後に、人口動態の変化検出に向けた課題について整理し、克服のためのモデル拡張方法について議論した。特に、上述の隠れマルコフモデルおよびトピックモデルによる変化検出について、これまでの実験・検証結果を比較することによって、手法に求められる要件に関する示唆を得た。

上述のモデル拡張を行ったうえで人口動態の変化検出手法の更なる発展が実現できれば、人口動態の変化点を検出し、その原因・要因を解釈可能な形で推定することができる。都市開発や新規交通サービスのアウトカム、および社会的イベントのインパクトを知ることができ、人口動態メカニズムの解明に資する手法だと考える。また、トピックモデルに基づいた変化検出手法そのものの新規性も大きい。この手法は人口動態分析以外の分野へも適用することが可能であり、多種多様なデータが取得される多岐にわたる分野への波及効果も大きいと期待される。そのため本論文で構築した隠れマルコフモデルおよびトピックモデルによる変化検出手法は、人口動態の変化検出の観点からはまだ限定的なものではあるが、上記モデル拡張に向けた重要かつ基礎的な検証と位置づけられる。

## 6.2 今後の課題と展望

本研究は上に述べたとおり一定の成果を得たものの、さらなる検討および議論が必要な課題が残る。今後の課題および展望について以下に示す。

### 6.2.1 状態推定手法のさらなる性能向上

本研究で構築した潜在状態推定手法について、以下に挙げる事項の観点から手法の洗練を行っていく必要がある。

#### 変化検出の精度向上

シミュレーションによる検証では、提案手法は30%弱の割合で誤検出が発生することが確認された。ゆえに実データの実験にて検出された異常や変化も同程度の割合で誤検出を含んでいるものと想定される。精度向上・誤検出削減に向けた方針として、複数日にわたるデータから日間変動の学習を行うこと、および24時から1時への連続性を確保することなどが考えられる。そのためにはこれらの学習機構を組み込んだモデルの開発を行うとともに、複数日にわたる大規模なデータを用いた検証を実施する必要がある。

### 変化検出における出力分布の検討

潜在状態の推定を行う上で、変化検出への適用では観測ベクトルに人口値と増減率を設定した。正規化したデータを用いる場合や、桁合わせを行う場合など入力するデータ形式の違いにより、潜在状態の推定結果が異なる可能性が考えられる。観測ベクトルの設定方法について詳細な検討を行う必要がある。

### 潜在的意味解釈における単語設定の検討

潜在的意味解釈を行う上で市区町村レベルの居住地を単語として使用した。モバイル空間統計データには都道府県および町丁目レベルでの居住地情報が含まれているため、これらの異なる分解能を持つ単語を用いた場合に推定されるトピックにどのような違いがあるのかを確認する必要がある。また、本分析では滞在先と居住先が一致する、すなわち自宅に滞在しているのみでトリップを起こしていない人の位置情報が含まれている。特に早朝深夜帯において他の地域からの来訪者が存在しない場合には、当該メッシュはただ一つの居住地情報のみを有することとなる。そのため、複数のトピックが混合しているとの仮定を置くトピックモデルにおいて、このような文書の存在は、他の時間帯におけるトピック分布の推定に対しても影響を与えることとなる。特に移動情報をもとに上述の交通需要発掘を行おうとする場合には、改善すべき課題である。そのためには、夜間人口に関する情報やモバイル空間統計データに含まれる町丁目レベルの居住者情報を用いることで、トリップを起こしていない人を文書から排除するなどの対策が考えられる。

### ハイパーパラメータの検討

階層ディリクレ過程を導入する上でハイパーパラメータは事前に設定する、もしくはデータの分布より適切な値を設定する必要がある。ハイパーパラメータの設定の違いによって推定される潜在状態の比較が必要である。特に、HDP-LDAによる自動トピック数を推定では、45個もの主要トピックが生成された。ハイパーパラメータの調整によって生成されるトピック数の制限を加えるなどの検討を行うこととなる。

### 潜在状態推定における安定性の確保

隠れマルコフモデルによる実験では、事後分布のサンプリングの過程において推定された潜在状態が頻繁に変化している様子が確認された。また、トピックモデルによる実験ではオンライン型変分ベイズ法を用いたため、学習時のパラメータやデータの学習順序によって推定結果が異なる様子が確認された。今後、モデルの拡張を通じてより大規模なデータや複数種類のデータの統合を行うことを考慮すると、推定される潜在状態の安定性の確保が望まれる。上述した通り、複数日にわたるデータからの日間変動の学習や、出力分布の検討、およびハイパーパラメータの検討を行うことによって、潜在状態推定における安定性の確保が実現できると考えられる。

### 多様な実データ適用を通じた状態解釈の妥当性の評価

隠れマルコフモデルによる変化検出の検証実験では列車運休による影響と思われる異常状態が推定された。一方で、トピックモデルによる変化検出の検証実験ではその考察の妥当性の評価を行うことができていない。今後、当該メッシュ内においてタワーマンション建設などが行われていないかなど、変化内容の原因を確認し、手法の妥当性を評価することが必要である。また、新規交通路線の開設や都市再開発の前後など、明らかに人口動態に変化があったと考えられるデータへの分析・適用も期待される。目に見える変化が顕著に存在しているデータへの適用を通じて、その顕在的变化が潜在的変化としてどのように表現されているのかを確認することで、状態解釈の妥当性の評価や、モデル理解の深化につながると考えられる。

### 6.2.2 潜在的意味解釈に基づく変化検出に向けた理論構築

潜在状態推定手法について洗練化を行った後、潜在的意味解釈に基づく変化検出手法への拡張によって、人口動態の変化検出に向けた更なる発展が望まれる。具体的には以下の点について理論構築をはじめとする検討を行っていかなければならない。

#### 時系列表現の確保

トピックモデルに基づく変化検出手法を基に、人口動態の変化検出に向けた更なる手法の発展を実現するためには、まず時系列表現の確保を行う必要がある。時系列データであるメッシュ人口データから変化や異常を検出するうえでは、時系列モデリングが必須であると考えられる。トピック分布に時間遷移を考慮した Topic tracking modelなどを参考に、モデル拡張を行うことが可能である。

#### 空間方向における相互関係の表現

空間方向に対するモデル拡張も考える必要がある。隣接するメッシュ間や交通ネットワークで密につながった地域間では人口動態に相関および相互影響が存在しており、潜在状態間にも相関や相互影響が含まれていると考えられるためである。モデルによってその影響を表現する場合は、位置に関する補助変数を導入する、トピック分布のサンプリング過程において隣接するメッシュとの相関を考慮できるようハイパーパラメータをさらに階層化させるなどアプローチ方法が挙げられる。また、異なる空間分解能のメッシュ人口データに対して本手法を適用し、階層クラスタリングの枠組みを利用することによって、複数分解能での潜在状態に関する情報を保有できる機構を構築するなどのアプローチ方法も考えられる。複数のアプローチ方法において適切なモデル表現の検証や推定の安定性・実現性の確保などにも着目する。

#### 出力構造の拡張によるデータ統合

地域別の来訪者数の割合が全く同じメッシュであってもメッシュに存在する人数が異なれば、それらのメッシュが持つトピックや潜在状態は異なるものと考えられる。これを考慮する

ためには、居住地とは別の観測情報として人数そのものをモデル出力として組み込む必要がある。さらに、将来的なデータ取得可能性の高まりから、交通量データや鉄道利用データなど、交通状況を表す多様なデータを統合することも考えられる。また、道路総延長や商業施設数など、静的な地理情報データを追加することで人口動態モデリングの精緻化につながるとも考えられる。この考えのもとでは、複数の単語分布を許容できる Multiple-Source Latent-Topicなどを基盤に、複数データ統合のためのモデル拡張を行うこととなる。

### 階層ディリクレ過程の枠組み下での理論統合

以上述べた、時系列表現の確保、空間方向の相互関係の表現、およびデータ統合について、階層ディリクレ過程による状態数の自動推定機構の枠組み下で、理論統合を行う必要がある。モデル構造が複雑になるため、学習理論の構築および推定の安定性の確保が課題である。

### 異なる時空間分解能での状態推定結果の比較

今回の適用では約 500m 四方のメッシュを対象としたが、地域によって人口密度は異なるため、もしくは検出対象とする異常の種類に応じて着目すべき空間分解能も異なると考えられる。特に今回適用した 500m メッシュでは人口動態の変動が激しく、ノイズに多く影響されてしまった可能性があり、異なるメッシュサイズのデータに対する分析も進める必要がある。さらに、階層クラスタリングに基づく考えの下、異なる時空間分解能データ間の連続性の表現を実現することが望まれる。

### 大規模データに対する状態推定手法の拡張性の確保

提案手法の実用を考えた場合、長期間(数日~数か月)かつ広範囲(東京~関東)における人口動態を記録した大規模データへの適用が求められる。状態推定や事後分布計算過程における安定性の確保が求められる。また、大規模データを扱うためのオンライン推定機構の構築など、ビッグデータ解析技術の援用が求められる。

## 6.2.3 今後の展望

最後に、本論文の成果および提案手法の拡張・実用化によってもたらされる今後の展望について示す。

### 移動に関する社会メカニズムの解明に向けた貢献

潜在状態の推定を異なる時空間分解能で行い、それぞれの階層で推定された潜在状態を解釈することで、マクロな人口動態とミクロ人口動態の相互作用を分析することができると考えられる。単位空間での状態が都市全体に与える影響や、逆に都市全体の状態が単位空間に与える影響を議論できる下地が整うことで、他の交通データとの統合も行った上で移動に関する社会メカニズムの解明に資すると考える。

### 交通施策の評価や新規交通サービスの創発

交通施策や新規交通サービスの規模やインパクトの評価は難しく、現在はその利用者数やその変化に着目せざるを得ない。本研究が提案する、潜在状態の推定に基づく変化検出は交通サービスへの評価に用いることができると考えられる。短期的な視点では開催されたイベントがもたらした人口動態や人の動きへのインパクトの評価、そして長期的な視点では交通インフラの新設による人口動態の変化検出などである。

### 提案手法の他分野への応用

提案手法における人口動態の状態推定手法は、メッシュ人口データ以外のデータに対しても適用することのできる汎用的なものである。また、単位空間にメッシュ以外を設定することも容易である。そのため、提案手法を用いることで任意のデータセットに対して任意の集計単位を設定した分析を行うことが可能となる。国土変遷の把握・分析やネットワーク通信のモニタリング、消費エネルギーのマネジメントなど、多岐にわたる分野に対して提案手法を応用可能性をはらんでいる。

## 付録 A

# 空中写真からの車両認識

### A.1 はじめに

交通データをいかに漏れなく広範囲を取得するかという観点では、衛星画像や航空写真からの車両位置を特定することで非集計観測を行うという方法も考えられる。広域を瞬時に観測できる航空写真や衛星画像などの空中写真は、都市計画や環境調査、災害被害把握など多岐にわたる目的に活用されてきた。近年では無人航空機 (UAV: Unmanned Aerial Vehicle) や超小型衛星の普及も伴い、大量の空中写真を取得できる環境が整いつつある。将来的には、航空写真や衛星画像など複数リソースを複合的に利用することにより、空間分解能・時間分解能を補完する観測システムの実現が期待される。ただし大量に取得される画像に対して交通量観測を行うためには、画像認識技術による車両認識の自動化が必須である。

画像から物体認識を行うため、物体検知とクラス分類を組み合わせた手法が広く普及している。物体検知とは、物体が存在すると推測される領域を画像中から抽出する技術であり、前処理として行うことで計算コストの改善や精度向上が見込まれる。また、クラス分類とは抽出された領域が何の物体であるのかを判断する技術であり、近年の深層学習技術の発展により精度が飛躍的に向上している。

空中写真からの車両認識に関して、前述の物体認識手法に基づく手法がこれまでに複数提案されている [126][127][128][129][130]。しかし、これらの適用は駐車場や空港などの地域や見通しの良い幹線道路を対象とした画像に限定されている。市街地や都市部を対象とした交通モニタリングが特に重要であると考えられるものの、市街地では建物の存在や影の影響によって車両認識は特に困難となることが予想される。そこで本章では市街地における空中写真を対象に、車両認識手法の適用可能性を検証する。

### A.2 使用する空中写真

#### A.2.1 市街地における航空写真および衛星画像

本章で使用する航空写真は東京都板橋区を撮影したものであり、詳細な仕様は表 A.1 の通りである (アジア航測株式会社提供)。衛星画像には商業用高分解能衛星 WorldView-3 によっ

表 A.1. 航空写真の仕様

使用カメラ	デジタル航空カメラ (DMC)
対地高度	730m
焦点距離	120mm
地上分解能	7.3cm

表 A.2. 衛星画像の仕様

被雲率	0%
太陽高度	30°
オフナディア角	7.04°
製品レベル	オルソレディ (OR2A)
地上分解能	31cm
ビット深長	11bit/8bit
バンド	3ch(Blue, Green, Red)

て取得されたパンシャープン画像を使用する。なお Kamiya ら [131] による衛星画像への物体検知手法の適用可能性の検証結果を元に、衛星画像のチャンネル数を RGB の 3ch ビット深長を 8bit に加工したものをを用いる。東京都渋谷区などの画像であり詳細な仕様は表 A.2 の通りである。

