

愛知工業大学大学院経営情報科学研究科

博士論文

マルチエージェント
シミュレーションを用いた
問題解決における

課題の検討

A Study on Issues
in Problem Solving
with Multi-agent Simulation

2026年3月

B22801 安藤圭祐

ANDO Keisuke

指導教員 伊藤暢浩

目次

第 1 章	序論	3
第 2 章	マルチエージェントシミュレーションを用いた問題解決	6
2.1	マルチエージェントシミュレーション	6
2.1.1	エージェントとマルチエージェントシステム	6
2.1.2	マルチエージェントシミュレーションの利用事例とその課題	7
2.2	マルチエージェントシステムのモデル	7
2.3	本研究の目的	9
第 3 章	ロボカップレスキューシミュレーションにおける救助戦略の設計	11
3.1	救助戦略の設計を通じた課題の明確化	11
3.2	ロボカップレスキューシミュレーションのモデル	12
3.2.1	ロボカップレスキューシミュレーションの概要	12
3.2.2	ロボカップレスキューシミュレーションの要素	13
3.2.3	ロボカップレスキューシミュレーションのシステム	21
3.3	救助戦略の開発	23
3.3.1	救助戦略の構成と設計	23
3.3.2	救助戦略の評価とコンペティション	30
3.3.3	救助戦略の開発における課題	30
3.4	分散型協調戦略の開発	31
3.4.1	分散型協調戦略の概要	31
3.4.2	救助部隊のモジュールの構成	32
3.4.3	タスクの検出と選択	34
3.4.4	瓦礫を考慮した経路探索	37
3.4.5	救助部隊への担当地域の割り当て	42
3.4.6	重要道路の構築	44
3.4.7	救助部隊間の情報共有	47
3.4.8	避難所の状況を考慮した搬送先の選択	49
3.5	分散型協調戦略の評価	52
3.6	救助戦略の評価に向けた環境と戦略の関係分析	55
3.6.1	救助戦略の評価における課題	55
3.6.2	環境と戦略の関係を分析する研究	56
3.7	救助戦略の設計と評価に関する考察	60

第4章	日本の交通事故要因の空間分析	62
4.1	交通事故要因の究明を通じた課題の明確化	62
4.2	交通事故情勢と事故分析における課題	62
4.2.1	日本の交通事故情勢	62
4.2.2	愛知県の交通事故情勢	64
4.2.3	交通事故の要因を調査する研究	67
4.2.4	事故要因の分析における課題	70
4.3	交通事故データベースの設計と構築	73
4.3.1	交通事故データベースの要件	73
4.3.2	交通事故のデータモデル	75
4.3.3	サンプルデータベースの実装	80
4.3.4	交通事故データベースの性能評価	85
4.4	ホットスポットの検出	86
4.4.1	カーネル密度推定を用いた事故リスクの推定	86
4.4.2	従来のホットスポットの検出手法とその課題	88
4.4.3	時空間的なホットスポットの検出手法の提案	94
4.4.4	ホットスポットの検出と評価	104
4.5	環境要因との関係分析	109
4.5.1	交通事故における環境要因と分析の目的	109
4.5.2	交通事故に関する特徴的な傾向を持つ地域の検出	110
4.5.3	空間的傾向に基づく交通環境と当事者の行動との関係分析	120
4.5.4	正面衝突事故の多発箇所とその交通環境の分析	124
4.6	交通事故要因分析に関する考察	138
第5章	結論	139
5.1	本研究の取り組みのまとめ	139
5.2	マルチエージェントシミュレーションによる問題解決における課題	139
5.3	今後の展望	141
謝辞		143
参考文献		145
索引		151

第1章

序論

近年、複雑な社会問題に対する解決策を見出すための手段として、マルチエージェントシミュレーションが注目されている。マルチエージェントシミュレーションは与えられた環境に対して、自律的に動作する主体を「エージェント」としてモデル化し、それらの相互作用を通じて、システム全体の振る舞いを解析する手法である。この手法を用いることで、さまざまな社会問題において、個および全体の両方の目標達成へ向けた協調行動を検討できる。例えば、2020年に流行した新型コロナウイルス感染症（COVID-19）では、「どのように感染拡大を防ぎつつ、社会活動を継続させるか」が、ウイルスを媒介する人間とその活動環境をモデル化することで検討され、その有用性が示されている [1]。

しかし、現行のマルチエージェントシミュレーションでは、対象とする問題のメカニズムの解明が十分でない場合が多い。そのため、シミュレーションの再現性や結果の信頼性の確保が課題とされている [2]。それにも関わらず、将来に発生し得る問題への対策検討が急務とされる社会問題においては、有用な対策を検討できる実用的なツールとして積極的に活用されている。

本研究では、マルチエージェントシミュレーションを用いた問題解決を次のプロセスからなるものとする。マルチエージェントシミュレーションを用いた問題解決では、これらのプロセスに対する検討が重要である。

1. モデル化プロセス：対象とする問題について、エージェントの持つ情報や振る舞い、環境をどのように表現するかを検討するプロセス
2. 戦略設計プロセス：多くのエージェントをどのように効果的に協調させ、目的を達成させるかを検討するプロセス
3. 評価プロセス：モデルの妥当性や戦略の有効性をどのように評価するかを検討するプロセス

これらのプロセスを具体的にどのようにおこなうかは、対象とする問題の性質によって異なる。そのため、一般化された方法論を確立することは難しく、実運用には多くの課題が存在する。

本研究では、マルチエージェントシミュレーションを用いた問題解決プロセスにおける課題を明らかとするため、社会的に重要な次の課題に取り組む。

- 地震災害状況に有効な救助戦略の設計：南海トラフ地震などへの備えとして、被害の状況予測や対策の検討はわが国の喫緊の課題である。
- 交通事故要因の究明：発生件数は減少傾向にあるものの、以前として多くの人命が日々失われており、効果的な対策のための要因分析は不可欠である。

これらの事例研究を通じて、今後ますます利用されることが想定される、マルチエージェントシミュレーションを用いた問題解決における課題の抽出に挑戦する。

まず、地震災害状況に有効な救助戦略の設計として、ロボカップレスキューシミュレーションにおける有効な救助戦略を開発し、評価した。ロボカップレスキューシミュレーションは地震災害における救助活動を再現し、マルチエージェントの協調戦略を評価できるベンチマークシステムである。

環境情報を自律的に収集し、適応的に行動する分散型の協調戦略を設計し、実装した。これは災害現場の視界や通信範囲の制限により、エージェントが得られる環境情報が局所的かつ限定的になる状況を考慮したものである。性能評価の結果、提案戦略を実装したエージェント群は、標準的な比較対象エージェント群よりも、効率的な救助活動を達成した。一方で、過剰な建物の倒壊による道路の閉塞など、想定を超える過酷な環境下では、性能が低下することも確認された。この結果は救助戦略の設計において、未知の環境への適応性や頑健性の考慮が重要であることを示している。

次に、交通事故要因の究明として、実際の事事例を分析した。交通事故は車両や歩行者といった交通主体が道路環境上で起こす現象であり、マルチエージェントシミュレーションによる分析が有効であることが予想される。しかし、交通流シミュレータは存在するものの、交通事故そのものを再現、分析可能なマルチエージェントシミュレーションは確立されていない。そこで本研究では、将来的な交通事故のマルチエージェントシミュレーションの実現に向けて、交通事故のモデル化に関する知見獲得を目指した。

具体的には、まず過去のデータから事故の発生しやすい場所と時空間を特定するための手法を開発し、既存手法に対する優位性を示した。次に、事故発生地点とその周辺の事故環境属性との関係を分析した。その結果、事故発生地点に空間的な偏りがあること、その偏りが事故時の違反内容により異なること、正面衝突事故が発生しやすくなるカーブ区間の曲率などを明らかとした。しかし、利用可能なデータの詳細度には限界があり、事故の発生と要因との因果関係を説明するには至らなかった。これは交通事故の精密なモデル化には、より詳細かつ多角的なデータの収集と、その分析が必要であることを示している。

これらの事例研究を通じて、マルチエージェントシミュレーションによる問題解決における課題として、本研究では、次の点を明らかとした。

- 問題の核の抽出（戦略設計）：問題全体に共通して存在する、問題解決に強く影響する核となる要素の抽出が重要である。優れた戦略の設計は、この核に対応した協調動作をエージェントに持たせることと対応する。この核の抽出には、さまざまな環境（問題設定）と戦略の組み合わせの中から、シミュレーションを通じ、それぞれの性質間の関係を明確化していくことが必要である。
- モデル境界の形成（モデル化）：観測可能なデータの限界に伴う、モデル境界は妥当なモデルの構築に対する課題である。この解決には、さまざまなデータを収集・結合するだけでなく、そこから導き出される情報を用いた潜在的要素の補完が必要である。また、こうした情報をいかにして導き出すか、というデータとその関係に対する研究が重要である。

本研究では、これらの課題を明らかとしたが、モデル化、戦略設計、評価のプロセスは相互に依存し、この関連性を考慮した総合的なアプローチが重要である。例えば、戦略設計で重要となる性質はモデル化に必要なデータの種類やその精度を規定する。また、モデルの妥当性はシミュレーション結果の信頼性を左右し、ひいては戦略評価の正当性にも影響する。このように相互に影響し合うプロセス全体を俯瞰し、整合性を保ちながら、進めることが今後のマルチエージェントシミュレーションによる問題解決において重要である。

本研究で抽出した課題は特定の応用分野に限らず、マルチエージェントシミュレーションによるさまざまな問題解決において共通して現れるものと考えられる。これらの解決に向けては、シミュレーション技術の高度化に加え、近年発展の著しい深層学習や生成 AI といった人工知能技術の活用が期待される。

本論文の構成は次のとおりである。第2章では、マルチエージェントシミュレーションの概要と関連研究を述べる。第3章では、ロボカップレスキューシミュレーションにおける救助戦略の設計について述べる。第4章では、交通事故要因の究明について述べる。最後に、第5章では、本研究のまとめと今後の展望を述べる。

本論文は理工系の大学生から研究者までを想定読者としている。特に、本研究に近い研究へ取り組む学生が困ることのないよう、多くの用語等についても解説している。そのため、やや教科書的に、本論文ではいくつかの表現的工夫を施した。本論文やその分野で頻出する用語は、「エージェント」のように強調している。また、本論文の末尾には、参考文献に加え、用語の索引を付している。これは用語から内容を参照したい読者の辞書の利用を想定したものである。タイプライタ体（例：agent）で表記された語は、プログラミングに関連する用語を示すものである。これらは読む際の参考としていただければ幸いである。

第2章

マルチエージェントシミュレーションを用いた問題解決

2.1 マルチエージェントシミュレーション

2.1.1 エージェントとマルチエージェントシステム

本研究で対象とするマルチエージェントシミュレーション (MASim^{*1}: multi-agent simulation) とは、コンピュータ上の仮想空間で複数の自律的に動作する主体を再現し、それらとそれらが活動する環境との相互作用を通じてシステム全体の振る舞いを観察するコンピュータシミュレーションの一つである。この中で、自律的に動作する主体を「エージェント」という。

エージェント (agent) とは、センサを通じて環境を認識し、アクチュエータを通じて、その環境に作用するとみなすことができるもののことである [3]。例えば、人間が行動するときには、目や耳などの感覚器を通じて、周囲の環境を認識し、手や声帯などの効果器を通じて環境へ作用する。このことから、人間は目や耳をセンサ、手の声帯などをアクチュエータとするエージェントとみなせるものの一つである。同様に、カメラ、赤外線センサなどのセンサや、さまざまなモーターなどのアクチュエータを持つロボットや車両といった無機物、さらにはソフトウェアのように物理的に実体が存在しないものも、周囲の環境を認識し、環境へ作用するものであれば、エージェントとみなすことができる。

なお、近年、大規模言語モデル (LLM: large language model) を用いた「AI エージェント」という言葉がある。ただし、本論文における「エージェント」はこれとは異なることに注意されたい。エージェントは「何かに作用するもの」という語源がある。そこから英単語としては「代理人」という言葉として用いられる。AI エージェント (agentic AI) は ChatGPT や Gemini などのチャットボットなどを介して、人間が自然言語で与えた目的を分割し、自律的に解決するものをいう。自律的に動作する点において、本論文のエージェントと共通点はあるものの、これらは基本的に単体で問題解決をおこなう。これに対して、本論文におけるエージェントはあくまでも、複数のエージェントで協力しながら問題を解決するものとして認識されたい。これは Minsky (1986) が『心の社会』において定義した、人工知能的な文脈で初めてエージェントという言葉を導入しているが、ここで説明される「心を構成する小さなプロセス一つひとつ」をエージェントと呼ぶという流れを汲むものである [4]。

マルチエージェントシミュレーションで再現される、複数のエージェントが相互に作用し合うシステムをマルチエージェントシステム (MAS: multi-agent system) という。マルチエージェントシステムでは、

^{*1} マルチエージェントシステムを「MAS」とすることが多いが、マルチエージェントシミュレーションを「MAS」としている論文もある。文献を読む際には、注意されたい。

エージェント全体の目標と、各自の目標の両方を達成できるように、各エージェントは行動し、また相互に協調する。人間同士が何らかの目標を達成するために、互いに協力する社会システムも、このマルチエージェントシステムで表現できるものの一つである。

マルチエージェントシミュレーションは対象とする事象を解析し、一つの数式にまとめるような従来のシミュレーション手法とは異なり、個別のエージェントとその環境をプログラムなどにより表現することで、複雑な事象をその複雑さを保ったまま再現できる。このように対象の事象がエージェントや環境として個別に表現されているため、新しい要素を追加したり、既存の要素を変更したりといった拡張や変更が柔軟に可能である。また、シミュレーションから、さまざまな条件下での、システム全体と個別のエージェントの両方を観察できる。そのため、対象とするシステムの理解や問題解決策の検討に役立てられる。

2.1.2 マルチエージェントシミュレーションの利用事例とその課題

近年では、COVID-19の鎮静化のために、さまざまな粒度に基づくマルチエージェントシミュレーションが取り組まれたこともあり、マルチエージェントシミュレーションは社会問題の解決策を検討するツールとして、多くの注目を集めている。この一例として、Castroらは従来の人から人への感染過程に加え、病院資源や空間ごとの人口密度をシミュレーションにより再現した [1]。ブラジルのパッサ・ヴィンテという地域を対象に、パンデミック発生後、365日分のデータを用いて、シミュレーションをおこなっている。その結果、500日目までの感染状況を精度良く推定でき、対策検討への有用性が示されている。

この他にも、マルチエージェントシミュレーションを応用した事例には、災害救助、金融、電力、ゲーム、都市交通など、さまざまなものを対象とするものが存在する。このように近年、マルチエージェントシミュレーションはさまざまな分野で活用されている。しかしその一方「マルチエージェントシミュレーションをどのような流れに基づいて実現し、検討を進めればよいか？」という適用に関する体系化はこれまで考えられていない。そのため、新たな問題を対象にマルチエージェントシミュレーションによる解決を図る際には、何をエージェント、環境とするかから、解決方法の検討および評価までを試行錯誤的に試みるほかない。

さらに、対象とする問題のメカニズムが十分に解明されていない場合も多い。そのため、「シミュレーションモデルが現実を適切に反映しているか？」というモデルの妥当性評価が課題として挙げられる。この課題はモデル化における粒度の粗さや、入力データの偏りなどに起因する。また、妥当性の十分さはひいてはシミュレーションから得られた結果の信頼性にも関わっている。特に、対象が物理的な現象から社会的な現象へと近づくほど、人間の心理を介するために、対象を客観的に捉えることが難しくなり、モデルの妥当性を確保することが一層困難となる。

このような課題があるにも関わらず、将来予測や対策検討が急務となる社会問題に対しては、意思決定の支援するための有力な選択肢として、マルチエージェントシミュレーションは積極的に活用されている。事象を完全に再現できなくとも、政策介入の効果比較やシナリオ評価をおこなうための実用的な枠組みとして一定の役割を果たしており、COVID-19対策、交通政策、災害対応など、行政を中心とする分野でその活用が進められている。

2.2 マルチエージェントシステムのモデル

マルチエージェントシステムは図 2.1 のようなモデルとして表現される。ここでいう、モデル (model, 模型) とは対象物を抽象化した数式や図などのことを指す。エージェントは環境から得られる情報に基づき、その環境へ作用することで、自律的に行動する主体である。ここで、エージェントが環境から情報を得ることを知覚 (percept) といい、環境へ作用することを行動 (action, 行為) という。




図 2.1 マルチエージェントシステムのモデル

それぞれのエージェントは環境を介して、相互に作用し合っている。マルチエージェントシステムでは、このように個別のエージェントと環境を表現し、その相互作用から複雑な現象を捉える。

さらに、エージェントは図 2.2 のように表現される [3]。エージェントがどのような知覚があるときに、どのような行為をおこなうかはエージェントの内部で対応付けられている。図中では「？」が対応関係を示す部分であり、知覚した情報を行為へ変換する役割を持つ。この対応関係を具体的に記述したものをエージェントプログラム (agent program) と呼ぶ。

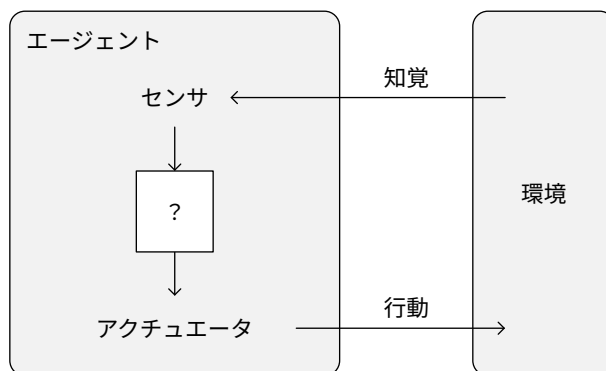


図 2.2 エージェントのモデル

エージェントプログラムには、知覚と行為の対応関係に基づき、単純なものから、複雑なものまで存在する。エージェントはこのエージェントプログラムのレベルに応じて次のように分類される [5]。

反射エージェント (reflex agent) あらかじめ決められた複数のルールに基づいて、動作するエージェントである。環境の状態がルールにマッチしたときに、対応する行為を実行する。「目の前の壁への衝突を避ける」といったの反射的な行為を表現できる。

内部状態に基づくエージェント (model-based reflex agent) 反射エージェントに内部状態を追加したエージェントである。エージェントは自身の状態を保持する記憶装置を持ち、現在の状態だけでなく、過去の状態へも対応することができる。

目標に基づくエージェント (goal-based agent) 内部状態に目標を組み込んだエージェントである。目標を内部状態に持つことで、行為から次の状態を予測し、目標に近づく行為を選択できる。

効用に基づくエージェント (utility-based agent) 目標の代わりに効用関数を使用するエージェントである。効用関数により、ある行為を実行したときの効用*²を算出する。目標が複数あり、それらがトレードオフ関係*³にある場合などに妥結策を取ることができる。

学習エージェント (learning agent) 目標や効用から、ルールの評価を評価し、修正するエージェントである。また、保持するルールだけでは、すべての状態へ対応できないため、適宜新たなルールを生成する。加えて、ルールを無限に持つこともできないため、価値の低い不要なルールを削除する。このようにして、人間の学習のように過去の経験を活かして、環境へ対応する機構を持つ。

本論文では、このようなエージェントの中でも特に、シミュレーション内で知覚と行為を通じて自律的に行動し、状況に応じた意思決定をおこなう主体を「エージェント」と呼ぶ。例えば、災害救助シミュレーションの場合には、助けを求める被災者や、救助活動をおこなう救助部隊がこれに該当する。

2.3 本研究の目的

本研究では、マルチエージェントシミュレーションを用いた問題解決プロセスを次の3段階から構成されるものとする。

1. モデル化プロセス：問題を解決するために必要なエージェントと環境を定義し、マルチエージェントシミュレーションを実現するプロセスである。エージェントや環境を定義するためには、対象の問題において、それぞれに該当するエージェントや環境の要素を明らかとする必要がある。また、各要素の状態や相互作用をモデル化するために、エージェントの意思決定や取り得る行動、環境が持つ要素、取り得る状態などを明らかとする必要がある。
2. 戦略設計プロセス：マルチエージェントシミュレーションから、問題解決のための戦略を設計するプロセスである。シミュレーションにより再現した問題に対し、有効な戦略を設計するためには、シミュレーションの実行結果を分析し、問題解決に有効な戦略を見出す必要がある。また、マルチエージェントシミュレーションで扱う問題はさまざまな条件を持つため、それらの条件に応じた戦略を設計する必要がある。
3. 評価プロセス：エージェントや環境のモデルの妥当性や、設計した戦略の有効性を評価するプロセスである。得られた結果の信頼性は、エージェントや環境のモデルの妥当性に依存する。そのため、モデル化プロセスにおけるこれらの定義が目的に対して適切なものであったかを評価する必要がある。また、戦略設計プロセスにおいて設計した戦略が、対象とする問題に対して有効であるかを評価する必要がある。

マルチエージェントシミュレーションを用いた問題解決においては、これらの3つのプロセスを適切に検討することが重要である。しかし、各プロセスで必要となる具体的な内容は、対象とする問題によって大きく異なる。このため、汎用的な方法論を確立することは容易ではない。さらに、実際の運用においては、明確な手順が確立されていないことから、試行錯誤的に各プロセスを進めざるを得ず、多くの課題が生じる。本研究では、これらの課題を明らかとし、整理することで、今後ますます利用が広がると考えられるマルチエージェントシミュレーションを用いた問題解決の発展に貢献することを目的とする。

そこで本研究では、次の社会的に重要な問題を対象として、マルチエージェントシミュレーションを用い

*² 目標をどれだけ満たすかという度合いのこと。

*³ 一方の目標へ近づこうとするときに、もう一方の目標から遠ざかるような状態のこと。いわゆる「あちらを立てれば、こちらが立たず」の状態を指す。

た問題解決プロセスを検討する。

- 地震災害状況に有効な救助戦略の設計：地震災害発生時において、多くの市民を救助するための有効な救助戦略を設計する。
- 交通事故要因の究明：交通事故の発生要因を究明し、交通事故削減のための有効な対策を検討する。

これらの問題はマルチエージェントシステムとして表現する際、目標に関する性質が異なる。救助戦略の設計では、市民を救助する救助部隊をエージェントとして、その戦略を検討する。ここで、すべての救助部隊は多くの市民を救助するという共通の目標を持つ。したがって、各エージェントの目標はシステム全体の目標と一致する。一方、交通事故要因の究明では、車両や歩行者をエージェントとして、事故被害低減のための対策を検討する。ここでは、各エージェントは通勤やドライブなど、異なる目標を持つ。したがって、各エージェントの目標と、システム全体の目標が一致しない。このように異なる性質を持つ問題に対する検討することで、広くマルチエージェントシミュレーションを用いた問題解決に資する知見獲得が期待される。

第3章

ロボカップレスキューシミュレーションにおける救助戦略の設計

3.1 救助戦略の設計を通じた課題の明確化

本研究では、今後のさまざまな問題に対するマルチエージェントシミュレーションを用いた問題解決に資するために、この課題を明らかとする。この課題を明らかにするためには、マルチエージェントシミュレーションを実際に利用して、問題を解決する事例から、その過程で生じた課題を収集し、整理することが必要であると考えられる。本研究では、この事例の一つとして、都市直下型地震を対象とした災害救助問題を扱う。

マルチエージェントシミュレーションを用いた問題解決では、まず対象の問題をモデル化し、シミュレーションを実現する必要がある。それから、そのシミュレーションを用いて、エージェント群の協調戦略を設計し、問題解決に取り組むこととなる。一方、本研究が扱う災害救助問題では、すでにこれを対象とするマルチエージェントシミュレーションとして「ロボカップレスキューシミュレーション」が存在する。また、このシミュレーションを用いた、多くの研究が展開されている。そのため、本研究ではこのシミュレーションを用いることで、災害救助問題についてのモデル化プロセスを省略する。つまり、エージェント間の協調戦略、ここでは市民を救助するための救助戦略を設計することから始めることとする。

マルチエージェントシミュレーションを用いた問題解決では、全体の目的達成のために、どのようにエージェント群を協調させるかが肝要である。マルチエージェントシミュレーションでは、多数のエージェントと環境が相互に作用し合う。また、そこから作り出される状態は無数に存在する。そのため、問題解決のために望ましいエージェント群の協調を実現するには、多数存在する要素や関係の一つひとつを考慮し、エージェント間をどのように協調させると、目的の状態に近づくかを検討しなければならない。

これは災害救助問題を対象としたときの救助戦略の設計においても同様である。災害救助問題では、さまざまな被災状況に対し、救助部隊をどのように協調させると、多くの市民を救助できるか？ という問題を扱う。本研究では、これを解決する救助戦略の設計と評価を通じて、マルチエージェントシミュレーションを用いた問題解決における課題を探る。災害救助問題は市民の救出順序や搬送経路の選択など、異なる目的の達成を要する、さまざまな部分問題を含む。これらの問題は一般にマルチエージェントシステムで研究対象とされる問題にもなっている。したがって、救助戦略の設計では、これらの問題の解決やその解決策の組み合わせの効果を図ることも必要となる。よって、災害救助問題を対象とすることで、広くマルチエージェントシミュレーションの戦略設計プロセスに通ずる課題を検討できると考えられる。

3.2 ロボカップレスキューシミュレーションのモデル

3.2.1 ロボカップレスキューシミュレーションの概要

ロボカップレスキューシミュレーション (RRS^{*1}: RoboCupRescue Simulation) とは、都市直下型の地震災害と、その際の救助活動を再現するコンピュータシミュレーションである [6]。具体的には、建物の倒壊や、それに伴い生じる瓦礫、道路網の寸断といった地震に伴う災害が表現される。また、被災した市民や彼らを救助する救助部隊といった災害状況下の人々と、その行動が表現される。

ロボカップレスキューシミュレーションは被災者や救助部隊をエージェントとするマルチエージェントシミュレーションとしてモデル化されている。エージェントである被災者や救助部隊は、コンピュータ上に構築された仮想的な都市の中で、それぞれ自律的に行動する。

ロボカップレスキューシミュレーションで表現される要素には、被災者 (市民)、救助部隊、建物、道路、指令所、避難所などがある。これらの要素はさまざまな属性を持ち、それらの属性から個々の状態が表現される。また、この状態はシミュレーションの時間進行に伴う、エージェントの行動、負傷や災害状況の進行などによって変化する。これらの要素については第 3.2.2 項で詳述する。

ロボカップレスキューシミュレーションでは、現実の 1 分に相当する時間を単位として、要素の状態を離散的に扱う。このように離散化された時間 (離散時間) を扱うシミュレーションでは、時間の進行をシミュレーションステップという単位で管理する。ロボカップレスキューシミュレーションのエージェントは、毎シミュレーションステップ、周囲の環境からの情報収集と、その情報に基づく行動決定を繰り返すものとしてモデル化されている。また、ロボカップレスキューシミュレーションでは、地震発生後の約 5 時間を対象とし、300 シミュレーションステップの計算を実行する。

なお、ロボカップレスキューシミュレーションの時間は離散時間としてモデル化されているが、すべての要素の状態が離散的に変化するというわけではない。例えば、エージェントの移動や体力の低下などは連続的に変化するものであり、連続時間で扱うのが自然である。しかし、連続時間を扱うシミュレーションは計算コストが高く、シミュレーションの状態に対する解析が難しい。そのため、連続的な変化を持つ要素についても、シミュレーションステップ間の微小時間に対する状態変化を内部的に計算したり、シミュレーションステップに合わせた変化量から状態を更新したりすることで、その状態を離散的に表現している。

シミュレーションステップごとの被災状況や救助活動の様子は、可視化システムで視覚的に確認できる。この様子は、例えば図 3.1 のように可視化される。この例では、愛知県名古屋市中区の栄地区をもとに作成した仮想都市で、シミュレーションが実行されている。図中の緑や赤などの小さな円のそれぞれがエージェントを表す。各エージェントは灰色の多角形で表現された道路を動き回り、仮想都市での情報収集、避難行動、救助活動をおこなう。

ロボカップレスキューシミュレーションでは、救助部隊が多くの市民を救助するために、どのように他の救助部隊と協調するかを、救助戦略として開発する。また、この救助戦略をシミュレーション終了時に生存していた市民の数や体力から評価できる。この評価を通じて、ロボカップレスキューシミュレーションは救助戦略として実装されたマルチエージェントシステムを評価するベンチマークシステムとしても利用される。

災害救助問題は広くマルチエージェントシステムで研究対象として扱われるさまざまな問題を内包する複合的な問題である。ロボカップレスキューシミュレーションはこの複合的な問題を表現し、問題の性質やその解法を研究できるシステムとして、マルチエージェントシステムの研究者に利用されている。さらに、より良い救助戦略の開発を競う競技会が開催されている。この競技会は自律移動型ロボットによる競技会であ

*1 「RCRS」と呼ばれることもある。




図 3.1 栄（愛知県名古屋市中区）をモデルとした仮想都市におけるシミュレーションの様子

るロボカップのリーグの一つとして開催されている。毎年国際大会では、さまざまな国から参加者が集まる。このようにロボカップレスキューシミュレーションの救助戦略は、マルチエージェントシステムを対象とする研究者、競技会の参加者など、広く国際的に開発がおこなわれているものとなっている。

3.2.2 ロボカップレスキューシミュレーションの要素

ロボカップレスキューシミュレーションには、市民、救助部隊、指令所、建物、道路、避難所などのさまざまな要素が存在する。これらの要素をエンティティ (entity) と呼ぶ。エンティティの種類を図 3.2 に示す。

ロボカップレスキューシミュレーションでは、エージェントも含め、すべての要素がエンティティとして扱われる。これらのエンティティのうち、市民、救助部隊、指令所の3種類がエージェントとして動作する。つまり、これらのエンティティは自律的に行動し、環境と相互に作用するものとなっている。建物、道路、瓦礫といった他のエンティティは、環境としてエージェントと相互に作用する要素として定義されている。

エージェントのうち、市民と救助部隊は自ら移動できるが、指令所は特殊な建物として定義されており、移動することはできない。また当然ながら、他の建物、道路、瓦礫についても移動することはできない。救助活動をおこなうエージェントである、救助部隊および指令所は「消防」「救急」「土木」という3種類に分かれており、これらはそれぞれ役割が異なる。以降、これらのエンティティのそれぞれについて説明する。

なお、以降本論文では戦略を説明するためなど、図中の表現において、ロボカップレスキューシミュレーションの状況を図 3.2 に示した可視化システム上で描かれる図形で表現する。これは例えば、市民は緑色の円形のアイコン、道路は灰色の多角形で表現するということである。これらの表現はロボカップレスキューシミュレーションをすでに利用している読者や、本論文を参考に実験する読者に向けたものであり、紙面上の情報と可視化システム上の情報とを対応させやすくするためのものである。

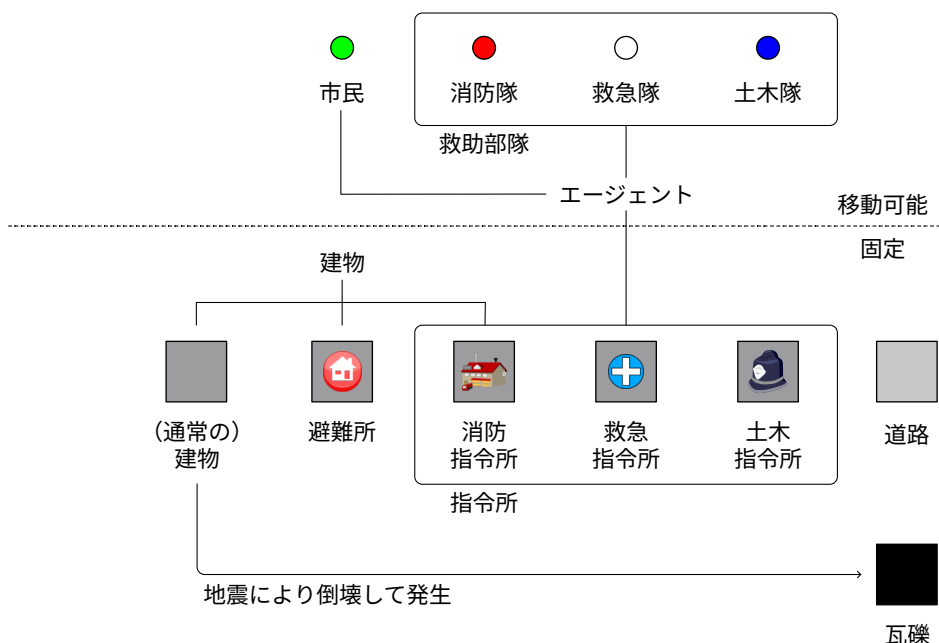


図 3.2 ロボカップレスキューシミュレーションのエンティティの種類と可視化システム上での表現（アイコン）

市民を表現するエンティティ

市民エージェント（civilian）は地震により建物の瓦礫に埋もれて動けなくなっている市民や、避難所へ避難する市民を表現したエージェントである。ここで、1体の市民エージェントが表現する人間の数は1人とは限らない。この数は基本的に5人から10人ほどのグループが想定されている。ただし、この人数も厳密に決定されているものではない。1体のエージェントが表現する人数、構成等は、対象としたい問題に合わせてるように、抽象化されている。

ロボカップレスキューシミュレーションでは、最初のシミュレーションステップで、まず地震が発生する。このとき、建物内にいた市民は倒壊した建物の下敷きとなり、負傷し、生き埋めとなる。一方、建物の外にいた市民は自力で避難行動をおこなう。

負傷した市民は、自力で移動することができない。また負傷に伴い、時間の進行とともに体力が減少する。最終的に体力がなくなると、市民は死亡してしまう。この体力の減少は救助部隊に救出され、避難所内の病床に着くまで継続的に進行するようになっている。

負傷していない市民は、自身から最も近い避難所へ向けて、最短経路で移動する。この最短経路は道路の経路距離のみを評価したものになっている。つまり、道路の状況は考慮されていないため、瓦礫により通行不能となっている場合には、市民はこれを解決できず、そこで留まるようになっている。

可視化システムでは、市民エージェントは図 3.3 に示すように、緑色の円形のアイコンで表現される。市民と後述する救助部隊は体力を持っており、残りの体力が少なくなるほど、その色が暗くなるようになっている。そのため、負傷した市民は暗い緑色で表現される。また死亡した市民は、アイコンの色が完全な黒色となる。




図 3.3 市民エージェントとその状態

救助部隊を表現するエンティティ

救助部隊エージェント (rescue platoon) は市民を救助するために活動する、救助部隊を表現したエージェントである。この救助部隊エージェントは1体が1部隊の救助部隊を表現しており、この部隊は複数人の人間、救助ロボット、救助車両等から構成されている。なお、この人数や構成等の詳細は市民エージェントと同様、対象としたい問題に合わせてられるように、抽象化されている。

救助部隊エージェントには、消防隊、救急隊、土木隊の3種類が存在する。それぞれの救助部隊エージェントはそれぞれ異なる役割を持つ。

消防隊エージェント (fire brigade) は崩れた建物の下敷きとなり、生き埋めとなってしまった市民を助け出すエージェントである*2。ここで、消防隊が埋没状態にある市民をそこから助け出す行動を、総合的な救助活動と区別して「救出」という。生き埋めの状態にある市民は、そうでない負傷者よりも体力が早く減少する。そのため、消防隊はこのような状況にある市民をいち早く発見し、救出する必要がある。

消防隊エージェントは可視化システムでは、図 3.4 に示すように、赤色の円形のアイコンで表現される。消防隊は埋没した市民のいる建物へ移動し、その市民を救出する。消防隊は救出状態になると、アイコンの色が黄色に変化する。救出作業が完了した消防隊は、他に救出が必要な市民の探索に向かう。一方で、救出された市民は負傷しており、自力では動けないため、その場に留まる。この市民を生存させるには、後述する救急隊による避難所への搬送が必要である。

なお、エージェントが1シミュレーションステップで実行できる行動は1つのみである。したがって、消防隊の救出は1シミュレーションステップにつき、1回のみ実行でき、移動との併用はできない。また、市民の埋没状態の解決に必要な救出回数(時間)は埋没の度合いに応じて異なる。埋没の度合いの大きい(深く埋まっている)市民を救出するには、複数のシミュレーションステップに渡って継続的に救出行動を繰り返す必要がある。これに対し、複数の消防隊で1体の市民の救出に当たることで、その数だけ救出にかかる時間を短縮できるようになっている。

*2 ロボカップレスキューシミュレーションの消防隊は現実のレスキュー隊に近い働きをする。2020年までのロボカップレスキューシミュレーションでは、地震に伴って発生する火災がシミュレーションされていた。消防隊はその消火活動を主な役割としていた。2021年以降は石造りの建物が多い欧米での震災状況を反映し、また問題を単純化するために、この火災シミュレーションが標準から外された。その結果、現在の仕様となっている。




図 3.4 消防隊エージェントと市民の救出の流れ

救急隊エージェント (ambulance team) は消防隊により救出された市民を避難所へと搬送する役割を持つエージェントである。救出された市民は、埋没状態から脱するものの、負傷により体力が継続的に低下していく。この状態は避難所へ搬送され、病床に着くまで継続的に進行するようになっている。救急隊はこれらの市民の体力の低下を止めるために、いち早く避難所へ搬送する必要がある。

救急隊エージェントは可視化システムでは、図 3.5 に示すように、白色の円形のアイコンで表現される。救急隊は救出が完了している市民を発見し、その市民を持ち上げる。次に、避難所へ向かい、到着したら市民をそこへ降ろす。可視化システムでは、救急隊が市民を持ち上げた状態は、救急隊と小さく描かれた市民のアイコンが重ねて描画される。

ここで、救急隊が市民を持ち上げる行動を「搬入」という。またこれに対して、救急隊が市民をその場に降ろす行動を「搬出」という。これらの行動は現実における「担架へ負傷者を乗せる／降ろす」「救急車へ負傷者を乗せる／降ろす」といった行動が抽象化されたものである。なお、これらの行動により、搬送できる市民の数は救急隊 1 体につき、1 体である。消防隊のように複数の救急隊で搬送する時間を短縮するといったことはできない。

搬送が完了した救急隊は、他の搬送を待つ市民を探索する。一方、避難所に送り届けられた市民は、病床が空いている場合、すぐにそこで治療を受ける。しかし、空いていない場合には、市民は病床が空くまでその場で待機する。ただし、待機中にも市民の体力は減少していくため、この待機中に死亡してしまう場合もある。そのため、救急隊はこのような状況を防ぐために、病床の空き状態を考慮して、搬送先を選択する戦略が求められる。

土木隊エージェント (police force^{*3}) は道路を啓開^{けいかい}し、通行可能にする役割を持つ救助部隊エージェントである。啓開とは、瓦礫などにより通行不能となった道路に対して、瓦礫の撤去や段差修正などの作業から、救助のための通行を確保する行動をいう [7]。ロボカップレスキューシミュレーションでは、建物が倒壊すると、その瓦礫が周囲の道路へ広がる。周囲の道路はこの瓦礫により通行不能となる場合がある。通行不能となった道路は他の救助部隊エージェントの移動の妨げとなり、救助活動が困難となる。土木隊は他の救助部隊の活動を可能とするために、これらの道路の通行を確保する役割を持つ。