## A.2.2 VEDAI データセット

前節での市街地における航空写真および衛星画像以外に、本研究では VEDAI (Vehicle Detection in Aerial Imagery) データセットを使用する。VEDAI データセットとは、Utah AGRC (Automated Geographic Reference Center) が提供する地上分解能 12.5cm の HRO 2012 6 inch Ortho photography の画像中に映り込む車両位置を Razakarivony ら [132] が整理し、ベンチマークデータセットとして公開しているもので、住宅地や駐車場、草地など多様な地域を対象とした画像である。さらに、写真に映り込む車両として plane, boat, camping car, car, pick-up, tractor, truck, van, other の全 9 種類の車両クラスが分類されている。

## A.2.3 学習データセットの作成

上述した航空写真、衛星画像および VEDAI データセットの画像内に映り込む車両の位置を整理し、学習データセットを作成する。PASCAL VOC[133] の物体位置定義に従い、bounding box と呼ばれる、物体をちょうど囲う矩形を画像中の車両毎に設定した。矩形設定においては自作した画像編集ツールを用いて、各デジタル画像中の車両座標値を取得した。最終的に、35 枚の航空写真から 1,166 車両、49 枚の衛星画像から 3,009 車両、1,271 枚の VEDAI データセットから 3,757 車両を取得した。なお、VEDAI データセットに関しては、plane, boat 以

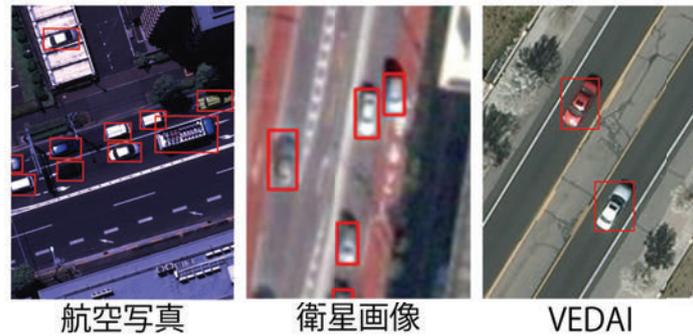


図 A.1. データセットの例

表 A.3. データセット別の画像仕様

	航空写真	衛星写真	VEDAI
画像枚数 [枚]	35	49	1,271
画像サイズ [pix × pix]	1920 × 1536	924 × 724	1024 × 1024
車両総数 [台]	1,166	3,009	3,757
1枚あたりの車両台数 [台]	33.3	61.4	3.0
車両平均サイズ [pix × pix]	約 70 × 70	約 20 × 20	約 50 × 50

外の計 7 つの車両クラスを使用した。また、VEDAI データセット中ですでに定義されている車両の 4 隅の座標情報を用いて、bounding box となる矩形を再定義した。図 A.1 に作成した学習データセットの例を示す。それぞれの画像中で赤い矩形で示されているのが「車両」を表す領域である。また、表 A.3 に学習データセット別の画像仕様を示す。

### A.3 車両認識手法の設計

本研究における提案手法は、入力された空中写真中において物体が存在すると推定される提案領域を抽出する物体検知と、各提案領域に対してその物体が車両であるかを判断するクラス分類に大別される。提案手法では物体検知に BING(binarized normed gradient) 手法 [134] を、クラス分類に畳み込みニューラルネットワーク (CNN: Convolutional Neural Network) モデルをそれぞれ利用する。

#### A.3.1 BING による物体検知

空中写真に対して物体検知手法を適用する場合、画像サイズが大きく計算コストが高い、画像中の車両の向きが様々である、大気によるゆがみやノイズの影響を受けやすいなどの課題に対応する必要がある。そこで本研究では、高速な解析が可能であり、かつ画像中の物体の向きや画像のゆらぎに対して頑健である [135]BING 手法を利用する。BING 手法とは、画像中の一般的な物体同士は NG(normed gradient) 特徴量およびそのバイナリ近似を施した BING

特徴量に相関があることを利用して、物体が含まれる矩形領域を画像中から提案する手法である。

物体領域の提案を行うにはまず、勾配画像を計算し、様々な形にリサイズした上で各サイズの画像  $i$  における任意の位置  $l$  にて NG 特徴量  $g_l$  を計算する。BING 手法における勾配画像の計算では、高速処理の実現のため、1次元の微分フィルタ  $[-1, 0, 1]$  を利用して  $x$  軸、 $y$  軸方向でそれぞれ  $g_x$ 、 $g_y$  を求め、 $\min(|g_x| + |g_y|, 255)$  をその画素における勾配値とする。また、NG 特徴量とは、ある画素を中心とする  $8 \times 8$  [pix  $\times$  pix] 小領域内の勾配値を並べた特徴量ベクトルである。次に、各 NG 特徴量と別途学習した重みベクトル  $w \in R^{64}$  の内積を計算し、フィルタスコア  $s_l$  を求める。

$$s_l = \langle w, g_l \rangle \quad (\text{A.1})$$

$$l = (i, x, y) \quad (\text{A.2})$$

ここで、 $(x, y)$  は画像内位置であり、 $\langle \rangle$  は内積を表す。

さらに、サイズ  $i$  毎に NMS(Non-Maximum Suppression) によって小領域を選定した後、重み  $v_i \in \mathbb{R}$  とバイアス  $t_i \in \mathbb{R}$  をパラメータとするモデルによって物体らしさを表すスコア  $o$  を計算し、高スコアを持つ領域を物体領域として提案する。

$$o_l = v_i \cdot s_l + t_i \quad (\text{A.3})$$

式 (A.1) の  $w$  および式 (A.3) の  $v_i, t_i$  の学習には、既知の物体領域を正例として、それ以外の領域からランダムに抽出した箇所を負例として線形 SVM(Support Vector Machine)[136] を利用する。

また、本手法では NG 特徴量  $g_l$  を上位  $N_g$  バイトで以下のように近似した BING 特徴量を利用する。

$$g_l \approx \sum_{k=1}^{N_g} 2^{8-k} b_{k,l} \quad (\text{A.4})$$

さらに、スコア計算の高速化のために線形モデル  $w$  を以下で近似する。

$$w \approx \sum_{j=1}^{N_w} \beta_j a_j \approx \sum_{j=1}^{N_w} \beta_j (a_j^+ - \overline{a_j^+}) \quad (\text{A.5})$$

ここで、 $a_j \in \{-1, 1\}^{64}$  は基底ベクトル、 $a_j^+ \in \{0, 1\}^{64}$  は二値ベクトル、 $N_w$  は基底ベクトルの数、 $\beta_j$  は重み係数である。すると、この近似によって式 (A.1) におけるフィルタスコアの計算を主にビット演算で代用できるため、手法全体を通じた高速化が実現される。

### A.3.2 CNN によるクラス分類

BING 手法によって抽出した各提案領域に対して、深層学習の一つである CNN を用いたクラス分類を行い、各提案画像が車両であるか否かを判断する。

本手法において構築したネットワークを図 A.2 に示す。図中の数値はネットワーク各層の次元数 (チャンネル数  $\times$  画像幅  $\times$  画像高さ) である。conv, max, norm, fc はそれぞれ畳み込み

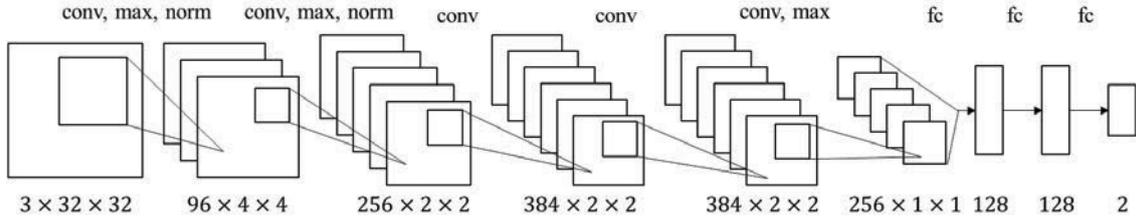


図 A.2. 構築した畳み込みニューラルネットワーク

層，最大プーリング層，バッチ正規化層，全結合層を表す．このネットワークは画像認識のタスクにおいて高い性能を誇る AlexNet[137] を参考にしており，主に 5 つの畳み込み層と 3 つの全結合層から構成されている．入力層は  $3 \times 32 \times 32$  [ch × pix × pix] であるため，BING による提案領域を  $32 \times 32$  [pix × pix] にリサイズした後，RGB 各チャンネル値をそれぞれ 255 で除して区間  $[0,1)$  に収まるように設定した値を入力する．ネットワークの出力層は「車両」と「車両以外」を表す 2 つのノードで構成されており，出力結果を元に車両か否かの判断を行う．最後に，車両と判断された領域同士 ( $A1$  および  $A2$ ) の重複面積率を以下の通り計算する．

$$\text{重複面積率} = \frac{A1 \cap A2}{A1 \cup A2} \quad (\text{A.6})$$

この値が閾値以上である場合にはそれらを重複とみなし，BING スコアの低い方の領域を削除する．本研究では近接の車両を分離するのに十分であり，かつ多くの重複を消去できると考えられる値として 15% を閾値として設定する．

## A.4 手法の適用と精度検証

前述の航空写真，衛星画像および VEDAI データセットに対し提案手法を適用し，その車両認識性能に関して比較する．なお，本研究では種類の異なる空中写真に対して独立して提案手法の適用可能性を検証するため，それぞれの空中写真において BING 手法と CNN のパラメータの学習を別々に行う．

### A.4.1 BING 手法の学習および車両検知率の検証

まず，十分な数の学習データセットの確保および検証データセットのバラツキの確保の観点から，各空中写真の約 8 割を学習用，残り約 2 割を検証用の画像として分割した．学習画像中の車両情報を用いて BING 手法のパラメータ  $w, v_i, t_i$  を学習し，検証画像に手法を適用した時の車両検知率を評価する．実装においては Cheng ら [134] が公開している C++ コードを利用した．また，このコード内には元画像のリサイズを制御するパラメータ，すなわちサイズの異なる画像  $i$  の集合を規定するパラメータとして base という変数が採用されている．本実験では検証を通じて，平均的な検知率が最良となる値として，航空写真では 2.0，衛星画像では 1.6，VEDAI では 1.2 に設定した．なお，より良い検知性能の実現のためには，RGB 空間，HSV 空間，グレースケールに変換した 3 種類の入力画像に対してそれぞれ BING 手法を

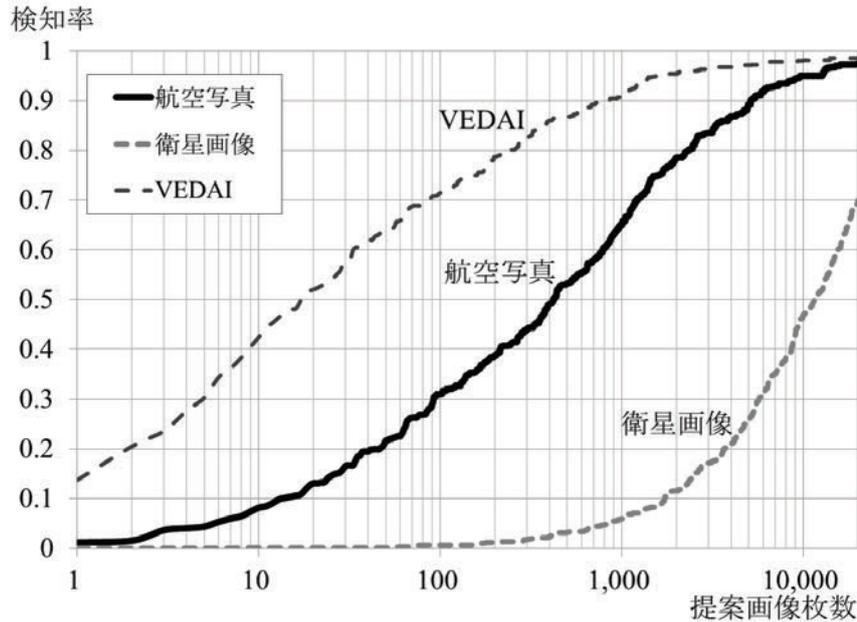


図 A.3. BING による車両検出率の比較

適用し、各出力結果を集計したものを最終的な出力とする方法が効果的であることが確認されている [134]。そこで本実験においても上記の方法を採用した。

図 A.3 に、学習済み BING 手法を適用した際の検証データセット別の車両検知率を示す。横軸に示す提案画像枚数とは、1 枚の空中写真に対して BING 手法が算出したスコア  $o_l$  を高い順に抽出した領域画像の数である。縦軸に示す検知率とは、1 枚の空中写真における車両検知率の平均値である。この結果より、VEDAI、航空写真、衛星画像の順で検知率が良いことが分かる。VEDAI データセットでは背景と車両の差が比較的明瞭であり、画像内に映り込む構造物も比較的少ないことが良好な結果に繋がったと考えられる。市街地を対象とする航空写真や衛星画像では画像内の構造物などを多く検知してしまい、検出率は VEDAI データセットに比べ低下した。

ただし表 A.3 に示す通り、3 種類のデータセットでは画像 1 枚あたりに含まれる車両台数が異なるため、上記の車両検知率では比較が困難となる可能性が考えられる。そこで、図 A.3 の横軸を 1 画像当たりの車両台数で除し、車両 1 台当たりの提案枚数に対する検知率へと補正した結果を図 A.4 に示す。車両 1 台当たりの提案枚数が 40 枚未満の場合では、VEDAI における検知率が最良であったが、40 枚を超えると VEDAI と航空写真が同程度の性能であることが分かった。一方で衛星画像は、他のデータセットと比較して検知率が低いままであった。衛星画像の場合は、車両と背景とのコントラストが小さかったため、勾配情報を元に物体検知を行う BING 手法が精度良く適用できなかつたと考えられる。

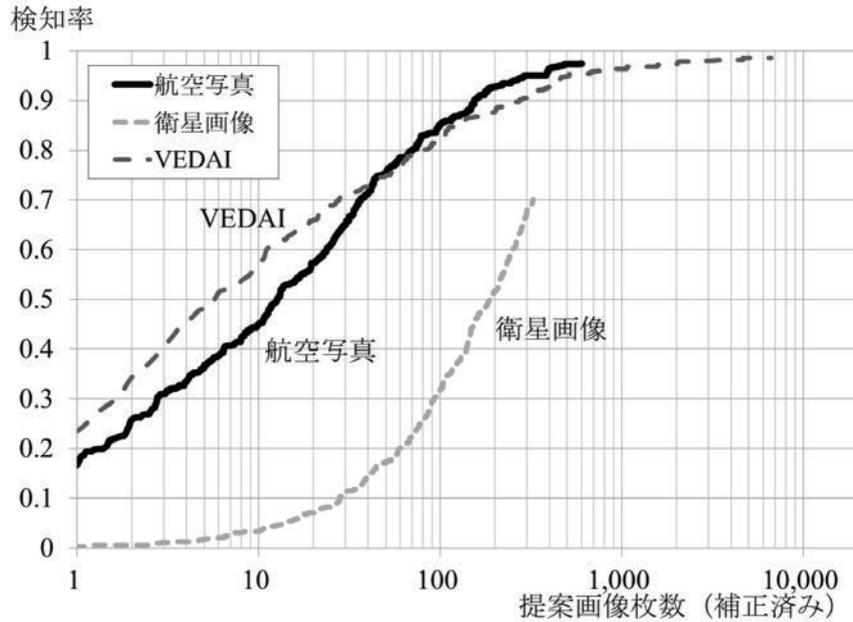


図 A.4. BING による車両検出率の比較 (補正済み)

表 A.4. CNN のクラス分類性能の比較

	航空写真	衛星写真	混合	VEDAI
Accuracy [%]	95.1	94.3	94.9	98.0

#### A.4.2 CNN の学習および分類精度の検証

前節と同様の学習データセット中から車両領域を抽出し、CNN モデルの学習に使用した。なお、モデルの汎化性能の向上のためデータ拡張 (data augmentation) を行い、学習に用いるデータ数を増加させた。具体的には、車両画像をそれぞれ  $\pm 60^\circ$ ,  $\pm 120^\circ$ ,  $180^\circ$  回転させたデータ、および、車両領域を 4 方向に平均移動させたデータである。データ拡張により、航空写真では約 9,000 台、衛星画像では約 24,000 台、VEDAI データセットでは約 30,000 台分の車両データを学習に用いたこととなる。また、「車両以外」を表すデータとして、データ拡張後の「車両」データと同様の枚数だけ空中写真中からランダムに取得した。パラメータをランダムに初期化し、最適化手法に Adam を利用して、100 画像を一つのミニバッチとした合計 100 エポックの学習を行った。実装においては Python 用深層学習ライブラリ Chainer を利用し、一部 CUDA-Convnet2 による GPU 演算を実施した。

表 A.4 に、検証データセット中の車両領域およびランダムに切り出した車両以外の領域に対して、学習済み CNN モデルを適用した際の正解率 (Accuracy) を示す。なお、正解率は以下で定義される統計量である。

$$Accuracy = \frac{\#TruePositives + \#TrueNegatives}{\#Data} \times 100\% \quad (A.7)$$

ここで、#True Positive (Negative) とは車両 (以外) データを車両 (以外) と認識できた数であり、#Data は各検証データの総数である。また、表中の「混合」とは、航空写真と衛星画像の 2 つの学習データセットから CNN モデルを学習して、衛星画像の検証データセットに適用した場合である。これにより車両認識が特に難しいと考えられる衛星画像に対して、複数リソースの組み合わせが認識性能の向上に寄与するかを検証する。

この結果より、いずれのデータセットにおいても正解率が 95% 前後、特に VEDAI データセットでは 98.0% と優れた分類性能を示していることが分かる。VEDAI データセットでは画像に移り込む構造物が比較的少ないため、「車両」と画像中からランダムで取得した「車両以外」が分類しやすかったことが、正解率が比較的高くなった理由の一つとして考えられる。

### A.4.3 提案手法の適用結果と車両認識性能の比較

前節までに学習した BING 手法のパラメータおよび CNN モデルを利用し、空中写真からの車両認識を行う。BING 手法による提案領域数を変化させた上で、それぞれの場合の車両検知率および精度を計算した。車両検知率 (Recall) とは画像中に映る車両の内、検知できた車両の割合であり、精度 (Precision) とは車両と判断した領域の内、実際に車両である領域の割合である。それぞれ、以下の通り計算される。

$$Recall = \frac{1}{\#image} \sum_i \frac{\#DetectedVehicles_i}{\#Vehicles_i} \times 100\% \quad (A.8)$$

$$Precision = \frac{1}{\#image} \sum_i \frac{\#TruePositive_i}{\#DetecedWindow_i} \times 100\% \quad (A.9)$$

ここで、#image とは各検証データセットにおける空中写真の枚数であり、 $i$  は各空中写真を示す。認識成功の判断基準として、検知された領域と検証データセット中の正解領域 (ground truth) の重複面積率 (式 (A.6)) が閾値 15% を超えた場合に、正しく車両領域を認識できたこととする。また、同一の車両を複数の領域で検知した場合、式 (A.8) の計算においては重複して計上することはなく、車両単位で集計する。一方で、式 (A.9) の計算の場合は重複を考慮せずに、検知された領域単位で精度を計算する。

表 A.5 に認識性能結果を示す。車両検知率に着目すると、VEDAI データセットへの適用では、BING 提案領域数が 100 枚と少ない場合でも車両検知率が 64.4%、20,000 枚の場合では 95.6% という高い検知率であった。一方、衛星画像への適用では、BING 提案領域数が 100 枚の場合、検出率は 0.6% であり、20,000 枚の場合でも検出率が 65.6% であった。航空写真や VEDAI データセットへの適用と比較して、衛星画像では検知率が低い結果となった。この結果は、図 4 に示す BING 手法による車両検出率と同様の傾向を有している。提案手法において高い車両検知率を実現するためには、BING 手法による車両検知と CNN モデルによるクラス分類の双方が高精度である必要があるが、表 A.4 に示す通りクラス分類性能はいずれのデータセットにおいても優れている。そのため、データセット間における BING 手法による検出性能の差が、車両検知率の性能差に直接的に結びついたと考えられる。従って、高い車両検知

表 A.5. 提案手法の認識性能の比較

	航空写真	衛星画像	混合	VEDAI
BING 提案領域数：100				[%]
Recall	28.9	0.6	0.6	64.4
Precision	28.1	5.3	5.0	40.0
BING 提案領域数：1,000				
Recall	57.5	5.8	6.3	83.4
Precision	13.2	7.0	5.8	30.4
BING 提案領域数：5,000				
Recall	78.9	29.7	31.7	88.6
Precision	110.8	6.1	5.3	26.5
BING 提案領域数：10,000				
Recall	83.8	45.8	51.9	91.3
Precision	10.2	5.2	5.0	24.6
BING 提案領域数：20,000				
Recall	85.9	65.6	70.0	95.6
Precision	9.8	5.3	5.1	21.3

率のためには、扱う空中写真に応じて適切な物体検知手法および提案領域数を確保する必要性が示唆される。

なお、航空写真と衛星画像を混合して学習させたモデルでは、衛星画像単体で学習させたモデルよりも車両検知率が上昇した。航空写真と衛星画像の双方の車両画像を学習データセットに利用したことで、多彩なパターンの車両に対する認識性能が向上したためと考えられる。車両認識が特に難しいと考えらえる衛星画像に対して、複数リソースの組み合わせが有効であることが示唆される。

一方、いずれのデータセットへの適用でも、BING 提案領域数が多くなるにつれ、誤検知も多く発生したことが原因となり精度が低下した。図 A.5 に示すのは航空写真に対して提案手法を適用した例であり、上段が元画像の一部に対して BING 手法を適用した結果である。下段が BING 手法による提案領域に対して CNN モデルを適用した結果、車両と認識された領域であり、赤い領域が認識成功、白い枠が誤検知を表す。画像中の車両が存在する領域以外にも、街区や道路自体を車両と認識してしまっていることが分かる。車両認識など大きなサイズの画像から数台～数十台の対象物を検知するというタスクの場合、提案領域数が数千枚～数万枚となると、その提案領域のほとんどは車両以外を指し示す画像となる。すると、CNN モデルのクラス分類性能こそ 95% 前後と高い場合であっても、誤分類が 5% 前後の割合で生じてしまうため、特に車両以外の領域を車両と認識するケースが数十枚～数百枚と存在することとなる。そのため、式 (A.9) における  $\#True\ Positive$  に対して  $\#Detected\ Window$  が大きくなっていくことが原因となり、精度が低下したと考えられる。ゆえに、誤検知を軽減して精

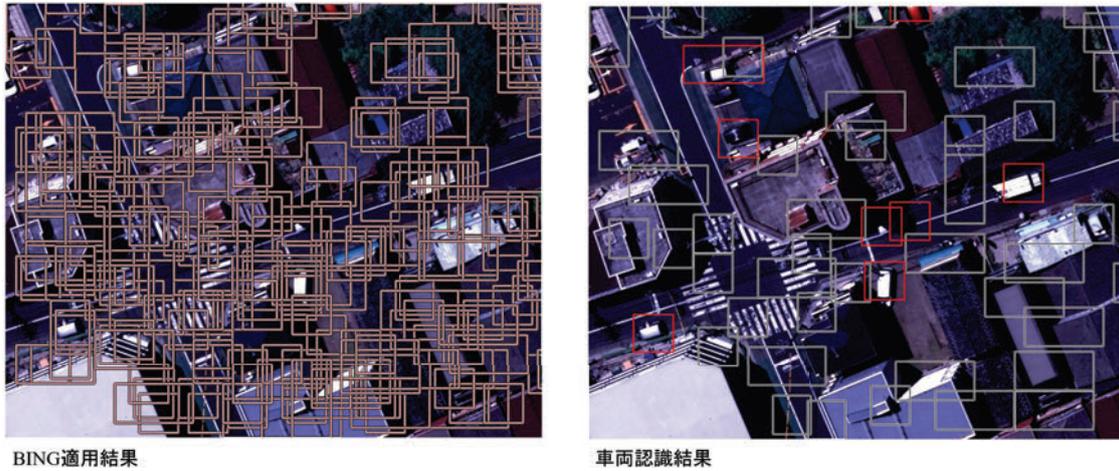


図 A.5. 提案した車両認識手法の適用例

度を向上させるためには、いかに高い検知率を確保しつつ提案領域数を低減できるかが重要であると考えられる。そのためには上記の検知率に関する議論と同様に、扱う空中写真に応じて適切な物体検知手法を扱う必要があると考えられる。

#### A.4.4 今後の課題

今後の課題として、BING 手法以外の物体検知手法を利用した場合の認識性能の比較検証が挙げられる。近年の画像認識分野では物体領域の抽出およびそのクラス分類を同一モデル内で行う深層学習手法が注目されており、Faster R-CNN[138] や YOLO[139]、SSD[140] などに代表されるような複数のモデルが開発されている。空中写真に対するこれらの手法の適用可能性も議論・検証する必要がある。さらに、本研究では RGB 画像のみを対象としていたが、IR 画像や SAR 画像など多様な画像に対しても適用可能性の検証を進める必要がある。これらの課題を克服し高精度で車両検知が可能となれば、広域を瞬時にかつサンプリング調査によらない交通データ取得手法としての活用が大きく期待される。

## 付録 B

# データ駆動型シミュレーションモデルの作成

### B.1 はじめに

人口動態の潜在状態推定をデータ同化の文脈で行う場合には、潜在状態の時系列遷移を表現するモデルが必要となる。特に、状態ベクトルに人の位置や速度、密度など多くの情報を設定し、多変量の状態ベクトルをもつ状態空間モデルを構築することができる点が、データ同化的なアプローチのメリットともいえる。ただしその場合、多種多様に存在するデータを考慮したシミュレーションモデルを構築することへの課題が残る。本章では、多種多様なデータが大量に存在していることを利用して、データ指向的にシミュレーションモデルを作成する方法について検討する。

メッシュ単位のシミュレーションモデル作成の上では、データの種類が異なればメッシュデータの生成過程が異なる点、同一のデータでも時間や場所によってメッシュ値のダイナミクスは大きく変動する点を考慮することが求められる。過去のメッシュ値が現在のメッシュ値に複雑に影響するためモデル構造の特定が容易ではなく、メッシュ値のダイナミクスの定式化が困難である。さらに、空間相関や冗長性、ノイズ等を考慮してシミュレーションモデル作成に有効な特徴量を抽出する必要がある。

そこで、多層パーセプトロン (multi-layer perceptron; MLP) と制約ボルツマンマシン (restricted Boltzmann machine; RBM) を組み合わせたシミュレーションモデル作成手法を提案する。ここで述べるシミュレーションモデルとは、ある時刻における対象地域内の全メッシュの観測値を入力とし、一時刻期先の全メッシュの観測値を予測するモデルである。MLP モデルのリッチな非線形性表現性により、時間帯や地域によって異なる人口分布の複雑なダイナミクスを学習することが可能となる。また RBM を用いることによって観測されたメッシュデータの背後に潜む有効な特徴量を自動的に見つけ出すことができると考えられる。