土木隊エージェントは可視化システムでは、図 3.6 に示すように、青色の円形のアイコンで表現される。瓦礫は建物の壁面から一定範囲内に広がり、その範囲によっては道路を通行不能にする。土木隊はこの瓦礫に対して、啓開行動をおこなう。土木隊の啓開は消防隊の救出と同様に、1 シミュレーションステップにつ

^{*3} 「police force」は本来、警察部隊という意味であるが、ロボカップレスキューシミュレーションでは歴史的な経緯から、この名称となっている。ロボカップレスキューシミュレーションでは、警察は登場しないため、注意されたい。

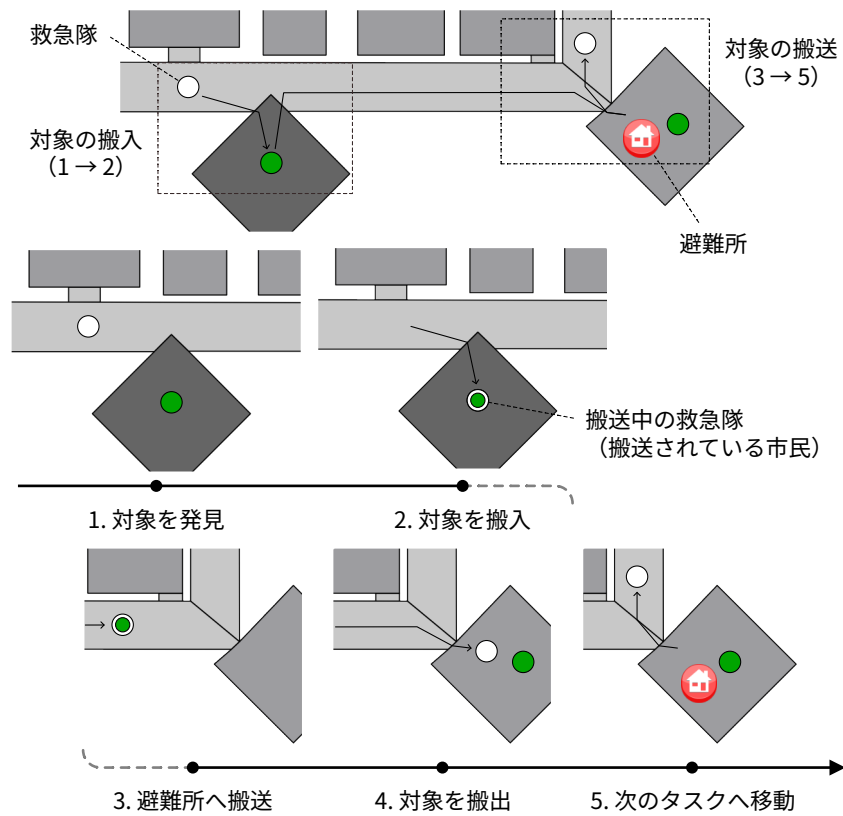


図 3.5 救急隊エージェントと市民の搬送の流れ

き, 1 回のみおこなうことができる。




図 3.6 土木隊エージェントと瓦礫の啓開

この土木隊の啓開行動には, 2 種類の方法が用意されている. 一つは図 3.7 に示す矩形啓開である. 矩形啓開は指定した方向に向けて, 一定の幅と長さの矩形領域を啓開する方法である. この幅 (啓開幅員) と長さ (啓開距離) は, あらかじめ土木隊の能力として設定されている. また, 1 シミュレーションステップで啓開できる瓦礫の量 (啓開量) には限りがあり, 対象のがれきの量がこれを超える場合には, 実行後の啓開距離が短くなるようになっている.




図 3.7 土木隊エージェントの矩形啓開とその効果

もう一つは図 3.8 に示す個別啓開である。個別啓開はがれきを直接指定して、そのがれきの周囲を啓開する方法である。この方法では、対象のがれきが全体の面積を収縮させるように、その周囲が啓開される。土木隊は基本的に矩形啓開を用いるが、がれきの形状が複雑かつ、その量が多いため、啓開範囲に対象を収めるのが難しいという場合には、個別啓開を用いた方が効果的に啓開できる場合が存在する*4。



図 3.8 土木隊エージェントの個別啓開とその効果

このように救助部隊はそれぞれの種類に応じて異なる役割を持つ。また、基本的に市民を救助するまでには、土木隊による道路啓開、消防隊による救出、救急隊による搬送という3つの行動が必要であり、それぞれの行動には実行順序に依存関係がある。そのため、多くの市民を救助するには、互いの状況を考慮した各救助部隊の協調行動が鍵となる。

救助部隊は互いの状況を把握するために、周囲のエージェントを直接観察するか、通信による情報連携が取り得る手段として存在する。ただし、救助部隊の視認能力には範囲があるため、直接観察できる情報は限定されている。また、救助部隊の通信にも、共有可能な情報の種類や量に制限がある。加えて、通信は送信から受信までに1シミュレーションステップかかり、情報が遅れることや、ノイズがあることなど、常に最新かつ完全な情報を得られるわけではない。そのため、救助部隊の情報共有に関する戦略を組み立てる際には、このような課題を考慮する必要があるようになっている。

救助部隊がおこなう通信には、音声通信と無線通信の2種類が存在する。音声通信は救助部隊の声と聴覚をモデル化したものであり、近くにいる救助部隊と情報を共有する手段である。また、市民は救助を求めているときに、一定確率で助けを求める声を発するが、これも音声通信として扱われる。救助部隊は音声通信により1シミュレーションステップにつき、1つのメッセージを送信できる。

一方、無線通信は音声通信と異なり、通信距離に制限がないものとなっている。また、救助部隊だけでなく、後述する指令所との通信にも利用する。さらに、1シミュレーションステップに複数のメッセージを送

*4 個別啓開は矩形啓開と比較して、啓開のモデル化としてはやや不自然である。特に、瓦礫が道路を完全に塞いでいる場合には、土木隊のいる位置と反対側の側面からも啓開が進行するなど、現実的ではない挙動が発生する。これは過去のロボカップレスキューシミュレーションにおいて、空間モデルが道路ネットワークとして表現されていたときのなごりである。当時のモデルでは、道路や瓦礫が領域を持っていないため、道路エッジ上の瓦礫を取り除く行動として個別啓開のみが啓開行動として用意されていた。一方、現在のロボカップレスキューシミュレーションにおいても、幾何モデルの設計上、土木隊が完全に瓦礫に埋もれた場合など一部の特殊な状況においては、個別啓開でしか脱出できないことがある。そのため、多くの戦略で個別啓開が現在も利用されている。

信できる。ただし、このメッセージの数と量（帯域幅）には制約がある。無線通信には、通信チャンネルが用意されており、1シミュレーションステップに通信可能なメッセージの数や量といった制約は通信チャンネルごとに設定されている。したがって、各通信チャンネルをどのように利用するかも、救助戦略の一つの重要な要素である。また、通信インフラが地震により破壊され、無線通信が利用できない場合もある。この場合、救助部隊にはそれぞれが直接視認した情報や音声通信のみから、災害状況を把握および推測することが求められる。

指令所を表現するエンティティ

指令所エージェント（rescue centre）は救助部隊の活動を指揮する施設を表現したエージェントである。救助部隊や避難所からの情報を集約し、全体の状況を判断して、各救助部隊に指令を出す役割を持つ。指令を受けた救助部隊はその指令に優先的に従い、行動する。

シミュレーションにおいて、指令所は特殊な建物として配置される。建物であるため、市民や救助部隊といったエージェントとは異なり、移動することはできない。また、指令所は情報の収集や共有を無線通信のみを用いておこなう。そのために指令所には救助部隊とは別の専用の通信チャンネルが割り当てられている。

指令所は救助部隊と同様に、消防指令所、救急指令所、土木指令所の3種類が存在する。各指令所は可視化システムでは、それぞれ図3.9に示すように対応するアイコンが建物に表示される。指令所は各々に対応した救助部隊へ指令を出す。また、指令内容を決定するために、指令所は無線通信により各救助部隊から情報を収集するが、救急指令所のみ、加えて避難所の病床の利用状況を把握できるという違いがある。

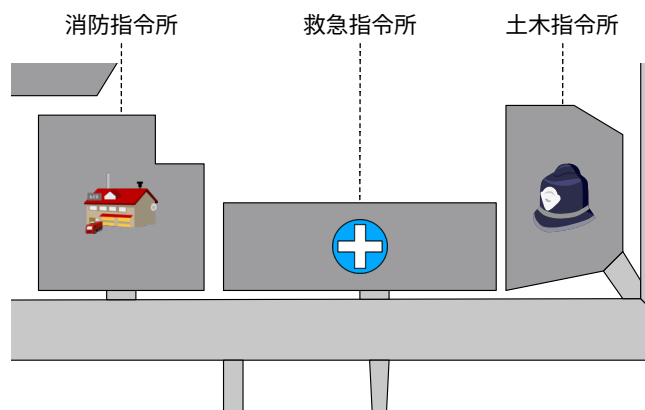


図 3.9 指令所エージェントの種類

環境を表現するエンティティ

エージェントが活動する災害環境は主に建物と道路という2種類のエンティティで構成されている。これらのエンティティは現実の地図情報をもとに定義され、多角形の領域として表現される。市民や救助部隊はこれらの領域内を移動し、避難や救助活動をおこなう。

建物および道路は他の建物または道路と互いに接している辺で接続されている。これらの繋がった領域内を市民や救助部隊は自由な方向へ移動できる。また、すべての建物と道路は孤立することなく、繋がっている。そのため、瓦礫に通行が阻まれている場合を除き、市民は必ず避難所へ移動でき、救助部隊はすべての市民がいる場所へ救助へ向かうことができるようになっている。

なお、ロボカップレスキューシミュレーションでは、マクロな災害状況を対象に再現している。そのため、建物内部の構造や階層、道路の勾配など、各空間の詳細は表現されていない。また、建物も道路も平面的に

扱い、立体交差や地下構造物は存在しないものとなっている。

建物には、通常のものの特異な役割を持つものが存在する。通常の建物は地震により確率的に倒壊し、内部にいた市民や救助部隊は負傷し、生き埋めとなる。また、建物の倒壊には度合いが存在し、その度合いに応じて周囲に広がる瓦礫の量や、内部の市民や救助部隊に与える負傷の度合いが変化する。

建物の倒壊の度合いに対する瓦礫の広がり方の例を図 3.10 に示す。この図では、左側に建物が 50% 倒壊した場合、右側に同じ建物が 70% 倒壊した場合を示している。瓦礫は倒壊した建物の壁面から一定範囲内に広がる。図から分かるように、この距離が建物の倒壊の度合いに応じて変化する。50% 倒壊した建物の方では、瓦礫が道路に掛かっているが、通れる部分が残っているのに対し、70% 倒壊した建物の方では、道路が完全に塞がれていることが分かる。このように建物の倒壊の度合いによって、道路の通行状況や、それに伴う道路啓開の必要性が変わるようになっている。




図 3.10 建物の倒壊の度合いと瓦礫の広がり

一方、特殊な建物には、避難所と指令所がある。これらの建物は地震を受けても倒壊しない。避難所には病床があり、負傷した市民が治療を受ける場所としての役割を持つ。また、救助部隊も負傷している場合には、避難所でそれを回復することができる。指令所は無線通信により、それぞれに対応する救助部隊への指揮をおこなう役割を持つ。なお、都市に避難所は必ず設置されているが、指令所は設置されていない場合がある。また、地震で通信インフラが破壊されている場合には、指令所は機能しない。

道路は現実の道路に合わせて作られている。そのため、道路幅員には広いものから狭いものまで存在するが、標準的には片側 1 車線の道路を想定した 7m の幅員を持つものが多い。これに対し、道路上で移動する市民と救助部隊は力学的に動作しており、それぞれ半径 20cm、50cm の平面的な粒子としてモデル化されている。互いに衝突判定を持ち、接触した場合には互いに押し合う力が働く。また、道路が他の道路や建物と接続していない辺には衝突判定があり、これらは市民や救助部隊の移動に対して、壁のように振る舞う。そのため、狭い道路に過剰な数の市民や救助部隊が通過しようとした場合には、互いに衝突し、移動を妨げ合うことがある。このようにして、道路の交通容量が物理的に表現されている。

建物と道路に加えて、瓦礫も環境を表現するエンティティの一種である。図 3.10 に示したように、瓦礫は倒壊した建物の壁面から一定範囲内に広がり、道路上にのみ生成されるエンティティである。瓦礫には衝突判定があり、市民や救助部隊の移動を妨げる。また、これらのエージェントがいる位置に直接瓦礫が発生した場合、土木隊による啓開がなされるまで、エージェントはその位置から動けなくなる。距離の近い建物が倒壊した場合には、それらの瓦礫が重なり合うようにして生成されることもある。このような場合には、その重なった部分の瓦礫の量が多くなり、啓開に時間がかかるようになっている。

瓦礫は他のエンティティと異なる点として、シミュレーションの進行中に形状や数が増えるという特徴がある。道路および建物は開始時から形状や数が増えないが、瓦礫は最初のシミュレーションステップで地震の発生に伴い、生成される。また、土木隊の啓開行動により、瓦礫の一部または全部が撤去されることで、形状や数が増える。そのため、土木隊は互いにどの瓦礫をどの程度撤去したかを把握し、そのもとで自身の適切な啓開行動を決定する戦略が求められる。

3.2.3 ロボカップレスキューシミュレーションのシステム

第 3.2.2 項で述べたように、ロボカップレスキューシミュレーションではさまざまな種類のエンティティから、災害状況が再現されている。これらのエンティティの動作や相互作用を実現するために、ロボカップレスキューシミュレーションのシステムでは、複数のシミュレータが組み合わさって動作している。ここでは、ロボカップレスキューシミュレーションのシステム全体と、各コンポーネントについて説明する。

ロボカップレスキューシミュレーションはサーバ・クライアント方式のシステムである。シミュレーションサーバとクライアントの構成を図 3.11 に示す。

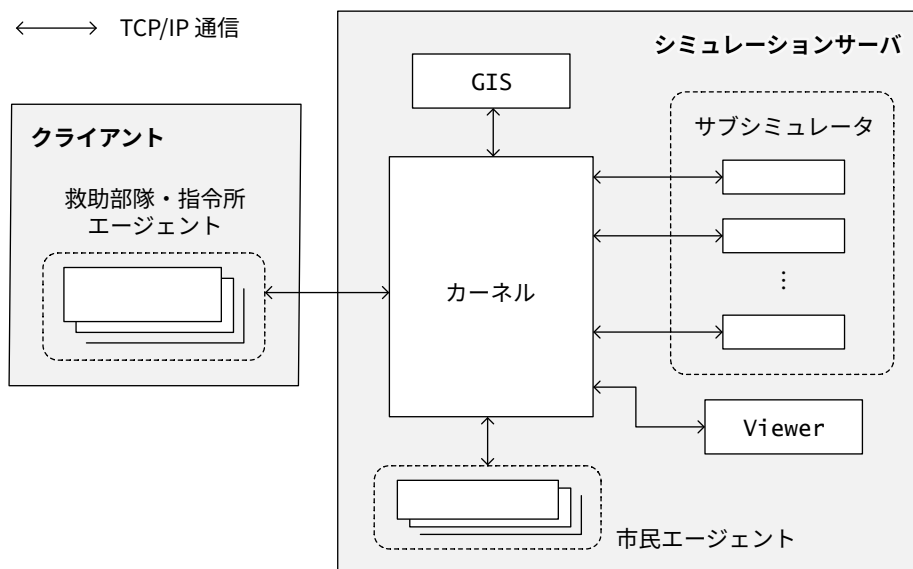


図 3.11 ロボカップレスキューシミュレーションのシステム構成

なお、市民エージェントは救助部隊エージェントと同様の仕組みで動作するが、通常は開発の対象とならない。そのため、ここではシミュレーションサーバの一部として扱っている。

シミュレーションサーバはカーネル (kernel) という各コンポーネントを繋ぐ役割を持つプログラムを中心に構成されている。サーバのコンポーネントには、複数のサブシミュレータ、GIS、ビューア、市民エージェントがある。各コンポーネントはカーネルと TCP/IP で接続され、毎シミュレーションステップ、通信により情報を交換する [8]。

サブシミュレータ (sub-simulator) は地震災害や救助活動が含む要素を個別に再現するシミュレータである。ロボカップレスキューシミュレーションが扱う災害状況は複雑であり、それらを一つのシミュレータで再現するのは難しい。そのため、個別の要素に対応したサブシミュレータを組み合わせることで、複雑な災害状況を再現している。また、各サブシミュレータが独立しているため、新たな要素を追加したり、既存の要素を改良したりすることが容易な仕組みとなっている。

現在のロボカップレスキューシミュレーションでは、次のサブシミュレータが存在している。

- CollapseSimulator : 建物の倒壊を再現するシミュレータ
- ClearSimulator : 道路の啓開を再現するシミュレータ
- TrafficSimulator : エージェントの移動や衝突を再現するシミュレータ
- MiscSimulator : エージェントの生命力の減少など、その他の要素を再現するシミュレータ

エージェントの動作や環境の変化は、これらのサブシミュレータで個別に計算される。そして、それぞれの計算結果がカーネルに集約され、シミュレーション全体の状態が更新されるようになっている。

カーネルに接続されている GIS は災害シナリオから、エンティティがどのような形状でどの位置に存在しているかを定義した、ワールドモデルを構築するコンポーネントである。構築されたワールドモデルはカーネルに提供される。災害シナリオ (scenario) とは、シミュレーション対象の災害、地域、救助部隊がどのようなものであるかを定義したデータである。このデータには、次の3種類のデータが含まれている。

- 地図データ: 対象地域の建物や道路の形状や位置を定義したデータ
- 配置データ: エージェントや特殊な建物の初期配置、避難所の病床数を定義したデータ
- 設定データ: 救助部隊の能力や被害の度合いなど、シミュレーションの設定を定義したデータ

Viewer (読み: ビューア) はロボカップレスキューシミュレーションの可視化システムの一つである。この可視化システムはエージェントの動作や活動環境をリアルタイムに表示するものである。この Viewer を用いたエージェントの動作の確認は、救助戦略の問題点や改善箇所の発見に利用されている。

なお、可視化システムは他にもいくつかのものが存在する。例えば、LogViewer はロボカップレスキューシミュレーションのサーバに付属するもう一つの可視化システムである。この可視化システムはシミュレーション終了後に、出力されたログファイルを読み込み、シミュレーションの様子を再生できるものである。また、サードパーティ製の可視化システムとしては、この LogViewer と同様にログファイルを読み込んで再生する ringo-viewer がある [9]。ringo-viewer は LogViewer がサポートしていない、通信の詳細情報やエージェントの知覚情報などを表示する機能を持つ。これらのログを再生する種類の可視化システムは、シミュレーションの複数同時実行など、リアルタイムにログを確認することが難しい場合や、Viewer で確認できない詳細な情報を確認する場合に用いられている。

救助部隊エージェントおよび指令所エージェントはクライアントとして動作する。シミュレーションサーバのカーネルと通信することで、知覚と行動の決定を繰り返す。クライアント内のエージェントプログラムは図 3.12 に示すように動作する。

エージェントは毎シミュレーションステップ、災害環境の知覚として、カーネルから自身や環境について更新された差分の情報を受信する。そして、この情報に基づいて、自身の知識を最新の状態に更新する。具体的に更新される内容には、視界に含まれる周囲の環境、位置や体力などの自身の最新の状態、他のエージェントからの通信内容といった情報が含まれる。

次に、エージェントは自身の知識に基づいて行動を決定する。この行動は救助戦略を定めた戦略プログラム (Tactics) で決定される。ただし、更新された知識が直接この戦略プログラムでは利用されるわけではない。この知識は戦略モジュールという種類のプログラムで参照される。戦略モジュールは救助戦略を部品化したプログラム群であり、それぞれの役割に応じた処理をおこなう。これには、例えば、目的地までの経路探索をおこなうモジュールや、救助対象を決定するモジュールなどがある。戦略プログラムでは、これらのモジュールをモジュールマネージャという管理プログラムを介して利用し、行動の決定をおこなう。そして、最終的に決定した行動をカーネルへ送信する。