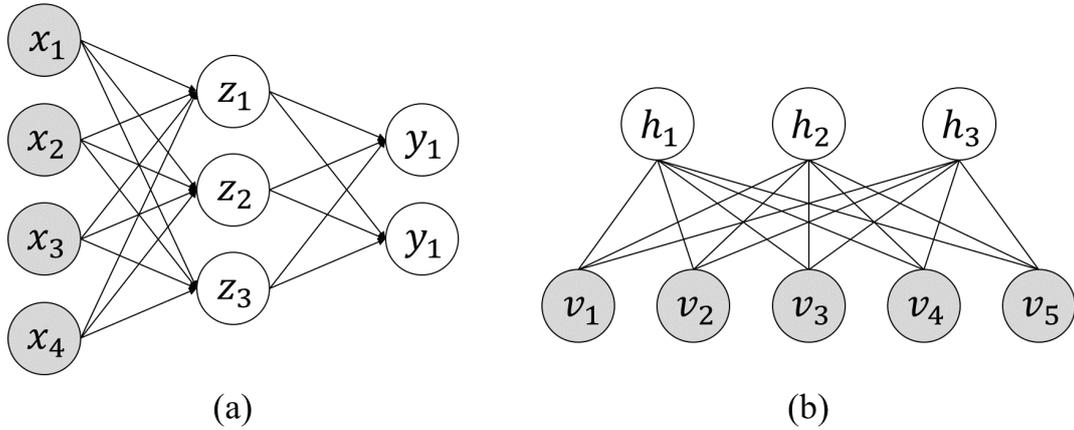


図 B.1. グラフィカルモデル. (a) 多層パーセプトロン, (b) 制約ボルツマンマシン

## B.2 提案手法の構築

MLP と RBM について概説した後、両者を組み合わせた提案手法を説明する。

### B.2.1 多層パーセプトロン

MLP はニューラルネットワークを多層にした構造で、前の層のユニットの出力が次の層のユニットの出力となって情報が層間を一方方向に伝播する。図 B.1(a) のように中間層を 1 つ持つ構造の MLP を考える。いま、 $d$  次元 (ここでは  $d = 4$  とする) 入力データ  $x = \{x_1, \dots, x_4\}$  が与えられたとき、中間層  $z$  と出力層  $y$  のユニットはそれぞれ以下の通り計算される。

$$z = f_1(W_1x + b_1,) \tag{B.1}$$

$$y = f_2(W_2z + b_2) \tag{B.2}$$

ここで、 $W$  は各層間の重み、 $b$  は各層のユニットのバイアスであり、これらのパラメータを全てまとめて  $w$  と表記する。また、 $f$  は活性化関数であり、シグモイド関数などが設定される。

MLP のパラメータ  $w$  の学習は、以下の誤差関数を最小化する  $w$  を求めることとなる。

$$E(\mathbf{w}) = \frac{1}{2} \sum_n \|y(x_n; w) - d_n\|^2 \tag{B.3}$$

ここで、 $x_n$  は訓練データであり、 $d_n$  は  $x_n$  に対する目標出力である。  $E(w)$  は一般に凸関数でなく、大域的な最小解を解析的に得るのは不可能であるため、誤差逆伝播法を用いた確率的勾配降下法 (stochastic gradient descent; SGD) によってパラメータの更新を行うこととなる。

## B.2.2 制約ボルツマンマシン

RBM とは、可視変数と隠れ変数をノードとする無向グラフであるボルツマンマシンのうち、可視変数と隠れ変数にのみ結合を有するモデルである。図 B.1(b) に示すのは RBM のグラフィカルモデルであり、可視変数  $v_i$  と隠れ変数  $h_i$  によってネットワークが定義される。可視変数は観測データに対応する確率変数であり、隠れ変数は可視変数とは別にネットワークの状態を支配する観測できない確率変数である。RBM は隠れ変数を用いることでデータの生成モデルをより良く表現できるとともに、グラフ制約を設けることでパラメータ推定の実現可能性が高いモデルである。提案手法では、この隠れ変数の集合を観測データの特徴量と捉える。なお、連続値であるメッシュデータに適用するにあたり、可視変数と隠れ変数がそれぞれ正規分布とベルヌーイ分布に従う Gaussian-Bernoulli RBM を利用する。

Gaussian-Bernoulli RBM ではエネルギー関数は以下のように定義される。

$$\Phi(\mathbf{v}, \mathbf{h}, \theta) = - \sum_i \frac{(v_i - a_i)^2}{2\sigma_i^2} - \sum_j b_j h_j - \sum_i \sum_j w_{ij} \frac{v_i}{\sigma_i} h_j \quad (\text{B.4})$$

ここで、 $a_i$ ,  $\sigma_i$ ,  $b_j$ ,  $w_{ij}$  はそれぞれ、可視変数が従う正規分布の平均、標準偏差、隠れ変数のバイアス、およびユニット間の結合の重みである。これらのパラメータをまとめて  $\theta$  と表す。式 (B.4) のエネルギー関数の式を用いることで、ネットワーク全体の同時確率分布は以下で与えられる。

$$p(\mathbf{v}, \mathbf{h} | \theta) = \frac{1}{Z(\theta)} \exp\{-\Phi(\mathbf{v}, \mathbf{h}, \theta)\} \quad (\text{B.5})$$

なお、 $Z(\theta)$  はモデル分布が確率分布の条件  $\sum_{\mathbf{z}} p(\mathbf{z} | \theta) = 1$  を満たすための規格化定数であり、分配関数と呼ばれる。また、隠れ変数を固定したときの可視変数の条件付き分布  $p(\mathbf{v} | \mathbf{h}, \theta)$ 、および可視変数を固定した時の隠れ変数の条件付き分布  $p(\mathbf{h} | \mathbf{v}, \theta)$  は以下のように求めることができる。

$$p(v_i | \mathbf{h}) = \frac{1}{\sqrt{2\pi}\sigma_i} \exp\left\{-\frac{(v_i - a_i - \sum_j w_{ij} h_j)^2}{2\sigma_i^2}\right\} \quad (\text{B.6})$$

$$p(h_j = 1 | \mathbf{v}, \theta) = \sigma\left(b_j + \sum_i w_{ij} \frac{v_i}{\sigma_i}\right) \quad (\text{B.7})$$

RBM のパラメータ学習には隠れ変数  $\mathbf{h}$  の周辺化を行った以下の対数尤度関数を用いた最尤推定法を行う。

$$\log L(\theta) = \sum_{n=1}^N p(\mathbf{v}_n | \theta) \propto \frac{1}{N} \sum_{n=1}^N \left[ \log \sum_{\mathbf{h}} \exp\{-\Phi(\mathbf{v}_n, \mathbf{h}, \theta)\} - \log Z(\theta) \right] \quad (\text{B.8})$$

この対数尤度を最大化するパラメーター  $\theta$  を解析的に求めるのは不可能であるため勾配上昇法

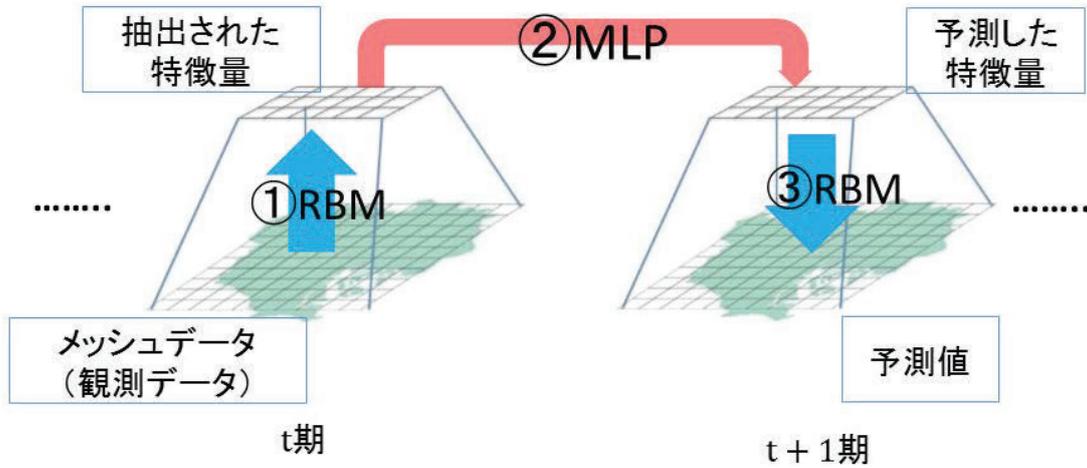


図 B.2. メッシュ単位のシミュレーションモデル作成手法の概要

を用いることとなる。以下の更新式に従いパラメータを更新していく。

$$\Delta w_{ij} = \epsilon \left( v_i^{(0)} p_j^{(0)} - \langle p_i^{(T)} p_j^{(T)} \rangle \right) \quad (\text{B.9a})$$

$$\Delta a_i = \epsilon \left( v_i^{(0)} - \langle p_i^{(T)} \rangle \right) \quad (\text{B.9b})$$

$$\Delta b_j = \epsilon \left( h_j^{(0)} - \langle p_j^{(T)} \rangle \right) \quad (\text{B.9c})$$

ここで、 $\epsilon$  は学習係数である。いずれのパラメータも更新式は  $\langle \cdot \rangle_{data}$  および  $\langle \cdot \rangle_{model}$  で構成されている。第1項  $\langle \cdot \rangle_{data}$  は学習データから求める。第2項の  $\langle \cdot \rangle_{model}$  は CD(contrastive divergence, コントラストティブダイバージェンス) もしくは P-CD(persistent CD, 持続的 CD) を用いて近似的に計算する。

### B.2.3 メッシュ単位のシミュレーションモデル作成手法

提案するメッシュ単位のシミュレーションモデル作成手法の概要を図 B.2 に示す。まず、RBM の可視変数に観測されたメッシュデータを入力し、隠れ変数の条件付分布  $p = p(h_j = 1 | \mathbf{v})$  の期待値を計算することでメッシュデータの特徴量を抽出する。次に、その特徴量を MLP に入力し、一時刻先の特徴量を予測する。そして、RBM 可視層の条件付分布  $p = p(v_i = 1 | \mathbf{h})$  の期待値を計算し、一時刻先のメッシュデータの予測値とする。

モデルの学習では、まず全ての時刻のデータを独立に扱った上で、メッシュデータの観測値を用いて RBM のパラメータ  $\theta$  の学習を行う。次に、学習済み RBM の隠れ変数条件付分布  $p = p(h_j = 1 | \mathbf{v})$  の期待値を計算し、メッシュデータの特徴量を抽出する。そしてその特徴量を MLP の学習データとして扱い、MLP のパラメータ  $w$  の学習を行う。

また、RBM の隠れユニットの数や MLP の中間層の数・中間層のユニット数といったモデルの構造に関する変数は可変である。一方、作成するシミュレーションモデルは、扱いやすさの観点から簡潔な記述であることが望ましい。そのため、可能な限り簡潔なモデルの構造かつ

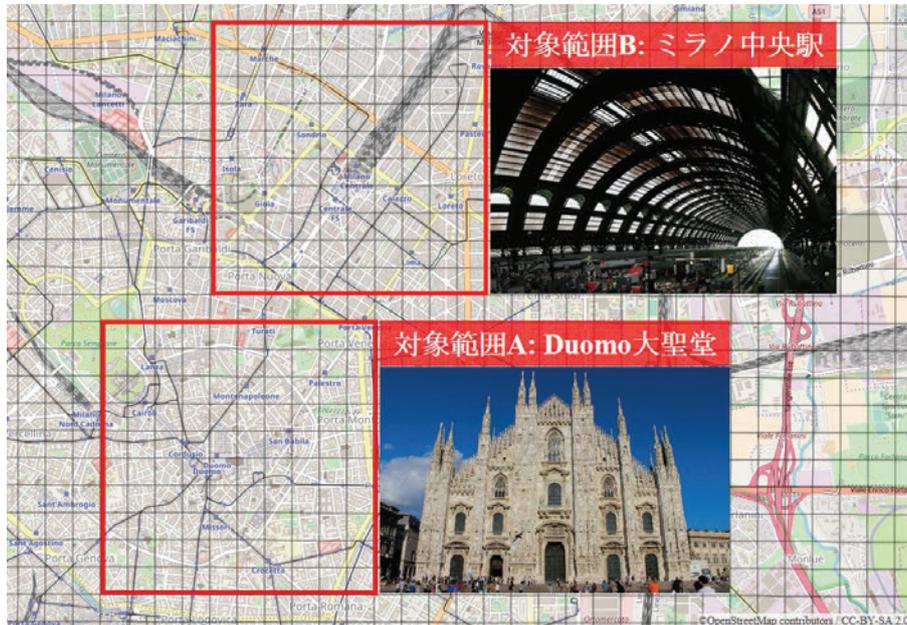


図 B.3. シミュレーションモデル作成の対象範囲

高い精度を担保するという観点から、適切にこれらの変数を検証する。

## B.3 適用と検証

### B.3.1 適用対象データ

適用対象のメッシュデータとして携帯電話会社 Telecom Italia が計測したミラノにおけるインターネット通信量のデータを使用した。これは、2013年11月から12月の2ヶ月間における携帯電話基地局情報 (Call Detail Records ; CDR) であり、ユーザの通信記録がメッシュごとに10分間隔で集計されている。2か月間に渡るデータが公開されているため、MLPやRBMの学習に用いるデータが十分に取得可能であると考えられる。

元データに含まれる対象エリアは、一辺235mの $100 \times 100$ のメッシュで構成された地域である。本検証ではこのエリアのうち、以下の2つの対象範囲A,Bを対象に検証を行うこととする(図B.3)。対象範囲Aは大聖堂Duomoを中心とするミラノの中心部の $10 \times 10$ メッシュである。スカラ座など他の観光スポットや、ファッションの店が並ぶモンテ・ナポレオーネ通りなどが存在する観光や商業が活発なエリアである。そして対象範囲BはMilano Centrale駅周辺の $10 \times 10$ メッシュである。Duomo地区から約2.5km北東に位置し、イタリア第2の乗降客数を誇る主要駅である。

本検証にて扱うシミュレーションモデルのタイムステップは1時間とする。そのため、10分間隔で集計されている元データを、0:00~1:00, 0:10~1:10, ..., 23:50~翌日0:50のように1時間ごとに再集計した。対象日時は元データのうち休日と年末(12月23日以降)を除く平日である。また、Gaussian Bernoulli RBMへの適用に当たり、観測データを平均0・分散1に

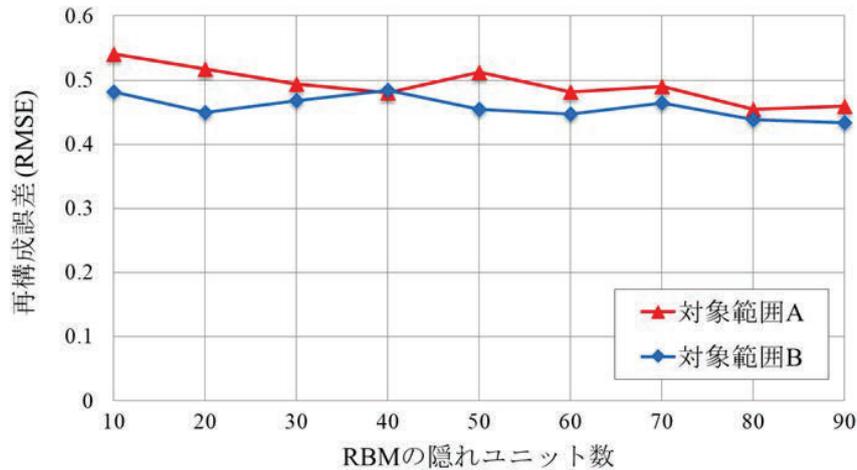


図 B.4. 隠れ変数を可変とした場合の RBM による再構成誤差

正規化を施した上で入力データとする。なお、ガウス分布の標準偏差のパラメータ  $\sigma$  は 1 に固定し、推定対象のパラメータからは除外する。

### B.3.2 制約ボルツマンマシンの構造の検証

本データに適用するにあたり可視層のユニット数は 100 となるため、隠れ層のユニット数は 100 以下の値で設定可能である。そこで二つの対象範囲について交差検証を行い、RBM の隠れ層のユニット数の検証を実施する。

評価内容として RBM の再構成誤差を利用する。ここで再構成誤差とは、学習済みの RBM に観測データを可視層に入力し、隠れ層、可視層の順に期待値を算出した時の、再構成結果と元のデータとの RMSE(Root Mean Squared Error, 二乗平均平方根誤差) を指す。この指標は 1 メッシュあたりの再構成誤差を意味し、この値が小さいほど RBM のデータ表現能力が高いこととなる。この指標を用い、隠れユニット数を 10~90 に変化させた上で最適なユニット数を検証する。

図 B.4 に検証結果を示す。横軸が隠れユニット数であり、縦軸が再構成誤差について交差検証を施した際の平均値である。いずれの対象範囲においても隠れユニット数の増加に伴い再構成誤差がなだらかに減少する様子が確認された。ただしその過程は単調ではなく、より隠れユニット数の多いモデルの方がより大きな再構成誤差を発生させることも確認された。そこで、対象範囲 A, B ともに前後の隠れユニット数よりも誤差が小さくなっている 60 を、モデルの隠れユニット数に決定した。

隠れユニット数が 60 のモデルにおいて、時間帯別の再構成誤差を図 B.5 に示す。時間帯によって RBM の再構成誤差が変動することが分かる。例えば、深夜から早朝にかけての時間帯は対象範囲 A, B ともに誤差が大きくなっている。日中に比べて通信量が少ないこのような時間帯では RBM による特徴量の抽出が難しく、日による通信量の変動が予測誤差を増加させやすいという可能性が考えられる。また、鉄道駅を中心とする対象範囲 B では、8 時頃と 19 時

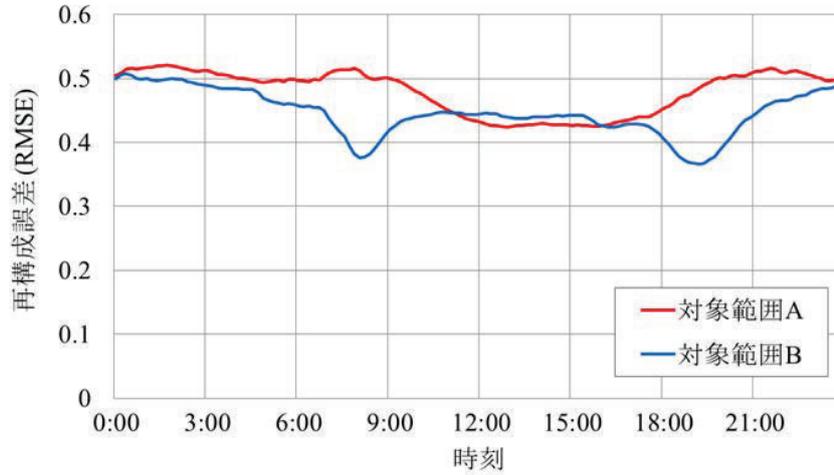


図 B.5. 隠れ変数が 60 の場合の RBM による時間帯別再構成誤差

頃がとりわけ再構成誤差が小さくなっている。これは通勤による駅利用客数が多くなる時間帯であるため、通信量もある決まったパターンに従いやすく、その時間固有の特徴量を抽出できたために高精度であったと考えられる。最後に、対象範囲 A における、ある一日の観測データと、それを RBM によって再構成した結果を 3 時間ごとに図 B.6 に示す。各時刻において左側が入力の観測データ、右側が RBM による再構成結果である。メッシュ値が小さい青い範囲は青く再構成され、メッシュ値が局所的に大きい赤いメッシュは赤く再構成されていることが分かる。対象範囲 B においても同様の傾向が確認されており、対象範囲における大域的な特徴および局所的な特徴の用法を RBM によるモデリングを通じて捉えられていると考えられる。

### B.3.3 多層パーセプトロンの構造の検討

#### 検証の概要

次に、特徴量の時系列変化を学習する機構である MLP の中間層の構造を決定する。まず、前節で学習した隠れユニット数 60 の RBM のモデルを用いて、各メッシュデータの特徴量として隠れユニットの条件付き分布  $p(\mathbf{v}, \mathbf{h}|\theta)$  の期待値を求める。そして、各時刻の観測値に対する特徴量を入力データ、一時間先の観測値に対する特徴量を出力データとして MLP の学習を行った。MLP は中間層が 1 つの構造とし、中間層のユニット数を 10~50 の範囲で変化させた上で交差検証により最適な中間ユニット数を検証する。評価基準として MLP による出力とその時刻の実際の特徴量データとの RMSE を用いる。

中間層のユニット数を可変とした時の MLP の予測誤差を図 B.7 に示す。中間層のユニット数を増やすたびに誤差は小さくなり特徴量の時系列予測精度が向上したことが分かる。これは、ユニット数を増やすことでより複雑な特徴量変化を表現可能になることを意味している。モデルの扱いやすさ、過学習の抑制という観点を踏まえ、MLP の中間層のユニット数を 40 と設定する。

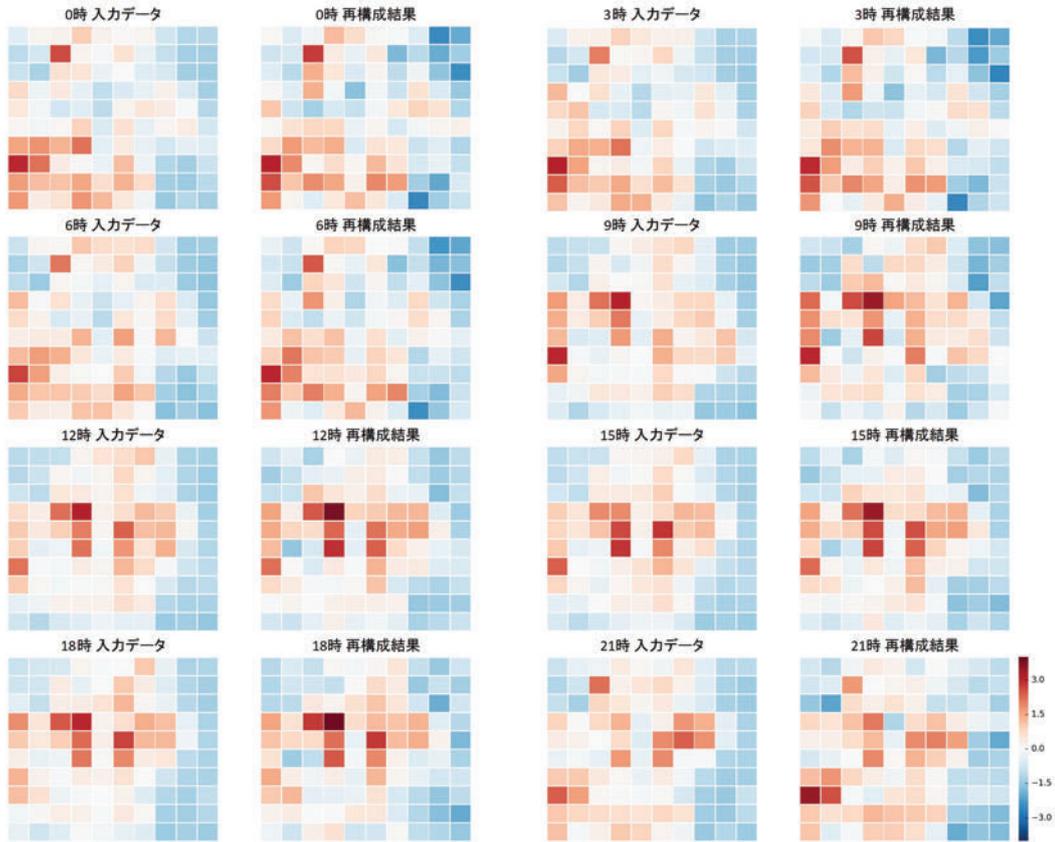


図 B.6. 対象範囲 A における RBM による時間帯別の再構成結果

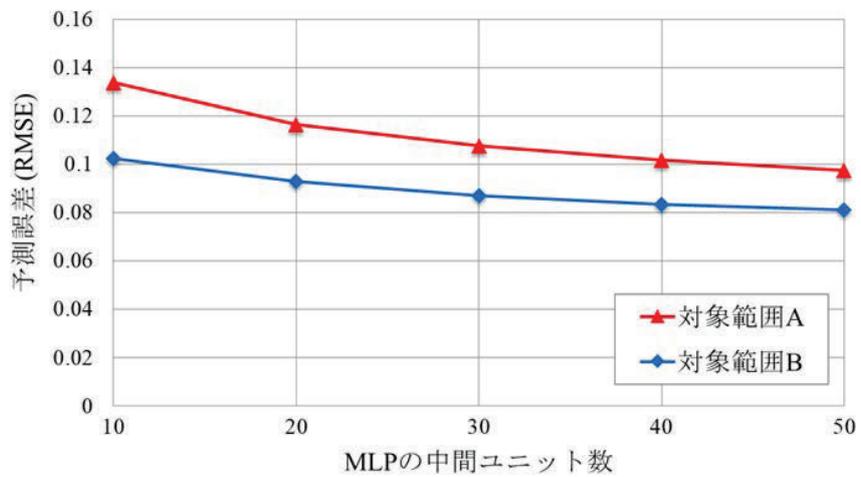


図 B.7. 中間層のユニット数を可変とした場合の MLP による特徴量の予測誤差

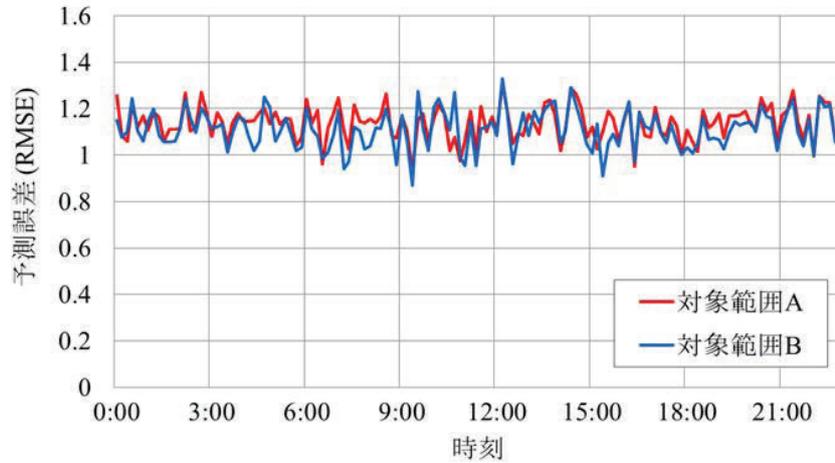


図 B.8. 作成したシミュレーションモデルの時間帯別の予測誤差

### B.3.4 予測精度の検証

RBM の隠れ層のユニット数を 60, MLP の中間層のユニット数を 40 に設定し, 両者を組み合わせて一時間後の全メッシュ値の予測を行って精度を RMSE によって評価する. 時間帯別の予測精度を図 B.8 に示す. どの時間においても RMSE の平均で 1.1 の予測精度であることが確認された. 図 B.9 には, 対象範囲 B におけるある一日での予測結果と実観測データとの比較を示す. 12 時や 17 時では対象地域中心部における通信量の集中や北部での減少など大域的な傾向を捉えられた一方で, 0 時や 3 時では中心部における通信量の集中を誤って予測してしまうなど, 大局的な傾向も捉えられなかった. RBM 自体の再構成誤差が RMSE で 0.48 であったのが, MLP によって特徴量の時系列変化を予測する機構を挟んだことで予測誤差が RMSE で 1.1 に増幅していることから, 特徴量からメッシュ値への再構成において MLP による予測誤差が増幅された可能性が考えられる.