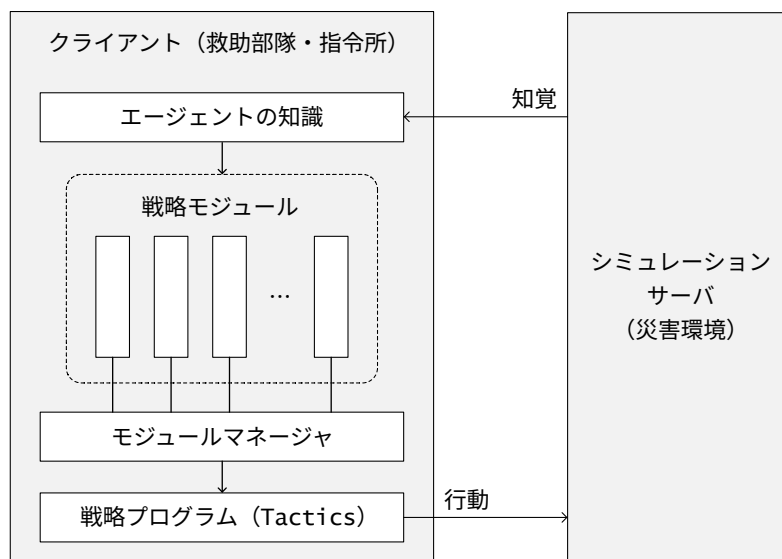


図 3.12 エージェントプログラムの動作の流れ

各戦略モジュールは毎シミュレーションステップ、最新の情報から内部状態を更新し、その結果を必要なタイミングで戦略プログラムに提供する。これにより、即座の判断を必要とする反射的な行動と、熟考を必要とする計画的な行動の両方とを、同一の枠組みで扱えるようになっている。この戦略モジュールを用いた設計は、サブサンクションアーキテクチャという技術に基づくものである。サブサンクションアーキテクチャ (subsumption architecture, 包摂アーキテクチャ) とは、複雑な振る舞いを複数の単純なモジュールへ分割し、それらを階層的に組み合わせることで、目的とする振る舞いを実現する設計手法である。Rodney Brooks が提唱した手法であり、掃除ロボットの「ルンバ」にも採用されるように、頑健な意思決定を実現する技術として広く知られている [10]。

救助戦略の設計には、これらの戦略モジュールのそれぞれの目的を満たすアルゴリズムと、戦略モジュール間の関係を設計する必要がある。本研究では、それぞれのエージェントが自身の置かれた状況から、取るべき行動を判断しつつ、全体と協調するための救助戦略を設計する。そのために、個々のモジュールをどのようなものとするかについては、第 3.3.1 項で述べる。

3.3 救助戦略の開発

3.3.1 救助戦略の構成と設計

ロボカップレスキューシミュレーションが対象とする災害救助問題はさまざまな問題を包含する複合的な問題である。そのため、この問題を解決する救助戦略を単純な方法で構築することは難しい。そこでロボカップレスキューシミュレーションでは、この複合的な問題を解決するために、救助戦略を複数の戦略モジュールという部品に分け、それぞれを開発し、その成果を組み合わせることで、全体の救助戦略を構成する方法を採用している。

この仕組みは RRS-ADF というフレームワークにより実現されている。**RRS-ADF** (RoboCupRescue Simulation Agent Development Framework) とは、ロボカップレスキューシミュレーションにおける救助部隊および指令所エージェントの開発を支援するためのフレームワークである (以降では単に「ADF」と

記す) [11]. ロボカップレスキューシミュレーションのプロジェクトでは, このフレームワークが標準開発ツールとして採用されており, 優れた救助戦略の開発を競うコンペティションでは, この ADF を用いて開発することがレギュレーションとして定められている [12].

ADF が導入される前のエージェントプログラムの開発では, 研究者は自身に関心を持つ課題に関する部分の開発に, その前提となる部分の開発が必要であった. これに対し ADF では, 救助戦略が戦略モジュールに分けられている. これにより, 研究者は対象としたい部分の開発に注力できる. また, 他の部分については, 既存のプログラムを利用できるようになっている.

ロボカップレスキューシミュレーションには, 優れた救助戦略の開発を競うコンペティションがある. その技術委員会では, 災害救助問題が含む問題を次の5つを掲げている.

- タスク割り当て (task allocation) : 全体の目的を達成するために, エージェントが担当するタスクや資源をどのように決定すべきか? を扱う問題
- 経路探索 (path finding) : 目的地に到達するため, 移動経路をどのように決定すべきか? を扱う問題
- 情報共有 (information sharing) : 効率的な協調を実現するために, それぞれのエージェントが持つ知識をどのように共有すべきか? を扱う問題
- 情報収集 (information collection) : 必要な情報を獲得するために, エージェントがどのように環境から情報を収集すべきか? を扱う問題
- グループ形成 (group formation) : タスクを協力して遂行するために, 複数のエージェントがどのようにグループを形成すべきか? を扱う問題

これらはロボカップレスキューシミュレーションにおいて, 標準問題と呼ばれる. この標準問題は災害救助問題だけでなく, マルチエージェントシステムに関する主要な問題でもある.

救助戦略の設計では, この標準問題のすべてを解決するアルゴリズムが必要となる. これに対し ADF では, 各問題を解決するエージェントアルゴリズムの部分を戦略モジュールと定義し, それらを開発するためのひな形を用意している. 5つの標準問題のそれぞれに対応する ADF の戦略モジュールを図 3.13 に示す.

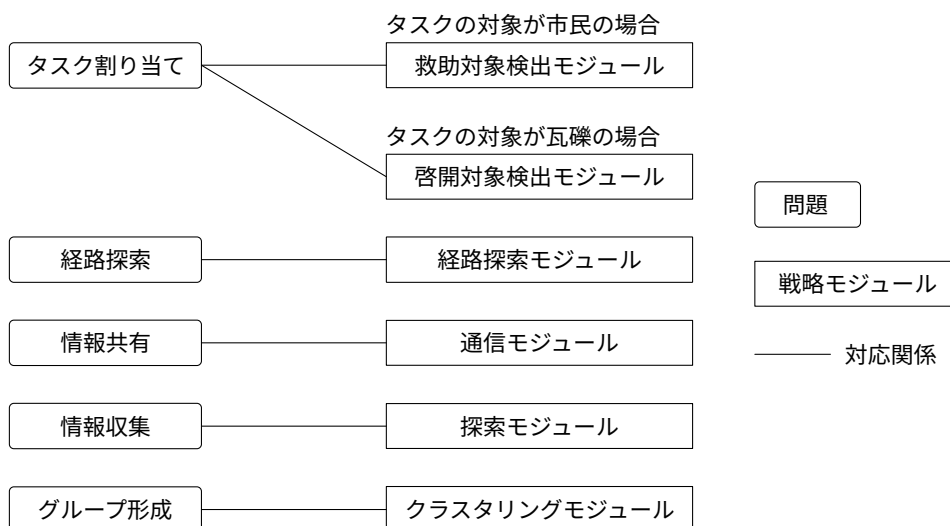


図 3.13 5つの標準問題のそれぞれに対応する ADF の戦略モジュール

タスク割り当て問題は対象とするタスクにより異なる解決方法が必要である. そのため, 複数種類の戦略

モジュールが対応している。その他の標準問題はそれぞれに対応する戦略モジュールが1種類ずつ用意されている。各モジュールには、サンプルプログラムもある。研究者はこれらを利用し、自身の関心のある問題に、対応したひな形を拡張して、アルゴリズムの改良や実験をおこなえるようになっている。

救助戦略の実現には、これらの標準問題を解決するアルゴリズム以外にも、あらかじめ設計しておくべき要素がある。具体的には、エージェント間で共有される情報の形式、タスクに対するエージェントの行動決定アルゴリズムなどが挙げられる。ADF では、これらもそれぞれ戦略モジュールとして扱う。

ADF でひな形が提供されている戦略モジュールは、次の4種類に分けられる。

- アルゴリズムモジュール
- 複合モジュール
- 行動制御プログラム
- 通信プログラム

以降、この戦略モジュールの種類ごとに、各モジュールについて概説する。

アルゴリズムモジュール (algorithm module) は単一的な問題を解決するためのアルゴリズムを持つモジュールである。このモジュールは図 3.14 に示すように、エージェントの知識から目的の計算をおこなう。そして、その結果は他のモジュールの計算に利用される。

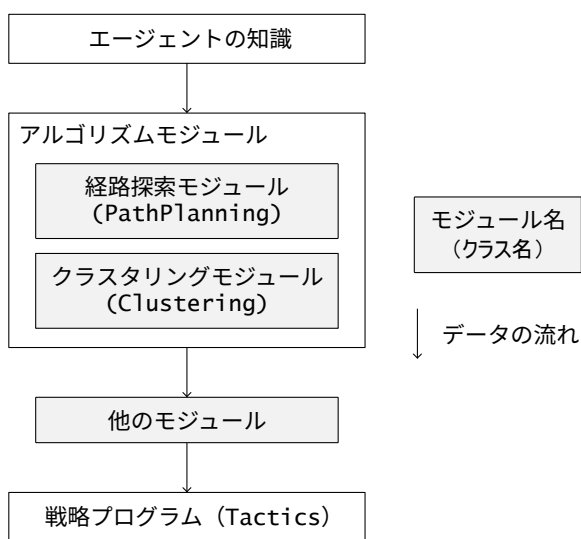


図 3.14 アルゴリズムモジュール

このアルゴリズムモジュールには、経路探索問題やグループ形成問題を対象とする次のモジュールが含まれる。

- 経路探索モジュール (PathPlanning)：経路探索アルゴリズムを用いて、自身から対象までの経路や、その長さなどを計算するためのモジュールである。移動経路の算出や、2つのエンティティ間の経路距離の算出などに利用される。
- クラスタリングモジュール (Clustering)：クラスタリングアルゴリズムを用いて、エンティティをグループ化するためのモジュールである。建物、道路をクラスタリング対象にした担当地域の計算や、市民をクラスタリング対象とした要救助者の集中箇所検出などに利用される。

複合モジュール (complex module) はアルゴリズムモジュールが単一的な問題を解決するのに対し、複合的な問題を解決するためのモジュールである。標準問題ではタスク割り当て問題、情報収集問題がこの複合的な問題に該当する。これらのモジュールは図 3.15 に示すように、エージェントの知識をもとに、その時点で取り組むべきタスクの検出をおこなう。また、必要に応じてサブモジュールとしてアタッチされたアルゴリズムモジュールを呼び出し、その計算結果を利用する。

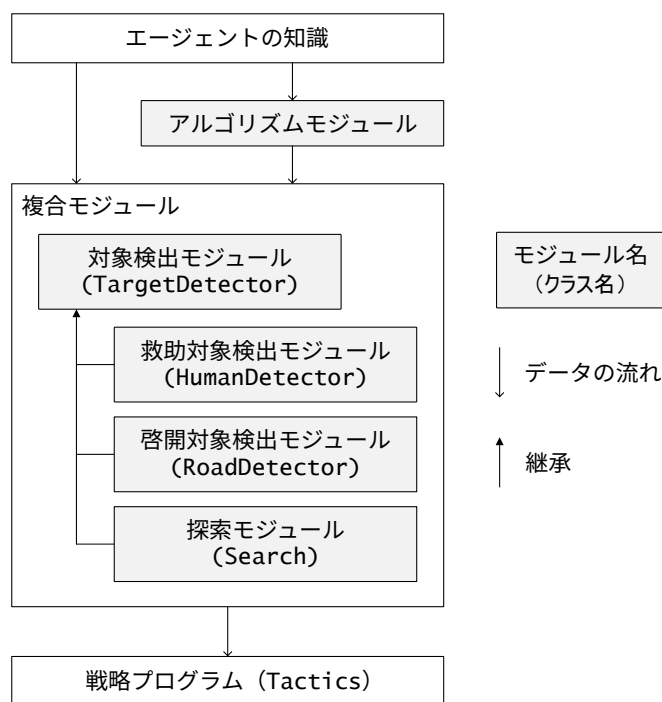


図 3.15 複合モジュール

複合モジュールでは、共通してエージェントの知識から、取り組むタスクを検出する。これを抽象的に定義したモジュールが対象検出モジュール (TargetDetector) である。このアルゴリズムはタスクの種類に応じて異なる。ADF では、タスクの種類ごとにこれを継承した対象検出モジュールの次のひな形が用意されている。

- 救助対象検出モジュール (HumanDetector)：市民の救助を対象とするものである。具体的には、消防隊の救助すべき対象、あるいは救急隊の搬送すべき対象を検出する。また消防隊の場合、建物の瓦礫に埋没している市民あるいは救助部隊を検出する。救急隊の場合には、負傷している市民を検出する。
- 啓開対象検出モジュール (RoadDetector)：道路の啓開を対象とするものである。土木隊が啓開すべき道路を検出する。把握している道路の状態から、瓦礫により通行できない道路の中で、優先的に啓開すべき道路を検出する。
- 探索モジュール (Search)：情報探索を対象とするものである。認識している情報から、自身の担当する種類のタスクを検出できない場合に、効果的な探索先として、道路や建物を検出する。

行動制御プログラム (control program) は対象検出モジュールにより、検出された対象に対して、おこな

う行動を決定するモジュールである。図 3.16 に示すように、エージェントの知識と、救助戦略プログラムを介して受け取った行動対象に対する計算をおこなう。また、複合モジュールと同様に、必要に応じてサブモジュールとしてアタッチされたアルゴリズムモジュールを呼び出し、その計算結果を利用する。

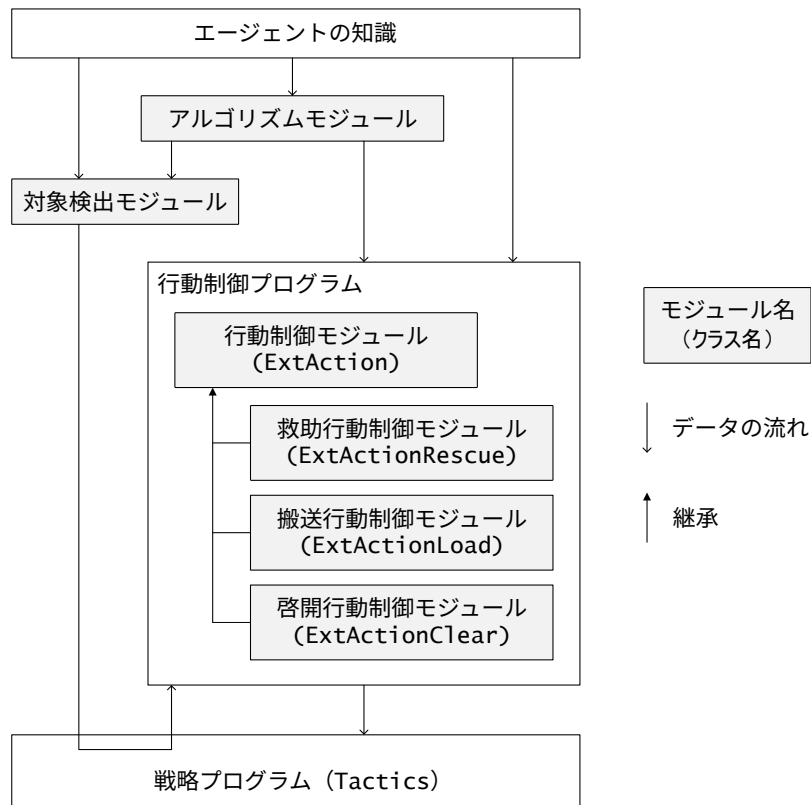


図 3.16 行動制御プログラム

ADF では、状況に応じた行動の生成をおこなうモジュールを抽象的に定義した行動制御モジュール (ExtAction) というモジュールがある。これを継承し、各タスクを生成するモジュールとして、次のモジュールのひな形が用意されている。

- 救助行動制御モジュール (ExtActionRescue)：消防隊が救助対象に対して、どのような行動を取るかを決定するモジュールである。救助対象検出モジュールで検出された対象に対して、その位置への移動、瓦礫からの救助といった行動を生成する。
- 搬送行動制御モジュール (ExtActionTransport)：救急隊が搬送対象に対して、どのような行動を取るかを決定するモジュールである。救助対象検出モジュールで検出された対象に対して、その位置への移動、対象の搬入、避難所への移動、対象の搬出といった行動を生成する。避難所への移動を生成する際には、搬送先とする避難所の決定もおこなう。
- 啓開行動制御モジュール (ExtActionClear)：土木隊が啓開対象に対して、どのような行動を取るかを決定するモジュールである。啓開対象検出モジュールで検出された対象に対して、その位置への移動や啓開といった行動を生成する。啓開行動の生成では、瓦礫を効率的に啓開するために、瓦礫や道路の領域に対する幾何計算を要する。

通信プログラム (communication program) はエージェント間で情報を共有するためのモジュールであ

る。図 3.17 に示すように、エージェントの知識に含まれるメッセージマネージャ (MessageManager) を介して、メッセージの送受信をおこなうプログラム群である。

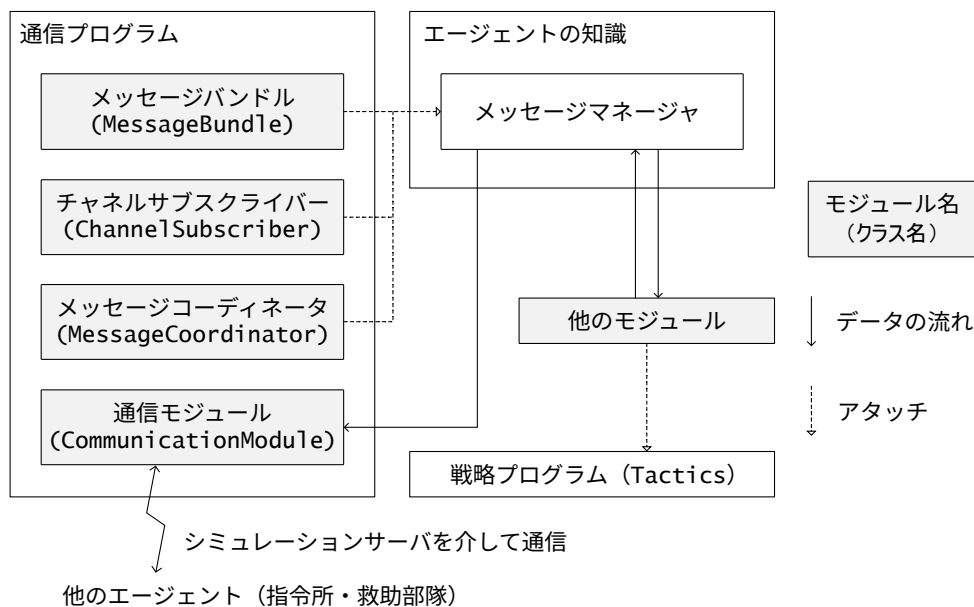


図 3.17 通信プログラム

メッセージマネージャは通信メッセージの保持および管理をおこなうコンポーネントである。このメッセージマネージャには、次の3種類の通信プログラムがアタッチされている。これらのモジュールは各シミュレーションステップの通信に伴い利用される。

- メッセージバンドル (MessageBundle)：通信の種類やフォーマットを定義するものである。
- チャンネルサブスクライバー (ChannelSubscriber)：各チャンネルをどのように利用するかを定義するものである。チャンネルはそれぞれ帯域幅が異なる。そのため、多くのメッセージを通信できるチャンネルもあれば、少ないチャンネルもある。ここでは、戦略上共有することが必要な情報の量に応じて、適切なチャンネルを適切な救助部隊の通信に割り当てる必要がある。
- メッセージコーディネータ：送信メッセージを優先度に基づき調整するためのものである。この優先度はメッセージに設定できるもので、その情報をどの程度優先して共有すべきであるかを示す。