### B.3.5 今後の課題

作成したシミュレーションモデル精度向上の方針として以下が挙げられる. まず, 本検証のモデルは時間帯を考慮せずに 1 時間後の全メッシュ値を予測するものとなっている. しかし現実においては時間帯によってメッシュ値のダイナミクスは大きく変動しうることから, 時間帯を考慮したモデルを構築することが考えられる. また, 本検証の提案手法においては RBM の可視層に複数の観測データを設定することが可能である. メッシュ値に変動を与える気象情報等の複数のデータを統合することで, より本質的な特徴量を抽出することができ, 予測精度の向上が期待できる. なお本検証では, RBM と MLP を同時に学習する理論の制限のため, 2 つのモデルを独立に学習を行っている. 2 つの異なるモデルの同時学習理論の開発も今後の課題として求められる.

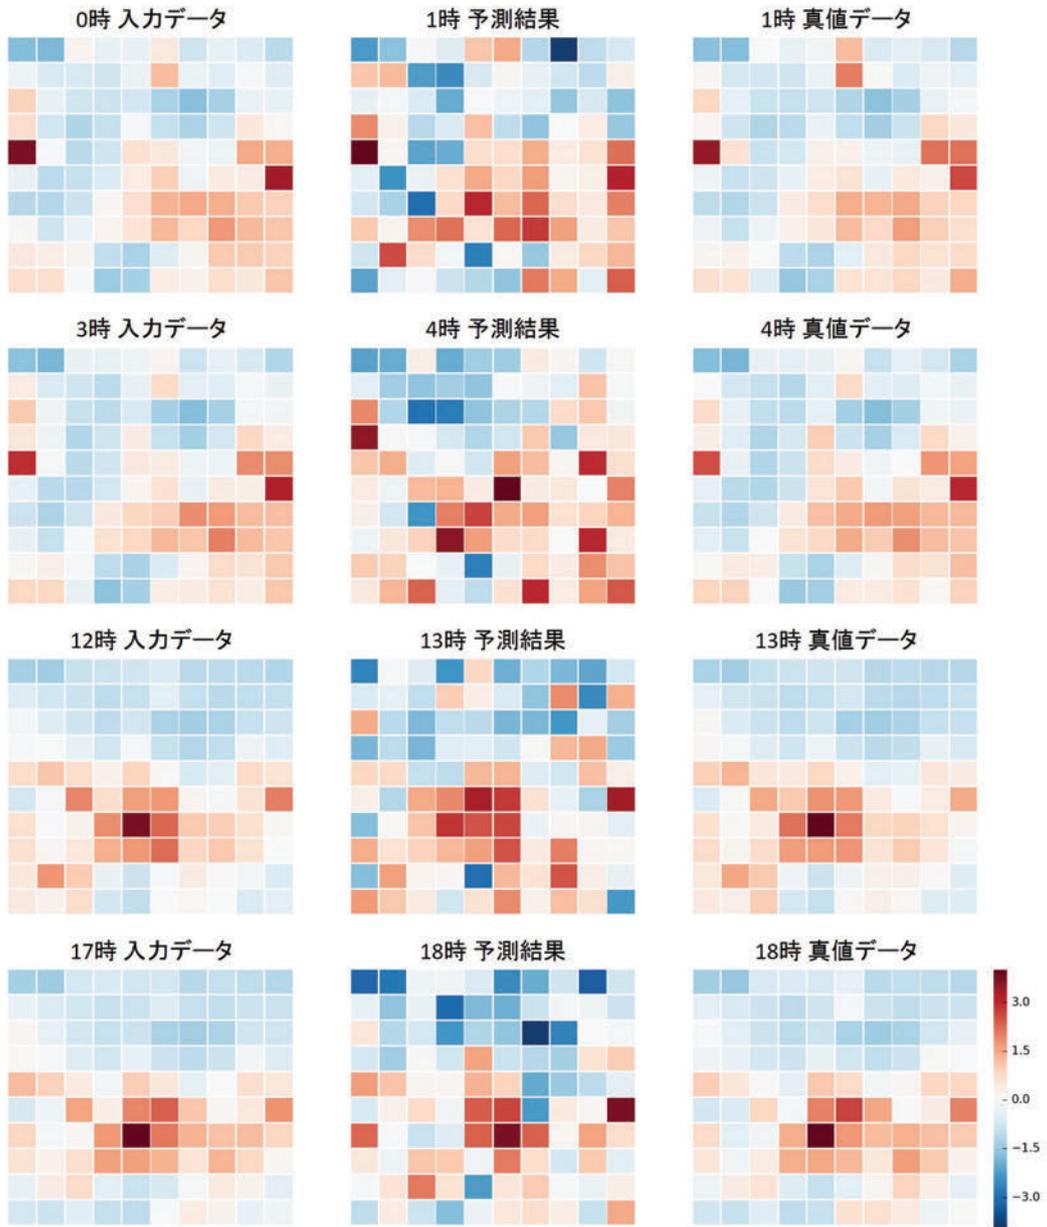


図 B.9. 対象範囲 B における予測結果

## 参考文献

- [1] C. Ratti, D. Frenchman, R. M. Pulselli, and S. Williams. Mobile landscapes: Using location data from cell phones for urban analysis. *Environment and Planning B: Planning and Design*, Vol. 33, No. 5, pp. 727–748, 2006.
- [2] M. C. González, C. A. Hidalgo, and A. L. Barabási. Understanding individual human mobility patterns. *nature*, Vol. 453, No. 7196, p. 779, 2008.
- [3] S. Hasan, C. M. Schneider, S. V. Ukkusuri, and M. C. González. Spatiotemporal patterns of urban human mobility. *Journal of Statistical Physics*, Vol. 151, No. 1-2, pp. 304–318, 2013.
- [4] Omnibond Systems, Traffic Vision. <http://www.trafficvision.com/>. (2018年1月31日参照).
- [5] 中西航. 予測モデルと観測データを統合した人物追跡手法の開発. 博士論文, 東京大学, 2014.
- [6] 神谷啓太, 布施孝志, 泉裕一朗. 空中写真を用いた市街地における車両認識手法の適用可能性の検証. 応用測量論文集, Vol. 28, pp. 99–107, 2017.
- [7] 株式会社 Agoop, ビッグデータソリューション (メッシュ型流動人口). [https://www.agoop.co.jp/solutions/bigdata/data\\_mesh\\_pop/](https://www.agoop.co.jp/solutions/bigdata/data_mesh_pop/). (2018年1月31日参照).
- [8] ゼンリンデータコムいつも NAVI ラボ, 混雑度マップ. <http://lab.itsmo.com/densitymap/>. (2018年1月31日参照).
- [9] Uber, Uber Movement. <https://movement.uber.com/>. (2018年1月31日参照).
- [10] NYC Taxi & Limousine Commission, Taxicab & Livery Passenger Enhancement Programs. [http://www.nyc.gov/html/tlc/html/about/trip\\_record\\_data.shtml](http://www.nyc.gov/html/tlc/html/about/trip_record_data.shtml). (2018年1月31日参照).
- [11] NTT ドコモ, モバイル空間統計に関する情報. [https://www.nttdocomo.co.jp/corporate/disclosure/mobile\\_spatial\\_statistics/](https://www.nttdocomo.co.jp/corporate/disclosure/mobile_spatial_statistics/). (2018年1月31日参照).
- [12] Dandelion, Open Big Data. <https://dandelion.eu/datamine/open-big-data/>. (2018年1月31日参照).
- [13] K. Mohamed, E. Côme, L. Oukhellou, and M. Verleysen. Clustering smart card

- data for urban mobility analysis. *IEEE Transactions on Intelligent Transportation Systems*, Vol. 18, No. 3, pp. 712–728, 2017.
- [14] Citi Bike, Citi Bike System Data. <https://www.citibikenyc.com/system-data/>. (2018年1月31日参照).
- [15] Transportation for LONDON, Open data users. <https://tfl.gov.uk/info-for/open-data-users/>. (2018年1月31日参照).
- [16] R. E. Kalman, P. L. Falb, and M. A. Arbib. *Topics in mathematical system theory*, Vol. 1. McGraw-Hill New York, 1969.
- [17] G. Kitagawa. Monte carlo filter and smoother for non-gaussian nonlinear state space models. *Journal of Computational and Graphical Statistics*, Vol. 5, No. 1, pp. 1–25, 1996.
- [18] N. J. Gordon, D. J. Salmond, and A. F. M. Smith. Novel approach to nonlinear/non-gaussian bayesian state estimation. *IEE Proceedings F - Radar and Signal Processing*, Vol. 140, No. 2, pp. 107–113, 1993.
- [19] 奥村学. トピックモデルによる統計的潜在未解釈. コロナ社, 2015.
- [20] D. M. Blei, A. Y. Ng, and M. I. Jordan. Latent dirichlet allocation. *Journal of Machine Learning Research*, Vol. 3, No. Jan, pp. 993–1022, 2003.
- [21] H. I. Suk, C. Y. Wee, S. W. Lee, and D. Shen. State-space model with deep learning for functional dynamics estimation in resting-state fMRI. *NeuroImage*, Vol. 129, No. Supplement C, pp. 292–307, 2016.
- [22] G. E. Hinton. A practical guide to training restricted boltzmann machines. *Neural Networks: Tricks of the Trade*, Springer, pp. 599–619, 2012.
- [23] D. H. Ackley, G. E. Hinton, and T. J. Sejnowski. A learning algorithm for boltzmann machines. *Cognitive Science*, Vol. 9, No. 1, pp. 147–169, 1985.
- [24] 人工知能学会. 深層学習. 近代科学社, 2015.
- [25] S. Y. Chen. Kalman filter for robot vision: A survey. *IEEE Transactions on Industrial Electronics*, Vol. 59, No. 11, pp. 4409–4420, 2012.
- [26] A. R. Jimenez, F. Seco, C. Prieto, and J. Guevara. A comparison of pedestrian dead-reckoning algorithms using a low-cost MEMS IMU. In *IEEE International Symposium on Intelligent Signal Processing*, pp. 37–42, 2009.
- [27] M. G. Dissanayake, P. Newman, S. Clark, H. F. Durrant-Whyte, and M. Csorba. A solution to the simultaneous localization and map building (SLAM) problem. *IEEE Transactions on Robotics and Automation*, Vol. 17, No. 3, pp. 229–241, 2001.
- [28] T. Bailey, J. Nieto, J. Guivant, M. Stevens, and E. Nebot. Consistency of the EKF-SLAM algorithm. In *IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp. 3562–3568, 2006.
- [29] M. Montemerlo, S. Thrun, D. Koller, and B. Wegbreit. FastSLAM: A factored solution to the simultaneous localization and mapping problem. In *18th AAAI*