また、通信そのものは通信モジュール (CommunicationModule) というモジュールがおこなう。このモジュールがメッセージマネージャを介して、情報の送受信をおこなう。これにより、異なるエージェント間で情報が共有できるようになっている。

ここで説明した、ADFにおける「モジュール」は単に部品化されているという意味だけではなく、同じ役割を持つ機能同士を交換できるという意味が込められている。したがって、同じひな形から拡張された同種のモジュールは、共通するインターフェースを持ち、交換できるようになっている。これにより、他の研究者が開発したモジュールと、自身が開発したモジュールを交換し、それらの機能を比較したり、さまざまな組み合わせから優れた救助戦略を探索したりできるものとなっている。

これらの戦略モジュールを呼び出し、各シミュレーションステップにおけるエージェントの意思決定をおこなう戦略プログラムは、その内容を変更することで、より高度な救助戦略を実現できるようになっている。

一方、このプログラムには、デフォルトの戦略も用意されている。これを利用することで、そこから呼び出されるモジュールのみを実装することで救助戦略を構築できるようになっている。

現在のロボカップレスキューシミュレーションでは、このデフォルトの戦略プログラムが広く採用されている。この理由には、戦略プログラムごと変更すると、呼び出されるモジュールの種類が変わってしまうため、救助戦略間の比較が困難となり、評価実験が難しくなることが挙げられる。したがって、各研究者やコンペティションの参加者は、それぞれの目的のためにこのデフォルトの戦略プログラムの下で、各モジュールの開発に取り組んでいる。本研究の救助戦略の設計においても、これまでに開発されたものを参考にすることができることから、このデフォルトの戦略を利用する。

救助部隊エージェントはこれらのモジュールを組み合わせて行動を決定する。基本的には、次の図 3.18 に示す流れで行動を決定する。この流れは ADF において、各救助部隊のデフォルトの Tactics として実装されているものである。

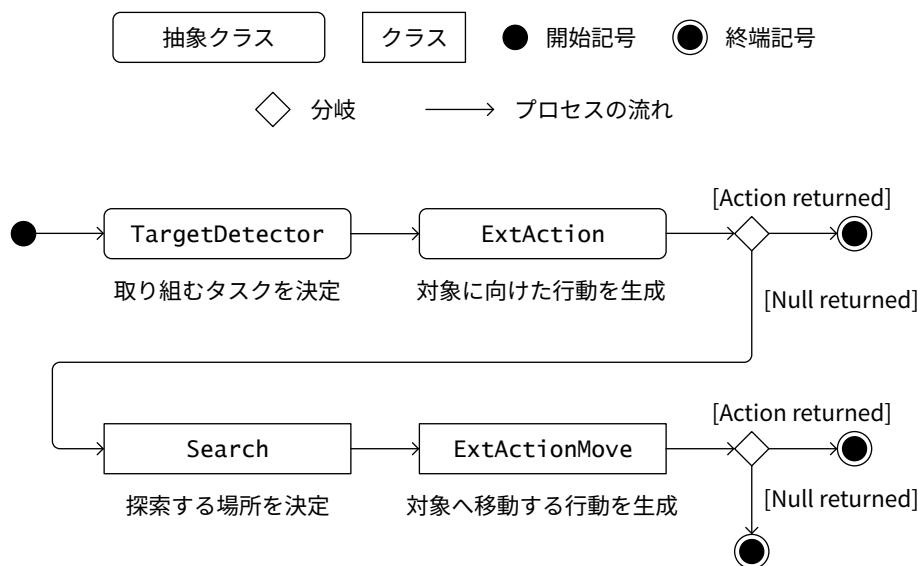


図 3.18 デフォルトの Tactics の流れ

まず、救助部隊は自身の対象とするタスクを TargetDetector により決定する。その後、ExtAction により、そのタスクへ向けた行動を生成する。例えば、消防隊の場合には、まず HumanDetector を用いて、自身の知識から、タスクとして救出する対象を決定する。その後、ExtActionRescue により、対象を救出する具体的な行動を生成する。ExtActionRescue では、自身が対象の位置にいない場合にはその位置へ向かう移動行動を生成し、対象の位置に到達した場合には救出行動を生成する。

また、タスクが見つからなかった場合には、Search により探索先を決定する。その後、ExtActionMove によりその位置へ向かう移動行動を生成する。タスクの決定では、自身の知識から対象を決定するが、救助部隊の知識には限りがあるため、タスクが見つからない場合がある。その場合、救助部隊は新たな情報を収集するために探索行動をおこなう。図 3.18 に示すとおり、デフォルトの Tactics では、ExtAction の戻り値が Null である場合に Search が呼び出され、探索先が決定されるようになっている。

3.3.2 救助戦略の評価とコンペティション

エージェントシミュレーションコンペティション (Agent Simulation competition, 以降では「コンペティション」と記す) はロボカップの競技会の一つである [6]。この競技会はレスキューシミュレーションリーグ (RSL: RoboCupRescue Simulation League) により開催される。競技参加者はロボカップレスキューシミュレーションの救助戦略を開発し、さまざまなシナリオのもとでその優劣を競う。

本研究では、2024年のコンペティションにおいて優勝を果たしたチームである **AIT-Rescue** の戦略を扱う。このチームはこのコンペティションの第1回から、継続的に参加している。また、チームのメンバーは入れ替わっているが、2024年のコンペティションを含め、筆者もこのチームに所属している*5。

コンペティションでは、救助戦略の良し悪しが評価される。この評価には、これまでいくつかの方法が提案されている。現在のコンペティションでは、シミュレーションの終了時点で、生存している市民の数および体力が多いほど、良い救助戦略として評価される。具体的には、次の式 (3.1) に示す **RSL21** スコア関数により、評価されている [13]。

$$S(t) = N_{\text{civ}}(t) \cdot \exp\left(-5 \left(1 - \frac{H_{\text{civ}}(t)}{H_{\text{civ}}(0)}\right)\right) \quad (3.1)$$

ここで、 $S(t)$ はシミュレーションステップ $t \in [0, T]$ における救助スコア、 $N_{\text{civ}}(t)$ は同ステップで生存している市民の数、 $H_{\text{civ}}(t)$ は生存している市民の体力の総和を表す。

シミュレーションの進行に応じて、市民の数や体力は減少するため、 $S(t)$ は時間とともに単調減少する。したがって、コンペティションでは、この救助スコアをいかにして高い値に維持できるかを競う。スコアは市民の体力が低下している場面では、ゆるやかに減少し、市民が死亡すると急激に減少する。スコアの変化の例を図 3.19 に示す。スコアはシミュレーション開始時点のスコア $S(0)$ は市民の数に等しく、 $S(0) = N_{\text{civ}}$ である。この災害シナリオでは、最初に 300 人の市民がいたことがわかる。シミュレーションは開始すると、建物内にいた市民が倒壊した建物の下敷きとなる。このとき、運悪く死亡してしまう市民がいくらかいるため、その数だけスコアは急激に減少する。その後、負傷した市民の体力低下とともにスコアはゆるやかに減少する。また、ある程度シミュレーションが進行すると、死亡する市民がいくらか出てくるため、スコアが階段状に減少する。市民の初期体力は等しく 10,000 に設定されているが、体力低下にはばらつきがあり、また救助の状況により死亡するタイミングが異なるため、スコアの減少のタイミングが異なっている。

なお、このスコアは市民の数や建物の配置など、災害シナリオに依存する。そのため、スコアを用いて、異なる救助戦略を同じ災害シナリオの下で比較するには利用できるが、異なる災害シナリオの間で比較することはできない。また、すべての市民が死亡してしまった場合、スコアは $S(t) = 0$ となるが、通常の災害シナリオでは、建物の外で避難行動をおこなう市民が配置され、これらの市民の体力は低下することがないため、このようなことになることはない。

3.3.3 救助戦略の開発における課題

開発する救助戦略は、どのような被災状況であっても、柔軟に適應できるものであることが望ましい。地震の発生場所には、都市部から地方部まで、さまざまな場所が含まれる。また、そのときの被害の深刻さや現場で対応できる要員の状況などは異なる。ロボカップレスキューシミュレーションにおいては、これらの要素は災害シナリオとして表現される。したがって、さまざまな災害シナリオを考慮し、それらに柔軟に対応できる救助戦略の開発が求められる。

*5 筆者は 2023 年まで競技会の運営スタッフとして活動し、2024 年から競技者として参加している。




図 3.19 シミュレーションステップの進行に伴う救助スコアの変化 (サンプルエージェント, sakae シナリオにおける実行結果)

しかし、考えられるすべての状況に対して、最適な判断を可能とする優れた救助戦略の開発は容易ではない。例えば、地震発生時に市民が広範囲に分散していた場合には、多くの市民を救出するために、救助部隊は要救助者の位置を特定し、それぞれ分散して、救助活動をおこなう必要がある。一方で、市民が一か所に集中している場合には、救助部隊はその場所を検出し、人員不足を補うために、そこへ集結して救助活動をおこなう必要がある。これらの例においては、それぞれ状況を判断するために、救助部隊は市民の分布状況を把握する必要がある。しかし、個々の救助部隊の視点においては、災害全体の状況は限られた知覚および通信情報から段階的に明らかになるものであり、事前にすべてを把握することはできない。また、この把握のための情報はノイズを含んでいるため、必ずしも正しいとはいえない。そのため、救助部隊が得られる情報は常に不完全かつ不確実性を伴うものとなる。加えて、この例では市民の分布状況のみを取り上げたが、実際には救助の進行度、道路の通行状況、避難所の収容状況など、さまざまな要素を考慮する必要がある。したがって、これらすべてを考慮した戦略の開発は非常に難しい課題であるといえる。

3.4 分散型協調戦略の開発

3.4.1 分散型協調戦略の概要

本研究では、さまざまな被災状況を考慮した救助戦略の実現に向けて、分散制御を重視した戦略を提案する [14]。この戦略は AIT-Rescue が 2024 年の競技会で採用したものである。以降、本論文ではこの戦略を分散型協調戦略と呼ぶ。

救助戦略は大きく分けて、指令所からの指令に基づく集中制御と、救助部隊が自律的に行動する分散制御の 2 つの考え方が存在する。本戦略はこれらのうち、分散制御を重視している。したがって、救助部隊は各々収集した情報を互いに共有しながら、状況を判断し、行動をおこなう。

本研究で設計する分散協調戦略は次の特徴を持つ。括弧内の項はそれぞれの特徴について説明する項を示している。

- 知識から適切な行動の対象を候補として検出し、最も優先すべき対象を選択する（第 3.4.3 項）
- 瓦礫による通行不能道路を考慮し、それらを迂回して移動する（第 3.4.4 項）
- 地域全体に対する情報収集と救助活動を実現するために、各救助部隊で地域全体を分担する（第 3.4.5 項）
- 積極的に利用する重要道路を定義し、それらの道路の通行の確保する（第 3.4.6 項）
- 限られた通信量で、救助部隊間で有用な情報を効率的に交換する（第 3.4.7 項）
- 避難所の状況を考慮して、適切な搬送先へ負傷者を搬送する（第 3.4.8 項）

本研究では、このようにさまざまな状況を考慮した戦略を実現するために、さまざまなモジュールを開発し、それらを組み合わせる。以降では、これらの特徴を実現する方法、それぞれに対応するモジュール、またその機能について説明する。

3.4.2 救助部隊のモジュールの構成

本戦略は TargetDetector や ExtAction において、高度な戦略を実現するため、新たなサブモジュールを設計した。本戦略のモジュール構成を図 3.20 に示す。また、各サブモジュールの概要を表 3.1 に示す。

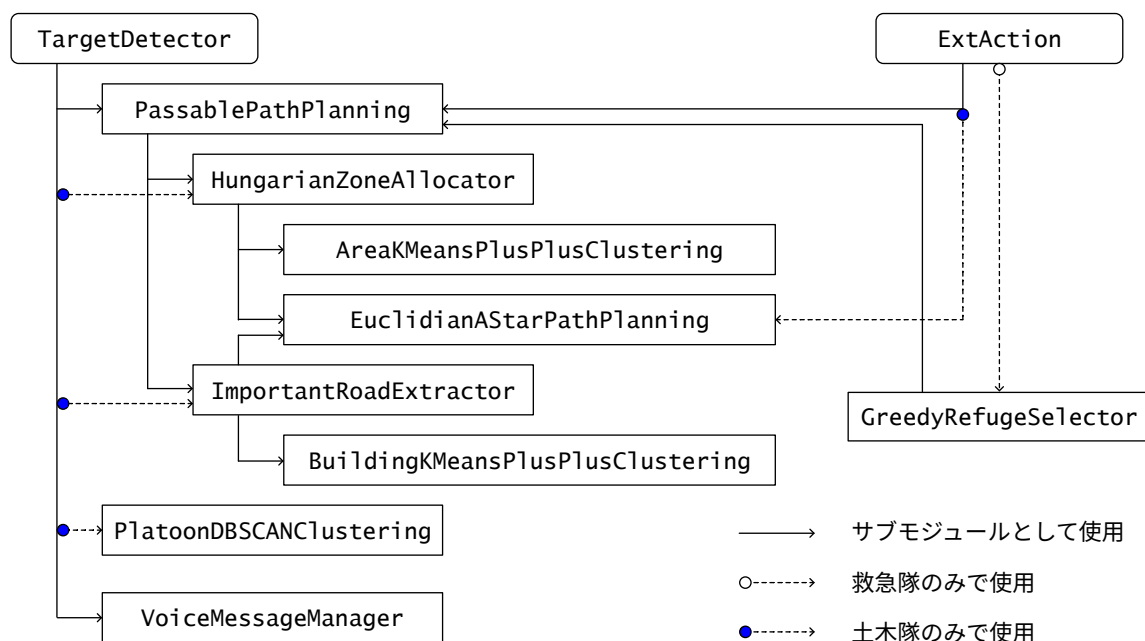


図 3.20 本研究の救助部隊エージェントのモジュール構成

本戦略における TargetDetector では、各救助部隊のタスクを適切に決定するために、さまざまなサブモジュールを用いて、タスクの優先度を評価する。PassablePathPlanning は道路と瓦礫の情報から、通行可能な経路を計算するモジュールである。救助部隊はこのモジュールを用いて、到達可能性の高い対象を自身のタスクに選択するようになっている。また、土木隊の啓開活動はエージェントの活動全体に影響を与えるため、より細かな評価をおこなうために、加えていくつかのサブモジュールを利用する。これらの TargetDetector における評価の詳細は第 3.4.3 項で説明する。また、PassablePathPlanning における通行可否の判定などの詳細は第 3.4.4 項で説明する。

HungarianZoneAllocator は地域を各救助部隊に割り当てるためのモジュールである。このモジュール

表 3.1 本研究で使用するサブモジュール

モジュール名	説明
PathPlanning (経路計画モジュール) :	
PassablePathPlanning	道路と瓦礫の情報から、通行可能な経路を計算するモジュール
EucidianPathPlanning	ユークリッド距離に基づく A* アルゴリズムにより経路を計算するモジュール
Clustering (クラスタリングモジュール) :	
AreaKMeansPlusPlusClustering	k-means++ 法に基づき、地域を複数のクラスタに分けるモジュール
BuildingKMeansPlusPlusClustering	k-means++ 法に基づき、建物を複数のクラスタに分けるモジュール
PlatoonDBSCANClustering	DBSCAN アルゴリズムに基づき、救助部隊が集中するクラスタを検出するモジュール
その他の新規のモジュール :	
HungarianZoneAllocator	ハンガリアンアルゴリズムに基づき、地域を各救助部隊に割り当てるモジュール
ImportantRoadExtractor	道路群から重要道路を抽出するモジュール
VoiceMessageManager	音声通信に関する共通戦略を実行するモジュール
GreedyRefugeSelector	待ち行列理論に基づき、最も早く病床が利用可能な避難所を搬送先として選択するモジュール

は PassablePathPlanning や RoadDetector で利用される。本戦略では、地域全体の情報収集と救助活動を漏れなく、効率的におこなうために、それぞれの救助部隊に担当地域を設けている。これは ADF のサブエージェントの戦略にも含まれるものであるが、従来のプログラムでは、地域の分割と救助部隊への割り当てが両方ともに Clustering で実施されていた。しかし、これらはそれぞれ「どのように分割すべきか?」「どのように割り当てるべきか?」という異なる問題を対象とした計算である。そこで、本戦略では地域を割り当てるモジュールとして、ZoneAllocator を新たに定義し、それぞれの計算を別々のモジュールで実行するように変更した。この担当地域の作成と割り当てについては第 3.4.5 項で説明する。

ImportantRoadExtractor (重要道路抽出モジュール) は道路群から重要道路を抽出するモジュールである。本戦略では、救助部隊が積極的に利用する道路を「重要道路」として定義し、それらの道路の通行の確保を優先的にこなう。この重要道路の抽出も既存のモジュールでは表現できないため、新たに定義した。重要道路の抽出方法については第 3.4.6 項で説明する。

VoiceMessageManager (音声通信管理モジュール) は音声通信に関する共通戦略を実行する新しいモジュールである。ロボカップレスキューシミュレーションでは、自身の救出や応援を要請する場面が、いずれの種類の救助部隊にも共通して、存在する。このモジュールはこれらの要請を表現するメッセージの作成や、優先順位の管理をおこなうためのモジュールである。なお、VoiceMessageManager が実行する処理は他のモジュールとの順序に依存しないものであるため、どこで実行されても問題はない。本戦略では、各救助部隊の Tactics で最初に実行される TargetDetector で呼び出されるようにしている。このモジュールの詳細は第 3.4.7 項で説明する。

行動制御プログラムでは、共通して、対象に向かう移動行動を生成するために、PathPlanning を用いる。本戦略では、消防隊、救急隊は瓦礫を迂回するために、PassablePathPlanning を用いている。一方で、土木隊は啓開活動により、瓦礫を除去できるため、瓦礫による閉塞を考慮せず、より短い経路を求められる EucidianPathPlanning を用いている。

ExtAction のうち、救急隊の搬送行動を制御する ExtActionTransport では、搬送先の避難所を選択するために、GreedyRefugeSelector を用いる。ExtActionTransport が対象とするタスクは対象の負傷者を搬入し、避難所へ搬送することである。そのため、このモジュールでは移動、搬入、搬出の3つの行動を生成する必要がある。また、救急隊は負傷者を搬入するまでは認識している市民の状態について考える必要があるが、その後の避難所まで搬送する間は、搬送先の避難所の状況を考慮する必要がある。このように ExtActionTransport は状況により、役割が大きく異なるため、本戦略では、後半の避難所の選択を別のモジュールとして、分離した。この避難所の選択は RefugeSelector という新たなモジュールとして定義している。具体的な選択方法については第 3.4.8 項で説明する。

なお、この救急隊の変更について、タスク自体を市民の搬入前後で分割する方法も考えられる。この場合、避難所への搬送は搬送先に適した避難所を指定する RefugeDetector と、指定された避難所へ搬送するための行動を生成する ExtActionTransport から実現できる。しかし、この方法では救急隊の Tactics を変更する必要がある。コンペティションでは、デフォルトの Tactics を維持することで、そこから呼び出されるモジュールについて、以降の参加者が利用したり、交換したりできるようにしている。この理由から、本戦略では搬送先の選択を ExtActionTransport に組み込む方法を採用している。

また、ここで説明したコンペティションの方針を満たす設計原則として、各モジュールは他の特定のモジュールに依存しないように設計する必要がある。本研究で提案するモジュールはすべてこの原則に従って設計されており、モジュールを他の同種のモジュールと入れ替えても動作するものとなっている。

3.4.3 タスクの検出と選択

救助部隊エージェントのタスクは、消防隊の救出、救急隊の搬送、土木隊の啓開、情報探索の4つである。それぞれの対象はタスクに応じた TargetDetector により検出される。TargetDetector は救助部隊エージェントが獲得した情報に基づいて、自身の内部知識から、対応するタスクを検出するモジュールである。そして、検出された対象は ExtAction に渡され、行動の生成に用いられる。

タスクとなり得るものは時間の進行や、自身を含むエージェントの行動により、動的に変化する。そのため、対象は常に最新の情報に基づいて、選択する必要がある。例えば、救急隊は埋没した市民を救出することはできない。そのため、目前に要救助者がいたとしても、埋没している場合には対象とすることができない。しかし、もしそこで消防隊が救出している場合には、その救出が完了したタイミングから、救急隊はその要救助者を搬送の対象とできる。

本戦略では、それぞれの TargetDetector で対象の動的な変化を考慮した選択手法を採用している。この流れを図 3.21 に示す。

1. 候補集合の更新 — 救助部隊エージェントが知覚した、あるいは通信で共有された情報から、候補集合を更新する。候補集合は救助部隊エージェントが認識している対象の中から、行動の対象となり得るものの集合である。救助部隊エージェントはこの候補集合を毎シミュレーションステップ、更新する。
2. タスクの継続判断 — 現在取り組んでいるタスクを継続するかどうかを判断する。救助部隊エージェントは毎シミュレーションステップ、何らかの行動を実行する。ここでは、前のシミュレーションステップにおける行動の対象が、このシミュレーションステップにおいても候補集合に含まれているか

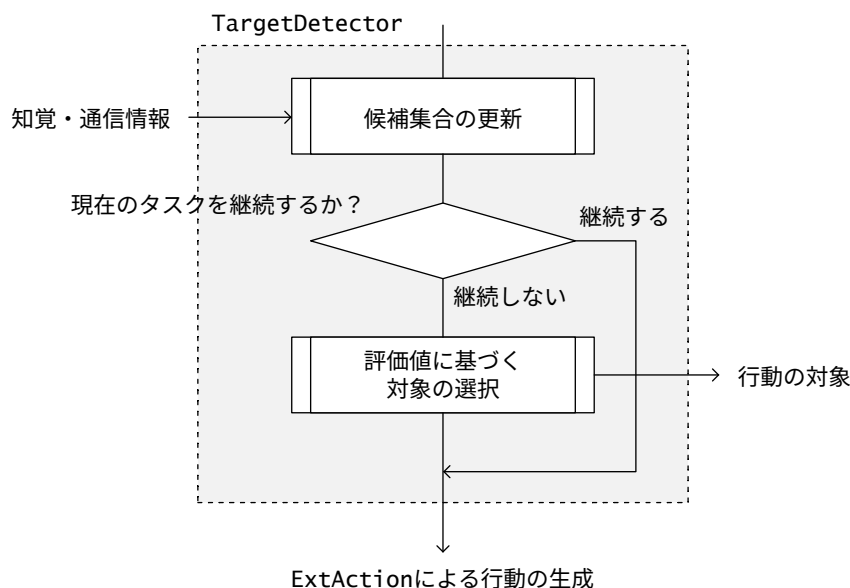


図 3.21 TargetDetector による行動の対象を選択する流れ

どうかを判断する。候補集合に含まれる場合、タスクが完了していないものと判断し、そのタスクを継続する。そうでない場合には、対象の問題が解決したものと判断し、新たな対象を候補集合から選択する。例えば、埋没状態の市民の救出をおこなっているが、まだ市民が埋没している場合には、その救出を継続するといった処理がこの段階でおこなわれる。

3. 評価値に基づく対象の選択 — 各候補を評価し、その中から最も評価の高いものを対象に選択する。この評価は事前に定められた複数の評価基準に基づいておこなわれる。例外として、候補が存在しない場合には、情報が不足しているものと判断し、情報探索をおこなう。

救助部隊エージェントが認識している対象のうち、それらが候補集合に含まれる条件は、そのタスクの種類により異なる。また、これらの条件は複数の条件の組み合わせから定義される。候補を各タスク τ ($\in \{Rescue, Transport, Clear, Search\}$) についての集合 C_τ として、式 (3.2) のように表現する。

$$C^{(\tau)} = \{t \mid \bigwedge_i Cond_i^{(\tau)}(t), t \in U_\tau\} \tag{3.2}$$

ここで、 U_τ はタスク τ におけるすべての対象の集合であり、 $Cond_i^{(\tau)}$ は対象 t がタスク τ の候補に含まれるために満たすべき条件である。

本研究では、各行動における候補に含まれる条件 $Cond_i^{(\tau)}$ を表 3.2 のように定めた。基本的には、タスクを実行可能な対象を候補に含めるようにしている。例えば、死亡した市民は救出することができない。そのため、消防隊の救出の候補には含めないものとなっている。

さらに、戦略上の理由から、候補に含める条件を追加している。まず、消防隊の救出、救急隊の搬送では、対象の生存可能性を考慮している。これは対象の体力、負傷度、および埋没度から、生存時間を推定し、その時間内に救助が完了するかどうかを判定し、救出が可能な対象を候補としている。また、救急隊は1体につき1人の市民しか搬送できない。そのため、最も近い救急隊が対象の搬送を担当する。さらに、情報探索では、倒壊した建物に限定して探索を実行する。倒壊していない建物は、探索が可能なものの、エージェントが埋没している可能性がないためである。

また、対象は評価関数に基づいて決定される。そこで、選択される対象 $Target$ を式 (3.3) のように表現す

表 3.2 行動ごとの候補に含まれる条件

条件	説明
消防隊の救出 (AITHumanDetectorFire) :	
$\text{Cond}_1^{(Rescue)}$: 救助要請条件	対象のエージェントが救助を必要としている (生存かつ埋没している) 状態である場合に成立
$\text{Cond}_2^{(Rescue)}$: 生存可能救助条件	対象のエージェントを生存した状態で時間内に救助可能である場合に成立
救急隊の搬送 (AITHumanDetectorAmbulance) :	
$\text{Cond}_1^{(Transport)}$: 搬送要請条件	対象のエージェントが搬送を必要としている (生存している, 埋没していない, 負傷している, 救急隊による搬送中でない, 避難所以外にいるをすべて満たす) 状態である場合に成立
$\text{Cond}_2^{(Transport)}$: 生存可能搬送条件	対象のエージェントを生存した状態で時間内に搬送可能である場合に成立
$\text{Cond}_3^{(Transport)}$: 近接割当条件	対象のエージェントから最も近い救急隊が自身である場合に成立
土木隊の啓開 (AITRoadDetector) :	
$\text{Cond}_1^{(Clear)}$: 啓開要請条件	対象の道路が瓦礫により通行不能である場合に成立
$\text{Cond}_2^{(Clear)}$: 部隊スタック条件	対象の道路で消防隊, 救急隊がスタックしている場合に成立
救助部隊の情報探索 (AITSearch) :	
$\text{Cond}_1^{(Clear)}$: 未探索条件	対象の建物が未探索である場合に成立
$\text{Cond}_2^{(Clear)}$: 倒壊条件	対象の建物が倒壊している場合に成立

る. $Target$ はあるタスク τ についての評価関数 $Score_\tau$ を最大化する候補 $c \in \mathcal{C}_\tau$ であり, この評価関数 $Score_\tau$ は複数の評価基準 $f_j^{(\tau)}$ の重み付き和として定義される.

$$Target = \underset{c \in \mathcal{C}_\tau}{\operatorname{argmax}} Score_\tau(c) \quad (3.3)$$

$$Score_\tau(c) = \sum_j w_j^{(\tau)} f_j^{(\tau)}(c)$$

ここで, $w_j^{(\tau)}$ は評価基準 $f_j^{(\tau)}$ に与える重みである. これらの重みはパラメータとして, あらかじめ設定する. また, 各評価基準 $f_j^{(\tau)}$ は対象の候補 c の特徴を評価するもので, その出力は $f_j^{(\tau)}(c) \in [0, 1]$ となるように正規化されている.

本研究では, 各行動における評価基準 $f_j^{(\tau)}$ を表 3.3 のように定めた. 特に, 道路上の瓦礫はすべてのエージェントの活動に影響を与えるため, 土木隊の啓開に関する評価基準を多く設定している.

これらの評価基準の計算には, サブモジュールを利用する. 距離基準では, PathPlanning を利用して経路を算出する. また, 地域割当基準では救助部隊に担当地域を割り当てる ZoneAllocator を, 部隊密集基準や道路重要度基準では, 救助部隊や道路の位置から, クラスタを検出する Clustering を利用する.

実装したエージェントでは, 基準を経験的に評価し, その順位から, 次の表 3.4 のとおり, 重みを設定した. これらの重みは基準をその重要度の高い順に並べるようにしたものである. 具体的には, k 番目に重要な基準の重みを $w_k = 2w_{k-1}$ とすることで, $w_k > \sum_{l=0}^k w_l$ を満たすようにしている.

このように本戦略では, 候補集合を動的に更新し, また複数の評価基準に基づき, 取り組むべきタスクを

表 3.3 行動ごとの評価基準

評価基準	説明
消防隊の救出 (AITHumanDetectorFire) :	
$f_1^{(Rescue)}$: 消防隊対象基準	消防隊であれば 1, そうでなければ 0
$f_2^{(Rescue)}$: 土木隊対象基準	土木隊であれば 1, そうでなければ 0
$f_3^{(Rescue)}$: 救急隊対象基準	救急隊であれば 1, そうでなければ 0
$f_4^{(Rescue)}$: 緊急度基準	救出後の残りの生存時間から評価
救急隊の搬送 (AITHumanDetectorAmbulance) :	
$f_1^{(Transport)}$: 距離基準	対象までの近さを経路の長さから評価
土木隊の啓開 (AITRoadDetector) :	
$f_1^{(Clear)}$: 部隊スタック基準	消防隊, 救急隊がスタックしていれば 1, そうでなければ 0
$f_2^{(Clear)}$: 避難所隣接性基準	避難所に隣接していれば 1, そうでなければ 0
$f_3^{(Clear)}$: 部隊密集基準	救助部隊が密集する地域に含まれていれば 1, そうでなければ 0
$f_4^{(Clear)}$: 道路重要度基準	重要道路が密集する地域に含まれていれば 1, そうでなければ 0
$f_5^{(Clear)}$: 地域割当基準	担当する地域に含まれていれば 1, そうでなければ 0
$f_6^{(Clear)}$: 距離基準	対象までの近さを経路の長さから評価
救助部隊の情報探索 (AITSearch) :	
$f_1^{(Search)}$: 地域割当基準	担当する地域に含まれていれば 1, そうでなければ 0
$f_2^{(Search)}$: 市民発見基準	市民の声のする位置から, 市民の発見の期待度を評価
$f_3^{(Search)}$: 距離基準	対象までの近さを経路の長さから評価

表 3.4 評価基準の重み

行動	基準 1	基準 2	基準 3	基準 4	基準 5	基準 6
消防隊の救出	8.0	4.0	2.0	1.0	-	-
救急隊の搬送	1.0	-	-	-	-	-
土木隊の啓開	32.0	16.0	8.0	4.0	2.0	1.0
救助部隊の情報探索	4.0	2.0	1.0	-	-	-

各基準の番号は重み $w_j^{(\tau)}$ の j に対応するものである.

選択する. 本研究では, この戦略に基づき, 変化する状況に応じた, 救助部隊エージェントの柔軟かつ合理的なタスク選択を実現する.

3.4.4 瓦礫を考慮した経路探索

瓦礫による道路の閉塞は救助活動への影響が非常に大きい. ロボカップレスキューシミュレーションにおける市民の救出は, 土木隊による道路啓開, 消防隊による救出, 救急隊による搬送の 3 段階でおこなわれる. したがって, 道路が瓦礫により通行不能である場合には, 消防隊や救急隊は現場へたどり着くことができず, 市民の救出が遅れることとなる.

瓦礫への対応には、二つの方法がある。一つは瓦礫を効率的に撤去することである。もう一つは、瓦礫により通行不能な道路を迂回して移動することである。瓦礫の撤去は土木隊にしか実行できないため、消防隊や救急隊は瓦礫により通行不能な道路を迂回して移動することが求められる。

そこで、本研究では、瓦礫を考慮した経路探索を実現する `PassablePathPlanning` というモジュールを提案する。救助部隊エージェントは `PathPlanning` により計算された経路に従い、目的地へ向けて移動する。`PassablePathPlanning` はこの `PathPlanning` の一つである。

本戦略の `PathPlanning` では、ベースアルゴリズムとして A* アルゴリズムを採用している。A* アルゴリズムは比較的シンプルでありながら、考慮すべき要素を追加しやすい特徴を持つ。加えて、一定の条件を満たすことで、最適解を保証することができる。そのため、競技会の参加チームなど、ロボカップレスキューシミュレーションの救助部隊エージェントでよく採用されるアルゴリズムである。`PassablePathPlanning` はこの A* アルゴリズムにおける経路コストを瓦礫に対応させる形で実現している。

A* アルゴリズム (A-star algorithm) は数理グラフにおいて経路を求めるための、代表的な探索アルゴリズムの一つであり、探索コストの小さいものからしらみつぶしに探索するダイクストラ法を拡張したものである [3]。アルゴリズムをアルゴリズム 1 に示す。このアルゴリズムでは、探索ノード n に対して、評価関数 $f(n) = g(n) + h(n)$ に基づく探索をおこなう。ここで、 $g(n)$ は開始ノード (開始地点) からノード n までの既知の最小コストであり、 $h(n)$ はノード n から目的ノード (目的地) までの推定コストである。 h はヒューリスティック関数 (heuristic function) と呼ばれ、経験則に基づく近似値を表現したものである。A* アルゴリズムでは、この $h(n)$ をコストに加えることで、目的ノードに近いノードから探索を優先的におこない、探索の効率化を図っている。

A* アルゴリズムは探索の開始ノード $start$ 、目的ノード $goal$ 、ヒューリスティック関数 h を引数として受け取り、 $start$ から $goal$ までの経路を求める。アルゴリズム 1 では、まず最初に親ノード $parent$ 、 g 値 (関数 g が返す値)、 f 値 (関数 f が返す値) を初期化し、オープンセット $open_set$ に $start$ を追加する。ここで、オープンセット (open set) は探索を予定しているノードの集合をいう。反対に、探索を完了したノードの集合はクローズドセット (closed set) と呼ばれる。初期化が完了したら、目的ノードに到達する、あるいはオープンセットが空になるまで、探索する。

探索では、まず $open_set$ から f 値が最小のノードを取り出す。これを現在の探索ノード $current$ と定義する。 $open_set$ は優先度付きキューであり、常に f 値が小さい順に要素が格納されている。POLL はその優先度付きキューから要素を取り出す関数である。反対に、OFFER は優先度付きキューに要素を追加する関数である。 $current$ が $goal$ である場合には、目的ノードに到達したものとして、探索を終了する。このとき、経路を $current$ から $start$ に向かって後ろ向きに辿り、この経路を結果として返す。BACKTRACK は $parent$ に基づいて、この操作をおこなう関数である。また、もしオープンセットが空になった場合には、目的ノードに到達できないものとして、解なしを意味する値 `NO_SOLUTION` を返す。

探索において、 $current$ が $goal$ でない場合には、そのノードの隣接ノードをすべて取得し、それらを順に評価する。`GET-NEIGHBORS(current)` は $current$ の隣接ノードの集合を表す。隣接ノード $neighbor$ は $g(current)$ と $COST(current, neighbor)$ の和で表される暫定的コスト c で評価される。 $g(current)$ は開始ノードから $current$ までの既知の最小コストであり、 $COST(current, neighbor)$ は $current$ から $neighbor$ までの、隣り合うノード間のコストを表す。なお、 g 値はこの c により更新されるため、ある地点 n_N までの既知の最短経路が $\langle n_0, n_1, \dots, n_N \rangle$ で表されるとき、 $g(n_N) = \sum_{i=0}^{N-1} COST(n_i, n_{i+1})$ となる。

もし c が $neighbor$ の既知のコスト $g(neighbor)$ より小さい場合には、 $neighbor$ の親ノードを $current$ に更新し、 $g(neighbor)$ と $f(neighbor)$ を更新する。このとき、 $f(neighbor)$ は $c + h(neighbor)$ で更新され、ヒューリスティック関数 h により、目的地に近いノードが優先されるようになっている。また、 $neighbor$ が

アルゴリズム 1 A* アルゴリズム

```

function A*(start, goal, h) returns start から goal までの経路または NO_SOLUTION
    parent ← ∅                                ▷ 親ノード, g 値, f 値を初期化
    g(start) ← 0
    f(start) ← h(start)
    open_set ← {start}
    while not IS-EMPTY(open_set) do
        current ← POLL(open_set)                ▷ オープンセットから f 値が最小のノードを取り出す
        if current = goal then
            return BACKTRACK(current)          ▷ goal に到達した場合, 経路を後ろ向きに辿り返す
        end if
        for each neighbor in GET-NEIGHBORS(current) do
            c ← g(current) + COST(current, neighbor)
            if c < g(neighbor) then            ▷ 求めたコストが既知のコストより小さい場合
                parent(neighbor) ← current      ▷ 親ノード, g 値, f 値を更新
                g(neighbor) ← c
                f(neighbor) ← c + h(neighbor)
                if neighbor ∉ open_set then
                    OFFER(open_set, neighbor)   ▷ 新しい探索先としてオープンセットに追加
                end if
            end if
        end for
    end while
    return NO_SOLUTION                        ▷ 目的地に到達できない場合, 解なしを意味する値を返す
end function

```

オープンセットに含まれていない場合には、オープンセットに追加する。探索済みのノードであっても、より良い経路が見つかった場合には、そのノードを再びオープンセットに追加することで、再探索を可能としている。まこのオープンセットへの追加はクローズドセットの役割を果たしているため、このアルゴリズムでは、クローズドセットを明示的に管理する必要がない。

一般にロボカップレスキューシミュレーションでは、A* アルゴリズムの経路コストには、エリアの重心間の距離が用いられる。また、ヒューリスティック関数には、探索ノードから目的ノードまでのユークリッド距離が用いられる。これはエリアの座標がその重心に設定されており、計算コストが低いためである。A* アルゴリズムで利用されるコストの項と、ロボカップレスキューシミュレーションにおけるエリアの対応関係を図 3.22 に示す。また、ある隣接したエリア n とエリア m との間の経路コスト $\text{COST}(n, m)$ 、および推定コスト $h(m)$ をそれぞれ式 (3.4)、式 (3.5) に示す。ここで、式中の $\text{dist}(p, q)$ は 2 点 p と q 間のユークリッド距離を表し、 x_n, y_n はそれぞれエリア n の x, y 座標を表す。

$$\text{COST}(n, m) = \text{dist}(n, m) = \sqrt{(x_n - x_m)^2 + (y_n - y_m)^2} \quad (3.4)$$

$$h(m) = \text{dist}(m, \text{goal}) = \sqrt{(x_m - x_{\text{goal}})^2 + (y_m - y_{\text{goal}})^2} \quad (3.5)$$