- National Conference on Artificial Intelligence*, pp. 593–598, 2002.
- [30] 布施孝志, 松本圭生. モバイル機器搭載センサを統合した自己位置推定手法の開発. 写真測量とリモートセンシング, Vol. 54, No. 6, pp. 290–299, 2016.
- [31] T. Fuse and K. Nagara. Real-time localization of mobile device by filtering method for sensor fusion. In *Videometrics, Range Imaging, and Applications XIV*, Vol. 10332, p. 103320L, 2017.
- [32] A. Yilmaz, O. Javed, and M. Shah. Object tracking: A survey. *ACM Computing Surveys*, Vol. 38, No. 4, 2006.
- [33] M. Camplani, A. Paiement, M. Mirmehdi, D. Damen, S. Hannuna, T. Burghardt, and L. Tao. Multiple human tracking in RGB-D data: A survey. *arXiv preprint arXiv:1606.04450*, 2016.
- [34] K. V. Wagh and R. K. Kulkarni. Human tracking system. In *International Conference on Electronics and Communication Systems*, pp. 1–6, 2014.
- [35] C. Y. Tsai, X. Dutoit, K. T. Song, H. Van Brussel, and M. Nuttin. Robust face tracking control of a mobile robot using self-tuning kalman filter and echo state network. *Asian Journal of Control*, Vol. 12, No. 4, pp. 488–509, 2010.
- [36] 桑谷立, 永田賢二, 岡田真人. マルコフランダムフィールドモデルによる計測画像データからの潜在構造抽出. 映像情報メディア学会誌, Vol. 68, No. 12, pp. 892–896, 2014.
- [37] S. C. Park, M. K. Park, and M. G. Kang. Super-resolution image reconstruction: A technical overview. *IEEE Signal Processing Magazine*, Vol. 20, No. 3, pp. 21–36, 2003.
- [38] M. Elad, 玉木徹 (訳). スパースモデリング :  $l_1/l_0$  ノルム最小化の基礎理論と画像処理への応用. 共立出版, 2016.
- [39] L. A. Gatys, A. S. Ecker, and M. Bethge. A neural algorithm of artistic style. *arXiv preprint arXiv:1508.06576*, 2015.
- [40] I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, and Y. Bengio. Generative adversarial nets. In *Advances in Neural Information Processing Systems*, pp. 2672–2680, 2014.
- [41] A. Radford, L. Metz, and S. Chintala. Unsupervised representation learning with deep convolutional generative adversarial networks. *arXiv preprint arXiv:1511.06434*, 2015.
- [42] Y. F. Huang, S. Werner, J. Huang, N. Kashyap, and V. Gupta. State estimation in electric power grids: Meeting new challenges presented by the requirements of the future grid. *IEEE Signal Processing Magazine*, Vol. 29, No. 5, pp. 33–43, 2012.
- [43] A. Monticelli. Electric power system state estimation. *Proceedings of the IEEE*, Vol. 88, No. 2, pp. 262–282, 2000.
- [44] Y. Liu, P. Ning, and M. K. Reiter. False data injection attacks against state estimation in electric power grids. *ACM Transactions on Information and System*

- Security*, Vol. 14, No. 1, pp. 13:1–13:33, 2011.
- [45] 山西健司. データマイニングによる異常検知. 共立出版, 2009.
- [46] G. Liang, J. Zhao, F. Luo, S. R. Weller, and Z. Y. Dong. A review of false data injection attacks against modern power systems. *IEEE Transactions on Smart Grid*, Vol. 8, No. 4, pp. 1630–1638, 2017.
- [47] Y. Velchev, S. Radeva, S. Sokolov, and D. Radev. Automated estimation of human emotion from EEG using statistical features and SVM. In *Digital Media Industry Academic Forum*, pp. 40–42, 2016.
- [48] 島田大樹, 彌富仁. 畳み込みニューラルネットワークを使った授業映像中の聴講者の状態推定システムの構築と特徴量獲得に関する検討. *知能と情報*, Vol. 29, No. 1, pp. 517–526, 2017.
- [49] L. Li, Y. Zhao, D. Jiang, Y. Zhang, F. Wang, I. Gonzalez, E. Valentin, and H. Sahli. Hybrid deep neural network–hidden markov model (DNN-HMM) based speech emotion recognition. In *IEEE Humaine Association Conference on Affective Computing and Intelligent Interaction*, pp. 312–317, 2013.
- [50] 佐藤忠彦, 樋口知之. ビッグデータ時代のマーケティング—ベイジアンモデリングの活用 (KS 社会科学専門書). 講談社, 2013.
- [51] 佐藤忠彦. 状態空間モデルのマーケティングへの応用. *岩波データサイエンス*, 岩波書店, Vol. 6, pp. 57–67, 2017.
- [52] K. Yada and N. Sano. Customer behavior modelling using radio frequency identification data and the hidden markov model. In *Annual SRII Global Conference*, pp. 509–514, 2012.
- [53] 上辻慶典, 柳本豪一, 吉岡理文. トピックモデルを用いたアクセスログからのユーザの状態推定. *電気学会論文誌. C*, Vol. 136, No. 3, pp. 357–362, 2016.
- [54] 本村陽一. 大規模データからの日常生活行動予測モデリング. *Synthesiology*, Vol. 2, No. 1, pp. 1–11, 2009.
- [55] 矢田勝俊. 顧客動線研究入門. *岩波データサイエンス*, 岩波書店, Vol. 4, pp. 70–81, 2016.
- [56] 稲垣和哉, 原祐輔, 桑原雅夫. 店舗の空間的・業種的共起関係に基づいた中心市街地の潜在構造分析. *土木学会論文集 D3 (土木計画学)*, Vol. 72, No. 5, pp. I.473–I.485, 2016.
- [57] 氏家晃仁, 福本潤也. 厳格な形状制約や連結性を仮定しない集積領域検出手法の開発. *土木学会論文集 D3 (土木計画学)*, Vol. 71, No. 5, pp. I.397–I.406, 2015.
- [58] N. J. Yuan, Y. Zheng, X. Xie, Y. Wang, K. Zheng, and H. Xiong. Discovering urban functional zones using latent activity trajectories. *IEEE Transactions on Knowledge and Data Engineering*, Vol. 27, No. 3, pp. 712–725, 2015.
- [59] 加藤直広, 立森久照, 高橋邦彦. 地図の上で階層ベイズモデリング. *岩波データサイエンス*, 岩波書店, Vol. 4, pp. 55–67, 2016.
- [60] Y. Zheng, W. Wu, Y. Chen, H. Qu, and L. M. Ni. Visual analytics in urban

- computing: An overview. *IEEE Transactions on Big Data*, Vol. 2, No. 3, pp. 276–296, 2016.
- [61] T. Von Landesberger, F. Brodtkorb, P. Roskosch, N. Andrienko, G. Andrienko, and A. Kerren. Mobilitygraphs: Visual analysis of mass mobility dynamics via spatio-temporal graphs and clustering. *IEEE Transactions on Visualization and Computer Graphics*, Vol. 22, No. 1, pp. 11–20, 2016.
- [62] G. Andrienko, N. Andrienko, G. Fuchs, and J. Wood. Revealing patterns and trends of mass mobility through spatial and temporal abstraction of origin-destination movement data. *IEEE Transactions on Visualization and Computer Graphics*, Vol. 23, No. 9, pp. 2120–2136, 2017.
- [63] R. Krueger, G. Sun, F. Beck, R. Liang, and T. Ertl. TravelDiff: Visual comparison analytics for massive movement patterns derived from twitter. In *IEEE Pacific Visualization Symposium*, pp. 176–183, 2016.
- [64] F. Xu, Y. Lin, J. Huang, D. Wu, H. Shi, J. Song, and Y. Li. Big data driven mobile traffic understanding and forecasting: A time series approach. *IEEE Transactions on Services Computing*, Vol. 9, No. 5, pp. 796–805, 2016.
- [65] M. G. Demissie, S. Phithakkitnukoon, T. Sukhvibul, F. Antunes, R. Gomes, and C. Bento. Inferring passenger travel demand to improve urban mobility in developing countries using cell phone data: A case study of Senegal. *IEEE Transactions on Intelligent Transportation Systems*, Vol. 17, No. 9, pp. 2466–2478, 2016.
- [66] W. Wu, J. Xu, H. Zeng, Y. Zheng, H. Qu, B. Ni, M. Yuan, and L. M. Ni. Telcovis: Visual exploration of co-occurrence in urban human mobility based on telco data. *IEEE Transactions on Visualization and Computer Graphics*, Vol. 22, No. 1, pp. 935–944, 2016.
- [67] R. Sanya and M. Mubangizi. Using mobile phone data to study dynamics of rural-urban mobility. In *IEEE International Conference on Data Science and Engineering*, pp. 1–6, 2016.
- [68] I. B. I. Purnama, N. Bergmann, R. Jurdak, and K. Zhao. Characterising and predicting urban mobility dynamics by mining bike sharing system data. In *IEEE 12th International Conference on Ubiquitous Intelligence and Computing*, pp. 159–167, 2015.
- [69] 中村敏和. データ同化手法を用いた人の流れの高精度推定手法の研究. 博士論文, 東京大学, 2014.
- [70] 矢部貴大, 関本義秀, 金杉洋, 檜山武浩. シミュレーションと断片的な観測データの同化による平常時と異なる人の流動の予測, 2014.
- [71] 長谷川瑤子, 関本義秀, 金杉洋, 檜山武浩. 同化手法を用いたスパースな携帯基地局情報に基づく人の移動推定. *交通工学論文集*, Vol. 1, No. 4, pp. A.9–A.17, 2015.
- [72] 原田遼. 詳細な交通行動推定のためのアクティビティシミュレーションと観測データの

- 統合に関する研究. 修士論文, 東京大学, 2017.
- [73] T. Iwata, H. Shimizu, F. Naya, and N. Ueda. Estimating people flow from spatiotemporal population data via collective graphical mixture models. *ACM Transactions on Spatial Algorithms and Systems*, Vol. 3, No. 1, p. 2, 2017.
- [74] M. Fiori, P. Musé, M. Tepper, and G. Sapiro. Tell me where you are and I tell you where you are going: Estimation of dynamic mobility graphs. In *IEEE Sensor Array and Multichannel Signal Processing Workshop*, pp. 1–5, 2016.
- [75] J. Candia, M. C. González, P. Wang, T. Schoenharl, G. Madey, and Albert-László A. L. Barabási. Uncovering individual and collective human dynamics from mobile phone records. *Journal of physics A: Mathematical and Theoretical*, Vol. 41, No. 22, p. 224015, 2008.
- [76] T. Horanont. *A study on urban mobility and dynamic population estimation by using aggregate mobile phone sources*. PhD thesis, The University of Tokyo, 2010.
- [77] B. Pan, Y. Zheng, D. Wilkie, and C. Shahabi. Crowd sensing of traffic anomalies based on human mobility and social media. In *Proceedings of the 21st ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems*, pp. 344–353, 2013.
- [78] R. Horiguchi, M. Iijima, M. Kobayashi, and H. Hanabusa. Traffic anomaly detection for surface street networks with the mesh-wised traffic indices on macroscopic fundamental diagram. In *OPTIMUM International Symposium on Recent Advances in Transport Modelling*, pp. 1–7, 2013.
- [79] 井料隆雅, 岩谷愛理, 朝倉康夫. 都市高速道路における時間帯別流入交通量の週変動分析. *交通工学研究発表会論文報告集*, Vol. 27, pp. 173–176, 2007.
- [80] 井上真一, 塚井誠人, 桑野将司, 奥村誠. 独立成分分析による非日常時の地方空港利用交通の分析. *土木計画学研究・論文集*, Vol. 28, No. 3, pp. 583–593, 2009.
- [81] J. Wang and I. C. Paschalidis. Statistical traffic anomaly detection in time-varying communication networks. *IEEE Transactions on Control of Network Systems*, Vol. 2, No. 2, pp. 100–111, 2015.
- [82] L. Li, X. Su, Y. Zhang, Y. Lin, and Z. Li. Trend modeling for traffic time series analysis: An integrated study. *IEEE Transactions on Intelligent Transportation Systems*, Vol. 16, No. 6, pp. 3430–3439, 2015.
- [83] P. S. Castro, D. Zhang, C. Chen, S. Li, and G. Pan. From taxi GPS traces to social and community dynamics: A survey. *ACM Computing Surveys*, Vol. 46, No. 2, p. 17, 2013.
- [84] V. Mahadevan, W. Li, V. Bhalodia, and N. Vasconcelos. Anomaly detection in crowded scenes. In *IEEE Conference on Computer Vision and Pattern Recognition*, pp. 1975–1981, 2010.
- [85] A Y. Grinberger and N. Shoval. A temporal-contextual analysis of urban dynam-

- ics using location-based data. *International Journal of Geographical Information Science*, Vol. 29, No. 11, pp. 1969–1987, 2015.
- [86] K. Mohamed, E. Côme, L. Oukhellou, and M. Verleysen. Clustering smart card data for urban mobility analysis. *IEEE Transactions on Intelligent Transportation Systems*, Vol. 18, No. 3, pp. 712–728, 2017.
- [87] W. Zeng, C. W. Fu, S. Müller Arisona, S. Schubiger, R. Burkhard, and K. L. Ma. Visualizing the relationship between human mobility and points of interest. *IEEE Transactions on Intelligent Transportation Systems*, Vol. 18, No. 8, pp. 2271–2284, 2017.
- [88] R. Krueger, D. Thom, and T. Ertl. Semantic enrichment of movement behavior with foursquare—a visual analytics approach. *IEEE Transactions on Visualization and Computer Graphics*, Vol. 21, No. 8, pp. 903–915, 2015.
- [89] 福富義章. 交通行動推定のためのアクティビティモデルと異種交通データからなる状態空間モデルの平滑化. 修士論文, 東京大学, 2018.
- [90] V. Chandola, A. Banerjee, and V. Kumar. Anomaly detection: A survey. *ACM Computing Surveys*, Vol. 41, No. 3, p. 15, 2009.
- [91] M. A. Pimentel, D. A. Clifton, L. Clifton, and L. Tarassenko. A review of novelty detection. *Signal Processing*, Vol. 99, pp. 215–249, 2014.
- [92] V. Hodge and J. Austin. A survey of outlier detection methodologies. *Artificial Intelligence Review*, Vol. 22, No. 2, pp. 85–126, 2004.
- [93] 井出剛, 杉山将. 異常検知と変化検知. 講談社, 2015.
- [94] E. Fox, E. B. Sudderth, M. I. Jordan, and A. S. Willsky. Nonparametric bayesian learning of switching linear dynamical systems. In *Advances in Neural Information Processing Systems*, pp. 457–464, 2009.
- [95] T. S. Ferguson. A bayesian analysis of some nonparametric problems. *The Annals of Statistics*, pp. 209–230, 1973.
- [96] 持橋大地. 最近のベイズ理論の進展と応用 [iii]: ノンパラメトリックベイズ. 信学誌, Vol. 93, No. 1, pp. 73–79, 2010.
- [97] Y. W. Teh, M. I. Jordan, M. J. Beal, and D. M. Blei. Hierarchical dirichlet processes. *Journal of the American Statistical Association*, Vol. 101, No. 476, pp. 1–30, 2006.
- [98] E. Di Lello, T. De Laet, and H. Bruyninckx. Hierarchical dirichlet process hidden markov models for abnormality detection in robotic assembly. *NIPS Workshop on Bayesian Nonparametric Models for Reliable Planning and Decision-Making Under Uncertainty*, 2012.
- [99] M. Bartcus, F. Chamroukhi, and H. Glotin. Hierarchical dirichlet process hidden markov model for unsupervised bioacoustic analysis. In *IEEE International Joint Conference on Neural Networks*, pp. 1–7, 2015.
- [100] C. P. Robert and G. Casella. *Monte Carlo Statistical Methods*. Springer, 2005.