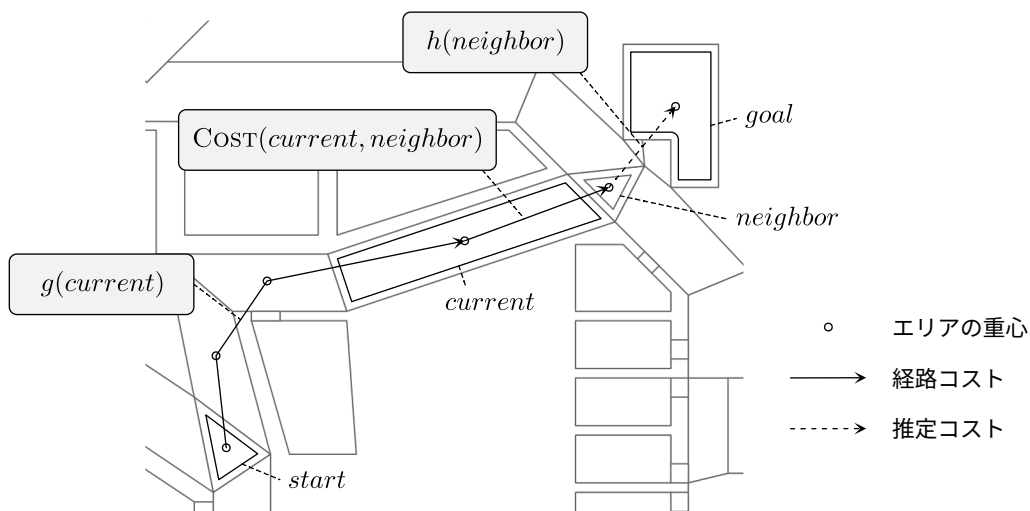


図 3.22 ロボカップレスキューシミュレーションにおけるエリアと A* アルゴリズムのコストの項との対応関係

本戦略にも、ユークリッド距離に基づく経路計画モジュールを `EuclideanPathPlanning` として定義し、一部の計算に利用している。しかし、このコスト関数では、瓦礫の影響を考慮していないため、対象の道路が瓦礫により通行不能な場合にも、通行可能な道路と同じようにコストが求められる。そこで、`PassablePathPlanning` では、瓦礫の影響、重要道路、担当地域を反映された新たなコスト関数を定義している。このコスト関数を式 (3.6) に示す。

$$\text{COST}'(n, m) = (1 + \omega_1(m) + \omega_2(m) + \omega_3(n, m)) \text{dist}(n, m) \quad (3.6)$$

ここで、 ω_1 , ω_2 , ω_3 は経路コストを調整するためのペナルティ項である。これらの関数は特定の条件を満たす場合に定数 w_i (> 0) を、満たさないときに 0 を返す。具体的には、次のとおりである。

- $w_1(m)$: エリア m が重要道路に含まれない場合にペナルティ w_1 を課す。
- $w_2(m)$: エリア m が自身の担当地域外である場合にペナルティ w_2 を課す。
- $w_3(n, m)$: エリア n の前にいたエリア (親ノード) からエリア m への移動が瓦礫に妨げられている場合にペナルティ w_3 を課す。

これにより、コスト関数は重要道路や担当地域を優先的に通過し、瓦礫により通行不能な道路を避けるように設計されている。各ペナルティは距離に比例するものとしているため、長い (大きい) エリアを通過する場合には、その影響が大きくなる。また、重み w_1 , w_2 , w_3 は各ペナルティの大きさを調整するパラメータである。いずれのペナルティ条件も満たさない場合、コストは $\text{COST}'(n, m) = \text{dist}(n, m)$ となり、エリア n とエリア m との間の距離に等しくなる。

`PassablePathPlanning` のヒューリスティック関数は式 (3.5) のままとしている。これは許容性を保つためである。A* アルゴリズムにおける許容性 (admissibility) とは、ヒューリスティック関数 h の値が実際の経路よりも常に小さく見積もられることを指す。A* アルゴリズムでは、この許容性が満たされる場合、最適解を見つけることが保証されている。図 3.22 から分かるように、 $h(\text{neighbor})$ は neighbor から goal までのユークリッド距離であり、実際の経路コストはこれよりも小さくなり得ない。また、新たに定義したコスト関数 $\text{COST}'(n, m)$ も、常に $\text{COST}'(n, m) \geq \text{dist}(n, m)$ を満たすため、`PassablePathPlanning` は許

容性を保つ.

コスト関数の ω_3 で求める通行可能性は、対象のエリア A の領域のうち、通行可能な領域 \mathcal{P} と通行可能な辺の集合 $\mathcal{E}_{\text{pass}}$ から判定する. まず、エージェントを点として近似し、エージェントがエリア A を経由して、エリア A_{prev} から、エリア A_{next} への移動できるかどうかを考える. この移動が可能であるためには、道路 A_{prev} から A へ、そして A から A_{next} へと至る通行可能な領域が連続している必要がある. この条件を定式化すると、次のようになる.

$$\text{PASSABLE}(A, A_{\text{prev}}, A_{\text{next}}) = \text{TOUCHED}(\mathcal{P}, \mathcal{E}_{\text{pass}}^{(\text{prev})}) \wedge \text{TOUCHED}(\mathcal{P}, \mathcal{E}_{\text{pass}}^{(\text{next})}) \quad (3.7)$$

ここで、 $\mathcal{E}_{\text{pass}}^{(\text{prev})}$, $\mathcal{E}_{\text{pass}}^{(\text{next})}$ はそれぞれ道路 R_{prev} , R_{next} と共有する通行可能な辺の集合である. また、 $\text{TOUCHED}(E, A)$ は辺 E がエリア A に接している場合に真を返す関数である. これらの集合は次のように与えられる.

$$\mathcal{E}_{\text{pass}}^{(\text{prev})} = \{E \mid \text{TOUCHED}(E, R_{\text{prev}}), E \in \mathcal{E}_{\text{pass}}\} \quad (3.8)$$

$$\mathcal{E}_{\text{pass}}^{(\text{next})} = \{E \mid \text{TOUCHED}(E, R_{\text{next}}), E \in \mathcal{E}_{\text{pass}}\} \quad (3.9)$$

探索が開始される地点では、エージェントの位置 \mathbf{p} から、次のエリア A_{next} への移動できるかを判定する必要がある. この場合は式 (3.7) をエージェントの位置に置き換えることで、次のように表される.

$$\text{PASSABLE}(A, \mathbf{p}, A_{\text{next}}) = \text{CONTAINS}(\mathcal{P}, \mathbf{p}) \wedge \text{TOUCHED}(\mathcal{P}, \mathcal{E}_{\text{pass}}^{(\text{next})}) \quad (3.10)$$

ここで、 $\text{CONTAINS}(A, \mathbf{p})$ はエリア A がエージェントの位置 \mathbf{p} を内包する場合に真を返す関数である.

通行可能な領域 \mathcal{P} は、まずエリア A から通行不能な瓦礫群 \mathcal{B} を除いた部分として定義できる. しかし、ロボカップレスキューシミュレーションにおいては、エージェントは点ではなく、半径 0.5 m の円として表現される. そのため、式 (3.7) や式 (3.10) の条件を満たしていても、通行領域の幅が細く、実際には通行できない場合がある. この条件を考慮するために、瓦礫群 \mathcal{B} とエリア A の通行不能な辺 (壁) \mathcal{E}_{imp} を、それぞれエージェントの半径だけ膨張させた当たり判定用の領域 \mathcal{C} を定義する. 最終的に、通行可能な領域 \mathcal{P} は次のように定義される.

$$\mathcal{P} = A \setminus \mathcal{C} \quad (3.11)$$

$$\mathcal{C} = \bigcup_{B \in \mathcal{B}} \text{BUFFER}(B, 0.5) \cup \bigcup_{E \in \mathcal{E}_{\text{imp}}} \text{BUFFER}(E, 0.5) \quad (3.12)$$

ここで、 $\text{BUFFER}(G, r)$ は図形 G を半径 r だけ膨張させた領域を返す関数である.

通行可能性の判定の例を図 3.23 に示す. この例では、図中の赤い矢印のように中央の台形の道路を左から右へ通行できるかどうかを判定する. この道路は 4 本の辺で構成されており、上下の辺が通行不能 (実線)、左右の辺が通行可能 (点線) である. 通行不能な辺および知覚している瓦礫から、それぞれの形状をエージェントの半径分だけ膨張させ、当たり判定 (緑の領域) を作成する. このとき、図で示している例のとおり、隣の道路にある瓦礫も膨張させたことで、対象のエリアの通行に影響することがある. そして、この当たり判定を対象の道路から除いた通行可能領域 (ピンクの領域) から、通行可能性を判定する. この例では、通行可能領域に左の通行可能な辺は接しているが、右の通行可能な辺は接していないため、この道路は通行不能と判定される.

コスト関数のパラメータはエージェントの実際の動作の観測に基づく調整から、経験的に $w_1 = 3.0$, $w_2 = 2.0$, $w_3 = 30.0$ と設定した. ここで例えば、 w_1 が 3.0 であることは、エージェントから見て、重要道路に含まれないエリアを通過する場合には、そのエリアの移動コストが実際の 3 倍だけ大きく評価されるこ




図 3.23 通行可能性の判定の例

とを意味する。特に、 w_3 を他のパラメータよりも大きく設定したのは、瓦礫により通行不能な道路を避けることを優先するためである。この値が小さいと、通行不能な道路が経路に含まれやすくなり、瓦礫が啓開されるのを待つことになる。しかし、通常のスナリオにおいては、地図に対して土木隊の数が十分にいないことが多いため、瓦礫を避けることを優先する方が救助効率において効果的である。そのため、このような値に設定している。

実際に迂回路が選択された例を図 3.24 に示す。図 3.24 では、エージェントの右側の道路が瓦礫で通行不能となっている。そのため、目的地に向けて区画の周囲を回り込む経路が選択されていることが確認できる。

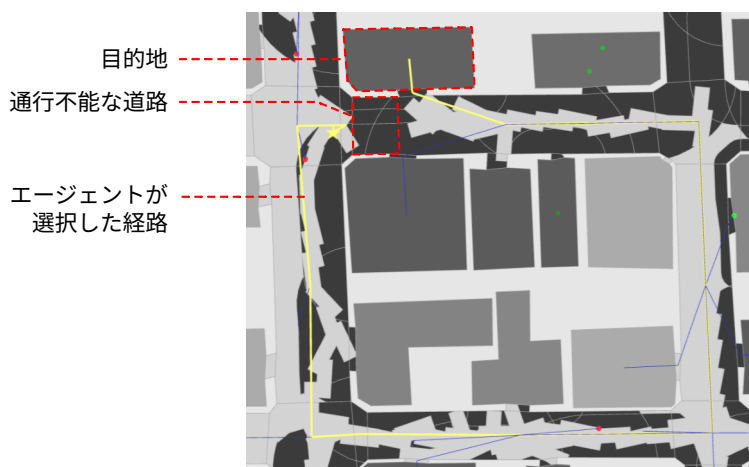


図 3.24 実際に迂回路が選択された例（災害シナリオ：sakae, ringo-viewer による可視化）

このように独自のコスト関数と通行可能性の判定を導入することで、PassablePathPlanning では、瓦礫を考慮した経路探索を実現する。本戦略では、この経路探索に基づき瓦礫を迂回した移動や移動時間の見積もりをおこなう。

3.4.5 救助部隊への担当地域の割り当て

ロボカップレスキューシミュレーションでは、タスクを優先度順に解決する貪欲法に基づく戦略がよく採用される。この戦略はタスクに対する評価が適切である場合には、各タスクに対して必要十分な救助部隊エージェントが割り当てられる。第 3.4.3 項で述べた、本戦略のタスクの選択方法もこの貪欲法の一つで

ある。

しかし、ロボカップレスキューシミュレーションのように、動的かつ不確実性を伴う環境でのマルチエージェントのタスク割り当てにおいて、適切な評価を設計することは難しい。そのため、貪欲法に基づくタスク割り当てでは、同じタスクを複数の救助部隊エージェントが重複して選択し、他のタスクが後回しにされるリスクがある。特に、救助部隊エージェントが集中的に配置される災害シナリオでは、エージェント間で知覚範囲が重複し、そこから構成される知識が大きく重なるため、このリスクが高まる。

このような重複選択による非効率を避けるために、本戦略では救助部隊エージェントに担当地域を割り当てる。担当地域を設定することで、各エージェントは異なる範囲を探索し、重複行動を抑え、分散的に処理できる。その結果、探索範囲が全体に偏りなく広がることで、未発見の市民に遭遇する確率が高まり、より多くの市民を救助できることが期待できる。

本戦略では、地域全体を救助部隊エージェントと同じ数だけ分割し、各エージェントに地域を1対1で割り当てる。この担当地域の割り当ては、救助活動を開始する前の事前計算でおこなう。エージェントはまず自身と同じ種類の救助部隊エージェントの数だけ、地域全体を分割する。この分割では、各担当地域での探索範囲が均等になるように、地図に含まれるエリアの重心をデータ点として、クラスタリングをおこなう。その後、分割された地域（クラスタ）と救助部隊エージェントの配置から、移動コストが小さくなるように、エージェントに地域を1対1で割り当てる。

クラスタリングには、 k -means++法を用いる。 k -means++法は k -means法の初期値の選択を改善したものであり、精度の高いクラスタを高速に獲得できるアルゴリズムである [15]。本戦略では、事前計算の限られた時間の中でより良い地域集合を獲得するために、 k -means++法を採用している。また、 k -means++法では、その手順の中で繰り返し、クラスタを更新し、調整する部分が存在するが、その更新回数は最大100回のイテレーションで打ち切る。これは高速に実行できる k -means++法であっても、入力によっては、収束までに時間を要する可能性があるためである。

k -means法 (k -means method) は非階層型のクラスタリングアルゴリズムの一つであり、クラスタ中心からの平方和誤差を最小化するように、与えられた k 個のクラスタにデータを分割するアルゴリズムである [16]。データ点の集合 $\mathcal{X} \subset \mathbb{R}^n$ を k 個のクラスタに分割する問題を考えるとき、 k -means法は次の手順でおこなわれる。

- 手順 1. k 個のクラスタ中心 $C = \{c_1, c_2, \dots, c_k\}$ を任意に選択する。
- 手順 2. $i \in \{1, \dots, k\}$ について、クラスタ C_i を他のどのクラスタ中心 c_j よりも c_i に近い X 内の点の集合として設定する。
- 手順 3. $i \in \{1, \dots, k\}$ について、 c_i をクラスタ C_i に含まれるすべての点の重心（算術平均）として更新する。
- 手順 4. クラスタ中心 C が変化しなくなるまで、手順 2. と手順 3. を繰り返す。

なお、 k -means法におけるクラスタ中心は、必ずしも重心には限定されず、各アルゴリズムで用いるデータの類似度の定義に依存する。ただし、本研究では、類似度をユークリッド距離で定義しており、 k -means++法の提案論文でも同様に扱っているため、クラスタ中心を重心としている。

しかし、 k -means法は初期のクラスタ中心の選択に依存して、凝集度の低い、悪い解（局所最適解）に収束することがある。このような局所最適解へ陥る現象は、例えば、実際には距離の離れているデータ点が初期のクラスタ中心によって、結び付けられ、その後、分離しなくなることなどから発生する。そこで、 k -means++法では、初期のクラスタ中心を次の手順で選択することで、この問題を改善している。

- 手順 a. 1 つ目のクラスタ中心 c_1 を、データ点の集合 \mathcal{X} から一様にランダムに選択する。

- 手順 b. すでに選択された中心からデータ点 x までの距離を $D(x)$ とし, 新しいクラスタ中心 c_i を $x \in \mathcal{X}$ から, 確率 $\frac{D(x)^2}{\sum_{x \in \mathcal{X}} D(x)^2}$ に基づいて選択する.
- 手順 c. k 個のクラスタ中心がすべて選択されるまで, 手順 b. を繰り返す.
- 手順 d. 手順 c. で選択されたクラスタ中心を用いて, **k-means** 法の手順 2. 以降を実行する.

k-means++ 法では, この初期のクラスタ中心の選択方法から, クラスタ中心が離れて選択される傾向があるため, **k-means** 法よりも良い解に収束しやすい. また, 実験から **k-means++** 法はクラスタの更新回数が少なくなることで, **k-means** 法よりも高速に収束することが知られている [15].

担当地域 (クラスタ) の割り当てでは, 各救助部隊エージェントが自身の担当地域に到達するまでの移動コストを最小化するように割り当てをおこなう. いま, N 隊の救助部隊を考える. i 番目 ($i \in \{1, \dots, N\}$) の救助部隊エージェントの位置を \mathbf{p}_i とし, 割り当てられた地域の中心から最も近いエリアの重心を $\mathbf{q}_{\sigma(i)}$ とする. このとき, 割り当て $\sigma: \{1, \dots, N\} \rightarrow \{1, \dots, N\}$ に対して, 次の最適割り当て σ^* を求める.

$$\sigma^* = \operatorname{argmin}_{\sigma} \sum_{i=1}^N \operatorname{dist}_{\text{path}}(\mathbf{p}_i, \mathbf{q}_{\sigma(i)}) \quad (3.13)$$

ここで, $\operatorname{dist}_{\text{path}}(\mathbf{p}_i, \mathbf{q}_{\sigma(i)})$ はエージェント \mathbf{p}_i から地域の中心 $\mathbf{q}_{\sigma(i)}$ までの経路距離を表す. 本戦略では, この経路距離を第 3.4.4 項に示したユークリッド距離に基づく A^* アルゴリズムにより求める.

本戦略では, この最適割り当て σ^* を求める方法として, ハンガリアンアルゴリズムを用いる. ハンガリアンアルゴリズムは N 個の資源を N 個の仕事に対して 1 対 1 で割り当てるときに, その総コストを最小化する問題を解くアルゴリズムである [17]. したがって, 本戦略においてはエージェントを「資源」, 地域を「仕事」とみなすことで, 式 (3.13) の最適割り当て問題をハンガリアンアルゴリズムで解くことができる. ハンガリアンアルゴリズムの手順は概略すると, 以下のとおりである.

- 手順 1. 各資源と仕事の組み合わせに対するコストを行列として表現する.
- 手順 2. 行ごと, 列ごとに最小値を引き, 行列の要素にゼロを作る.
- 手順 3. ゼロを基準に仮の割り当てをおこなう.
- 手順 4. 手順 3. ですべての資源を一意に割り当てられなければ, 行列を調整して新しいゼロを作る.
- 手順 5. 完全な割り当てが得られるまで, 手順 3. と手順 4. を繰り返す.

これらの手順から, 総コストを最小化する最適な割り当てが求められる.

実際に提案手法により, 担当地域を救助部隊エージェントに割り当てた例を図 3.25 に示す. この例では, 栄地区の地図に対して, 8 体の消防隊エージェントを配置し, 8 つの担当地域を割り当てた. 図の右部分は割り当て結果として得られた, それぞれの担当地域である. 結果から, 担当地域は概ね均等に分けられていることが分かる. また, 各エージェントの位置から近い担当地域が割り当てられていることが確認できる.

このように本戦略では, 救助部隊が効率的に情報探索できるように各救助部隊への担当地域の割り当てる. 本戦略では, この割り当てられた担当地域に基づき, 探索やタスクの選択を実行する.

3.4.6 重要道路の構築

土木隊は救助部隊全体の活動効率を高めるために, 道路に飛散した瓦礫を撤去し, その通行を確保する. これにより, 消防隊や救急隊が目的地へ向かうときに, 進路上の瓦礫により辿り着けない, あるいは迂回しなければならないといった問題を解消する.