- [101] E. B. Fox. *Bayesian nonparametric learning of complex dynamical phenomena*. PhD thesis, Massachusetts Institute of Technology, 2009.
- [102] J. Munkres. Algorithms for the assignment and transportation problems. *Journal of the Society for Industrial and Applied Mathematics*, Vol. 5, No. 1, pp. 32–38, 1957.
- [103] 杉山将. 確率分布間の距離推定: 機械学習分野における最新動向 (サーベイ, <特集>機械学習研究部会). *日本応用数理学会論文誌*, Vol. 23, No. 3, pp. 439–452, 2013.
- [104] 岩田具治. トピックモデル. 講談社, 2015.
- [105] T. L. Griffiths and M. Steyvers. Finding scientific topics. *Proceedings of the National Academy of Sciences*, Vol. 101, No. suppl 1, pp. 5228–5235, 2004.
- [106] Y. W. Teh, D. Newman, and M. Welling. A collapsed variational bayesian inference algorithm for latent dirichlet allocation. In *Advances in Neural Information Processing Systems*, pp. 1353–1360, 2007.
- [107] A. Asuncion, M. Welling, P. Smyth, and Y. W. Teh. On smoothing and inference for topic models. In *Proceedings of the 25th Conference on Uncertainty in Artificial Intelligence*, pp. 27–34, 2009.
- [108] C. Wang, J. Paisley, and D. Blei. Online variational inference for the hierarchical dirichlet process. In *Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics*, pp. 752–760, 2011.
- [109] L. Fei-Fei and P. Perona. A bayesian hierarchical model for learning natural scene categories. In *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, Vol. 2, pp. 524–531, 2005.
- [110] W. Chong, D. Blei, and F. F. Li. Simultaneous image classification and annotation. In *IEEE Conference on Computer Vision and Pattern Recognition*, pp. 1903–1910, 2009.
- [111] J. C. Niebles, H. Wang, and L. Fei-Fei. Unsupervised learning of human action categories using spatial-temporal words. *International Journal of Computer Vision*, Vol. 79, No. 3, pp. 299–318, 2008.
- [112] M. Rodriguez, S. Ali, and T. Kanade. Tracking in unstructured crowded scenes. In *IEEE 12th International Conference on Computer Vision*, pp. 1389–1396, 2009.
- [113] K. Ishiguro, T. Yamada, S. Araki, T. Nakatani, and H. Sawada. Probabilistic speaker diarization with bag-of-words representations of speaker angle information. *IEEE Transactions on Audio, Speech, and Language Processing*, Vol. 20, No. 2, pp. 447–460, 2012.
- [114] 中野倫靖, 吉井和佳, 後藤真孝ほか. トピックモデルを用いた歌声特徴量の分析. 研究報告音楽情報科学 (MUS), Vol. 2013, No. 23, pp. 1–7, 2013.
- [115] D. J. Hu and L. K. Saul. A probabilistic topic model for music analysis. In *Proceedings of the Neural Information Processing Systems*, Vol. 9, 2009.
- [116] 岩田具治, 渡部晋治, 山田武士, 上田修功. 購買行動解析のためのトピック追跡モデル. 電

- 子情報通信学会論文誌 D, Vol. 93, No. 6, pp. 978–987, 2010.
- [117] 倉島健, 岩田具治, 星出高秀, 高屋典子, 藤村考. 行動範囲と興味の同時推定モデルによる地域情報推薦. 情報処理学会論文誌データベース (TOD) , Vol. 6, No. 2, pp. 30–41, 2013.
- [118] 黒川茂莉, 横山浩之, 吉井和佳, 麻生英樹. 携帯電話通信時に得られる疎な位置情報履歴を用いた有意位置検出. 電子情報通信学会論文誌 D, Vol. 95, No. 4, pp. 722–733, 2012.
- [119] 神谷啓太, 中西航, 泉裕一郎. トピックモデルを用いたサッカーの攻撃パターンの分類による類似プレーの抽出. 統計数理, Vol. 65, No. 2, pp. 1–10, 2017.
- [120] S. Gerrish and D. M. Blei. Predicting legislative roll calls from text. In *Proceedings of the 28th International Conference on Machine Learning*, pp. 489–496, 2011.
- [121] 岩田具治, 渡部晋治, 澤田宏. ファッション雑誌を用いたコーディネート支援システム. 情報科学技術フォーラム講演論文集, pp. 179–180, 2010.
- [122] D. M. Blei and J. D. Lafferty. Dynamic topic models. In *Proceedings of the 23rd ACM International Conference on Machine Learning*, pp. 113–120, 2006.
- [123] X. Wang and A. McCallum. Topics over time: A non-markov continuous-time model of topical trends. In *Proceedings of the 12th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 424–433, 2006.
- [124] T. Iwata, S. Watanabe, T. Yamada, and N. Ueda. Topic tracking model for analyzing consumer purchase behavior. In *Proceedings of the 21st International Joint Conference on Artificial Intelligence*, pp. 1427–1432, 2009.
- [125] Y. Zheng, H. Zhang, and Y. Yu. Detecting collective anomalies from multiple spatio-temporal datasets across different domains. In *Proceedings of the 23rd ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems*, p. 2, 2015.
- [126] X. Chen, S. Xiang, C. L. Liu, and C. H. Pan. Vehicle detection in satellite images by parallel deep convolutional neural networks. In *2nd IAPR Asian Conference on Pattern Recognition*, pp. 181–185, 2013.
- [127] X. Chen, S. Xiang, C. L. Liu, and C. H. Pan. Vehicle detection in satellite images by hybrid deep convolutional neural networks. *Geoscience and Remote Sensing Letters*, Vol. 11, No. 10, pp. 1797–1801, 2014.
- [128] Q. Jiang, L. Cao, M. Cheng, C. Wang, and J. Li. Deep neural networks-based vehicle detection in satellite images. In *IEEE International Symposium on Bioelectronics and Bioinformatics*, pp. 184–187, 2015.
- [129] H. Zhu, X. Chen, K. Dai, W. and Fu, Q. Ye, and J. Jiao. Orientation robust object detection in aerial images using deep convolutional neural network. In *IEEE International Conference on Image Processing*, pp. 3735–3739, 2015.
- [130] S. Qu, Y. Wang, G. Meng, and C. Pan. Vehicle detection in satellite images by incorporating objectness and convolutional neural network. *Journal of Industrial*

*and Intelligent Information*, Vol. 4, No. 2, 2016.

- [131] K. Kamiya and T. Fuse. Applicability evaluation of object detection method to satellite and aerial imageries. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol. XLI-B7, pp. 229–234, 2016.
- [132] S. Razakarivony and F. Jurie. Vehicle detection in aerial imagery: A small target detection benchmark. *Journal of Visual Communication and Image Representation*, Vol. 34, pp. 187–203, 2016.
- [133] M. Everingham, L. Van Gool, C. K. Williams, J. Winn, and A. Zisserman. The pascal visual object classes (VOC) challenge. *International Journal of Computer Vision*, Vol. 88, No. 2, pp. 303–338, 2010.
- [134] M. M. Cheng, Z. Zhang, W. Y. Lin, and P. Torr. BING: Binarized normed gradients for objectness estimation at 300fps. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 3286–3293, 2014.
- [135] J. Hosang, R. Benenson, P. Dollár, and B. Schiele. What makes for effective detection proposals? *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 38, No. 4, pp. 814–830, 2016.
- [136] R. E. Fan, K. W. Chang, C. J. Hsieh, X. R. Wang, and C. J. Lin. LIBLINEAR: A library for large linear classification. *Journal of Machine Learning Research*, Vol. 9, No. 8, pp. 1871–1874, 2008.
- [137] A. Krizhevsky, I. Sutskever, and G. E. Hinton. Imagenet classification with deep convolutional neural networks. In *Advances in Neural Information Processing Systems*, pp. 1097–1105, 2012.
- [138] S. Ren, K. He, R. Girshick, and J. Sun. Faster R-CNN: Towards real-time object detection with region proposal networks. In *Advances in Neural Information Processing Systems*, pp. 91–99, 2015.
- [139] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi. You only look once: Unified, real-time object detection. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 779–788, 2016.
- [140] W. Liu, D. Anguelov, D. Erhan, C. Szegedy, S. Reed, C. Y. Fu, and A. C. Berg. Ssd: Single shot multibox detector. In *European Conference on Computer Vision*, pp. 21–37, 2016.

## 謝辞

私の周りの恩師や仲間、そして家族からのご指導およびご支援がなければ、この博士論文の執筆を無事終えることはできませんでした。ここに深い感謝の意を表します。

卒業論文から修士論文、そしてこの博士論文に至るまで、布施孝志教授には大変お世話になりました。私の研究進捗が芳しくない時、研究生活に迷いが生じた時、いかなる時も私を決して見放すことなく、厳しくかつ温かくご指導いただきました。そして研究に一筋の光が見いだせた時や一区切りついた際にいただいた労いの言葉は、研究を続けるための確かな力となっております。6年間という短くも長い期間、布施先生にご指導いただけたのは、私の研究生活の中で最も幸せであったところと確信しております。

本論文の執筆においては副査の先生方にも大変厚いご指導をいただきました。清水英範教授には私の考えるより遥か上の視点から、この論文の位置付けに関してご助言をいただきました。また、論文副査の場面だけでなく普段の研究室ゼミにおける清水先生のご発言からは、研究者としての思慮の巡らせ方の一端を学ばせていただきました。羽藤英二教授には研究の意義から研究成果の応用方法に至るまで、多岐にわたる面でご助言いただきました。さらには研究の進め方や次のキャリアにおける目標設定など多くの観点からアドバイスしていただけたことは、研究生活を送るにあたっての大きな力となっております。大口敬教授には交通工学の観点から多くのご助言をいただきました。手法の適用自体に関心が行きがちであった私の研究方針に対し、分析結果のより具体的かつ深い考察の重要性をご教授いただきました。浅見泰司教授には本研究の適用対象および結果に対して終始冷静かつ的確なご助言をいただきました。論文中の表現方法や構成などに対しても具体的にご教授いただいたことにより、本論文をより良いものにすることができました。

私が計6年間在籍することとなった交通地域ラボ(地域/情報研究室および交通・都市・国土学研究室)の素晴らしい先生・先輩・同期・後輩の皆様からは常に多くを学ばせていただきました。中西航先生(現 東京工業大学特任助教)は研究室の助教として大変お世話になった先生であると同時に、一研究者の先輩として頼りにさせていただいた方でもあります。共同研究やラボでの生活を通じて、若手研究者としての振る舞いや悩みに関して直接的かつ間接的にアドバイスいただけたことは私にとって大変な励みとなっております。また、交通地域ラボの助教として、柳沼秀樹先生(現 東京理科大学講師)および原祐輔助教にも研究および生活面における数々のご支援をいただきました。さらに、ラボの先輩方からは研究に向かう姿勢を学ばせていただき、同期達とは研究仲間として共に切磋琢磨することができ、そして後輩からは時に指導する立場を通じて、私自身大きく成長することができました。特に高田大暉さん、高橋真美さん、原田遼さん、泉裕一朗さん、福富義章さん、森田仁美さんらの成果は、私の博士論文の完成には欠かせない要素となっております。地域/情報研究室の秘書である石田涼子さんには、私たちの研究生活を円滑にするための多くのサポートをしていただきました。

また、月刊『測量』(日本測量協会)および土木学会誌(土木学会)の学生編集委員として活動できたことは、実務に触れる大変貴重な経験であると同時に、研究を行う上での大きな刺激

となりました。両編集委員会においては大変多くの方にお世話になり、皆様には心からお礼申し上げます。

なお、本研究で使用したデータの一部はアジア航測株式会社様にご提供いただきました。研究活動費においては、日本学術振興会から特別研究員として JSPS 科研費 JP16J06150 の助成をいただきました。

最後となりましたが、いかなる状況でも私の考えを尊重し、私の自由な生き方を否定することなく常に優しく見守ってくれた家族、特に両親には大変感謝しております。また、婚約者である宏美は無償の優しさをいつも与えてくれました。笑顔で満ち溢れた新しい生活を共に創り上げることを楽しみにしています。

これまでお世話になった方全てのお名前を挙げることはできませんが、全ての方に、改めて深く感謝申し上げます。

2018年2月21日