しかし, これまで競技会などで対象とされてきた現実的な災害シナリオのほとんどでは, 土木隊の数に対する瓦礫の量が多く, 制限時間内にすべての道路を啓開することが困難なものとなっている. また, この啓



図 3.25 エージェントの位置と割り当てられた担当地域の例（左：エージェントの配置，右：割り当てられた担当地域，地図：sakae）

開活動の間にも、負傷者は体力が減少していく。つまり、救助できる市民の数が増やすためには、啓開すべき道路を適切に選択する必要がある。

そこで本戦略では、優先的に啓開し、各救助部隊が積極的に利用する道路を重要道路として定義する。この重要道路は事前計算において、地図情報から決定する。重要道路を事前に決定しておき、救助部隊でこれを共通することで、限られた範囲の啓開であっても、効率的な市民救助を図る。第 3.4.3 項で述べたとおり、土木隊の啓開対象の選択において、この重要道路を優先的に啓開される。この戦略により、重要道路は救助活動の初期における通行の確保が期待される。また、第 3.4.4 項で述べたとおり、これを受けて、救助部隊は移動経路の選択において、重要道路を優先的に選択する。優先道路は啓開されている可能性が高いため、これを移動経路として選択することで、途中の瓦礫により、目的地に辿り着けないリスクを低減できる。

重要道路は多くの市民を救助するために、要救助者を発見しやすいものであることが望ましい。ロボカップレスキューシミュレーションにおいて、要救助者は基本的に倒壊した建物内に存在する。建物外あるいは倒壊しなかった建物内に配置された市民は自力で避難所へ移動する。そのため、救急隊が搬送の途中で負傷者を搬出するなどの例外を除き、要救助者は負傷から自力で動くことができず、建物内に留まっている。しかし、事前計算ではこれらの要救助者がどの建物にいるかまではわからない。そのため、事前計算で利用可能な情報から、重要道路を「地図上の多くの建物へアクセスしやすい道路」と定義する。

本戦略では、重要道路が多くの建物へアクセスしやすいものとなるように、建物の空間分布に基づいて、これを決定する。建物の数や位置は災害シナリオにより異なる。そのため、多くの建物へアクセスしやすい道路を重要道路として決定するには、建物の空間分布を考慮する必要がある。具体的には、次の手順から求めた道路群を重要道路とする。

- 手順 1. 地図上のすべての建物を空間的にクラスタリングする。
- 手順 2. 各クラスタのクラスタ中心から最も近い建物を算出する。
- 手順 3. 手順 2. で算出した建物のすべての組み合わせの間で、最短経路となる道路を算出する。

ここで、クラスタリングには、k-means++ 法 (BuildingKMeansPlusPlusClustering), 経路探索にはユーグリッド距離に基づく A* アルゴリズム (EuclidianPathPlanning) を用いる。また、クラスタの数については、事前に適した値を決定しておくものとする。実際に決定された重要道路の例を図 3.26 に示す。

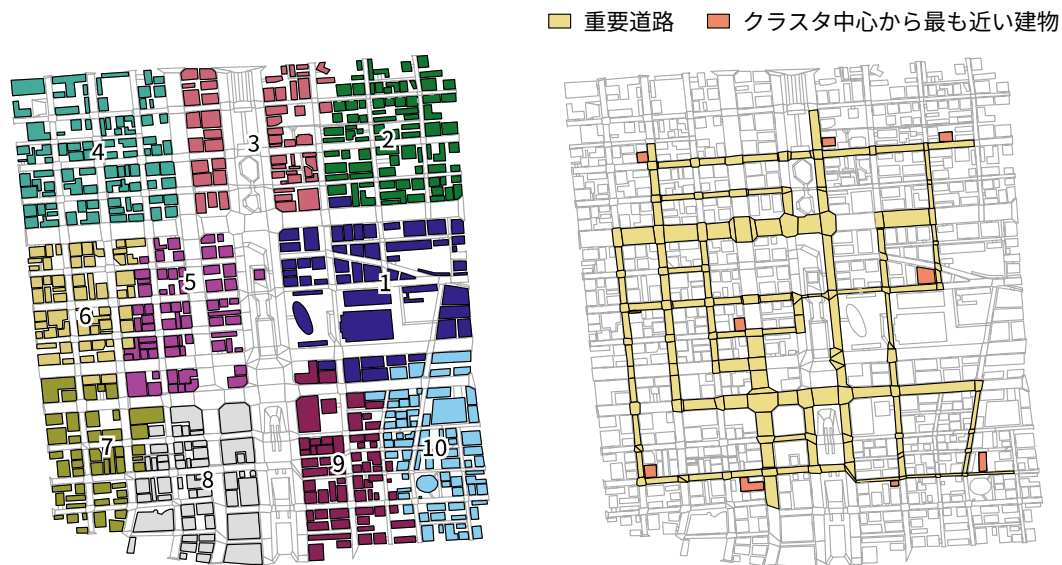


図 3.26 作成した重要道路の例 (左: 建物のクラスタ, 右: 基準となった建物と重要道路, 地図: sakae)

このクラスタ数は地図全体に対して重要道路が占める割合を決定している。例として、クラスタ数が 5 個, 15 個のそれぞれの場合の重要道路を図 3.27 に示す。図 3.27 のとおり, クラスタ数が多いほど, 基準となる建物が増え, 結果として接続される重要道路の数も増加していることがわかる。このため, 設定するクラスタ数は啓開される道路や救助部隊の探索範囲へ間接的に影響を及ぼす。

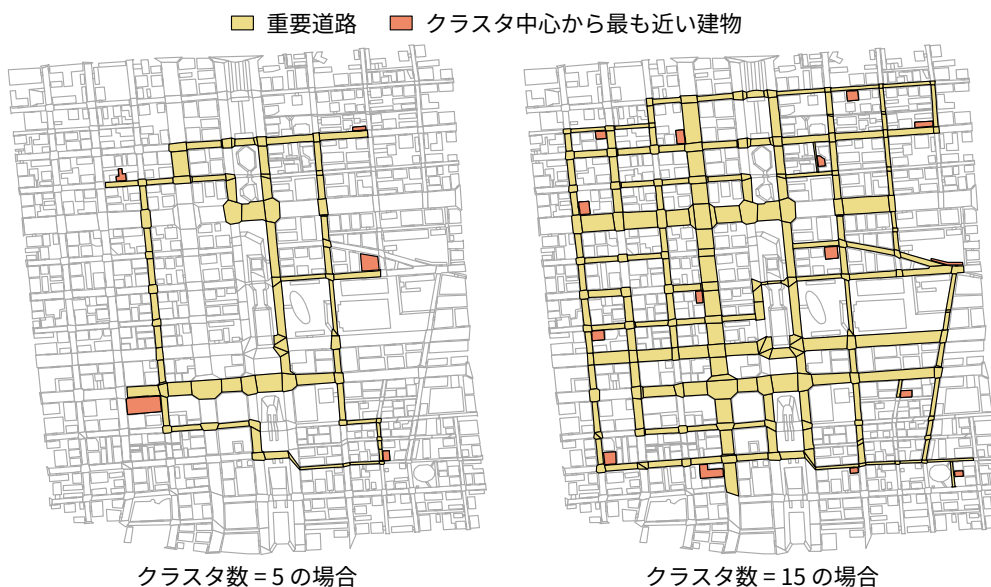


図 3.27 異なるクラスタ数の下で作成された重要道路の比較 (地図: sakae)

一方で、同じクラスタ数であっても、災害シナリオに基づく瓦礫の量によって救助成果は異なる。特に、瓦礫の多いシナリオでは、クラスタ数を過大にしてしまうと、啓開が時間内に完了できなくなり、重要道路を設定する効果が薄れてしまう。このような関係を踏まえ、本戦略では、過去の大会シナリオを用いた調整により、最終的にクラスタ数を10個と設定した。

本戦略では、このように建物の空間分布に基づいて重要道路を構築する。この結果、得られた重要道路はクラスタ間を効率的に連結し、広範囲に分布する建物へアクセスしやすいものであるといえる。したがって、これらの道路の啓開や救助部隊が積極的な利用は、多くの負傷者の発見につながる事が期待される。

3.4.7 救助部隊間の情報共有

救助部隊の意思決定において、通信による情報共有は重要な役割を果たす。救助部隊は知覚範囲の外にある情報を直接知ることができない。そのため、情報探索として、移動しながら対象地域の情報を収集する。しかし、市民の救助には猶予がないため、効率的に情報を収集し、意思決定に反映していく必要がある。救助部隊間の通信は、この情報収集を効率化し、迅速な意思決定を支援するものとなっている。

ロボカップレスキューシミュレーションでは、無線通信と音声通信の2種類の通信手段が用意されている。本戦略では、それぞれの特性に合わせた情報共有をおこなう。

無線通信は遠くの救助部隊へ情報を共有することが可能であるものの、通信帯域の制限から、共有できる情報量が限られている。また、それぞれの救助部隊はどのような情報を送信するかを互いに知ることができない。そのため、複数の救助部隊が多くの情報を共有しようとする、一斉に送信されたメッセージから通信チャンネルの容量が不足し、溢れた情報が失われるリスクがある。これらの理由から、無線通信では緊急度の高い情報を共有することが望ましい。

そこで本戦略では、無線通信において次の情報を共有する。

- 自身が瓦礫にスタックしているという情報
- 視界内の通行不能な道路の情報

自身が瓦礫にスタックしている情報は、土木隊に救助の要請をおこなうものである。また、通行不能な道路の情報は、救助部隊が移動経路を選択する際に、その道路を避けるために利用される。これらの情報は救助部隊の移動に直接影響し、緊急度が高いものと考えられる。また、両方とも送信する条件が限定されていることから、複数の救助部隊が一斉にメッセージを送信することによる通信の容量不足のリスクは低い。

一方で、音声通信は通信範囲があり、情報の共有範囲が近傍に限定される。しかし、通信チャンネルを全体で共有する無線通信とは異なり、各シミュレーションステップで各救助部隊は少なくとも1つのメッセージを送信できるものとなっている。1シミュレーションステップに送信できるメッセージの最大数は、災害シナリオにより異なるが、多くの場合は「1」に設定されている。

送信できるメッセージの数が限られているため、本戦略の音声通信では、各情報に優先度を設定し、緊急度の高いものから送信する。具体的には、次に示す優先度で各情報を共有する。

- 優先度 1. 自身の救出要請：自身が埋没しているという情報
- 優先度 2. 他の救助部隊の救出要請：視界内の他の救助部隊が埋没しているという情報
- 優先度 3. 市民の救出要請：視界内の市民が埋没しているという情報
- 優先度 4. 市民の搬送要請：視界内の市民が埋没から救出され、搬送を待っているという情報

これらの情報は周辺に消防隊や救急隊が存在することを前提として、それらの救助部隊に支援が必要であることを通知する目的で送信される。これらの情報を無線通信で共有した場合、受信した情報に含まれる救

助対象が、受信者の担当地域外である場合や、受信者から遠方に位置する場合には、支援に結びつかない可能性が高い。一方、音声通信は近傍にしか届かないことから、支援につながる可能性が相対的に高い。

通常の災害シナリオでは、音声通信の範囲は約 30–75m、救助部隊の知覚範囲は約 30–100m に設定される。つまり、音声通信と知覚範囲はほとんどが重なっている。そのため、音声通信が有効に機能するのは、壁などの障害物により、直接知覚できない対象を近傍の救助部隊に知らせる場面となる。このような場面では、情報を受信した消防隊や救急隊が対象発見までの時間を短縮できる。

基本的に、各救助部隊はこれらの優先度 1–4 の情報を送信する。しかし、常に送信すべき情報が存在するとは限らない。そのため、周囲に情報を共有できる救助部隊がいても、送信する内容がない場合がある。このような状況では、情報共有の機会が活かされず、無駄が生じる。

そこで、本戦略ではこのような無駄を削減するために、他の救助部隊から受信した情報を再送信するリレー通信をおこなう。このリレー通信は他の救助部隊から受け取った優先度 2–4 の情報を、優先度 5–7 の情報として再送信するものである。さらに、リレー通信する情報もない場合には、優先度 8 として自身の状態を送信する。このリレー通信は情報共有の機会の有効活用しつつ、知覚範囲外の情報が救助部隊へ伝達される可能性を高めるものである。

音声通信による情報共有の例を図 3.28 に示す。この例では、救急隊が埋没した市民を発見し、その情報を付近の消防隊に送信している。

エージェントの視界は壁（建物や道路の通行不能なエッジ）に遮られる。そのため、消防隊 A は埋没した市民との間の壁があることから、この市民を知覚できない。一方で、消防隊 A は救急隊の通信範囲内に位置しているため、救急隊からの通信を受信することで、この市民を認識できる。ただし、エージェントが通信情報を受信するのは、送信されたシミュレーションステップの次のステップとなる。

さらに、消防隊 B は消防隊 A が先ほど受信した情報をリレーした場合、その情報を受信できる。このようにして、消防隊 B は発信元の救急隊から離れており、その通信範囲の外に位置しているが、リレー通信を介することで、埋没した市民の情報を得ることができる。ただし、消防隊 B がこの情報を受信するのは、消防隊 A が情報を受信した次のシミュレーションステップであるため、送信からは 2 ステップ後となる。また、実際には各シミュレーションステップでエージェントは移動しているため、さらに遠くのエージェントへ情報が伝達される。なお、通信にはノイズがあるため、必ずしもすべての情報が伝達されるとは限らない。

エージェントの通信処理は各モジュールの情報更新の一部として定義される。本戦略における無線通信は自身が移動するための要請としての役割が強いため、移動の制御をおこなう `ExtActionMove` の一部として定義した。一方で、音声通信はタスクについての情報を共有するが、自身のタスクの遂行ではなく、他の救助部隊へ情報を共有し、その救助部隊のタスクを支援する役割を持っている。そのため、情報共有自体が目的となっており、ADF の既存のモジュールにはこれに対応するものが存在しない。

そこで、本戦略では音声通信による情報共有を `VoiceMessageManager` という新たなモジュールとして定義した。このモジュールは各シミュレーションステップで先に示した優先度に基づく音声通信を実行する。なお、このモジュールは独立しており、どこで実行しても問題ない。本戦略では実装上、`Tactics` の中で最初に実行される `TargetDetector` モジュールのサブモジュールとして定義している。

受信処理は無線、音声に関わらず、デフォルトの `Tactics` の中で処理されている。この処理は各モジュールの呼び出しより先に実行されるもので、通信により共有された情報のうち、知覚していないものを自身のワールドモデルへ反映している。本戦略では、この既存の受信処理をそのまま利用する。

このように本戦略では、無線通信と音声通信の特性に合わせた情報共有をおこなう。無線通信では、帯域の制約を考慮し、緊急度の高い移動に影響する情報を共有する。一方、音声通信では限られた送信機会を有効に活用し、近傍の救助部隊への情報共有を実行する。これらの戦略により、それぞれの通信の制約を考慮

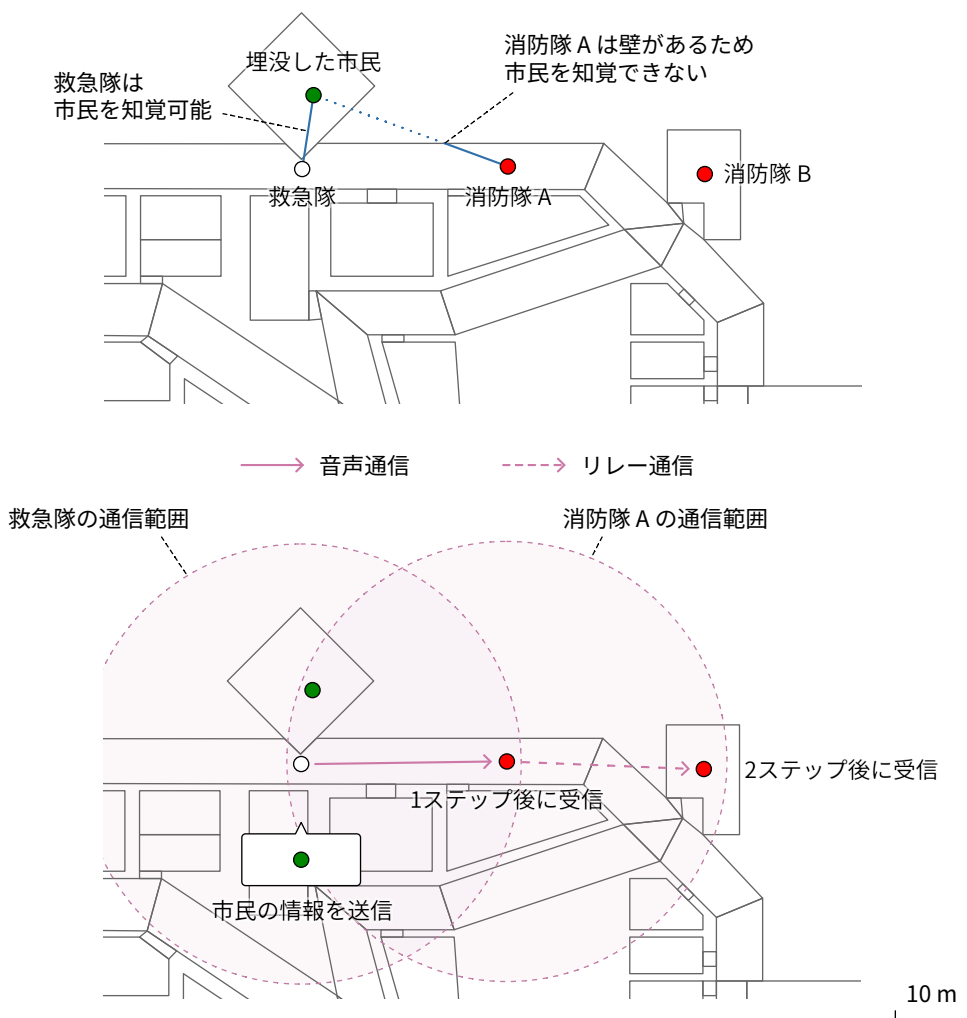


図 3.28 音声通信における情報共有の例（通信範囲：30m）

しつつ、効率的な救助活動を実現するための意思決定を支援する。

3.4.8 避難所の状況を考慮した搬送先の選択

救急隊により避難所へ搬送された負傷者は、必ずしも病床を利用できるとは限らない。これはそれぞれの避難所の病床の数に限りがあるためである。そのため、搬送先の避難所ですべての病床が利用されている場合には、病床が空くまで、負傷者はそこで待たなければならない。病床の空きを待つ間にも、負傷者の体力は減少していく。その結果、死亡してしまう場合もある。このような状況を考慮して、救急隊は搬送先を適切に判断する必要がある。しかし、救急隊は複数ある避難所の利用状況をリアルタイムに知ることができない。そのため、各避難所に搬送したときの待ち時間などを正確に予測することは難しい。

そこで本戦略では、救急隊が負傷者を搬入するときに、その時点で利用可能な情報から、最も早く病床が利用可能な避難所を推定し、そこへ搬送する。具体的には、次の式 (3.14) に示す避難所 r^* へ搬送する。

$$r^* = \operatorname{argmin}_{R_i \in R} T_{\text{total}}(R_i) \tag{3.14}$$

ここで、 R はすべての避難所の集合を表す。また、 $T_{total}(R_i)$ はある避難所 R_i を搬送先として選択した場合に、搬入時点から負傷者が病床を利用できるまでの合計時間を表す。本戦略では、この合計時間 $T_{total}(R_i)$ が最も短い避難所を搬送先として選択する。

負傷者は救急隊に搬入された後、避難所へ搬送され、病床が利用可能になるまで避難所で待機する。この一連の流れから、合計時間 $T_{total}(R_i)$ は「避難所までの搬送時間」と「避難所での待ち時間」の和として定義できる。ただし、待ち時間は搬入時点の情報からしか推定できず、将来の避難所の状態を正確に反映することはできない。そこで本戦略では、搬入時点で推定された待ち時間 $T_{wait}(R_i)$ を用いる。このとき、搬送中にこの待ち時間の一部が消化されるため、実際にかかる合計時間は式 (3.15) のとおり、搬送時間 $T_{transport}(R_i)$ と待ち時間 $T_{wait}(R_i)$ のうちの長い方として近似できる。

$$T_{transport}(R_i) = \max(T_{transport}(R_i), T_{wait}(R_i)) \tag{3.15}$$

図 3.29 はこれを図示したものである。図の上段では、搬送時間が待ち時間よりも短い場合を示している。この場合には、負傷者は搬出された後、病床の待ち行列に並ぶ。ただし、待ち時間を搬入時点のものとしているため、実際に待つ時間は搬送時間を差し引いた分の時間となる。したがって、全体の合計時間は待ち時間と等しい。一方、図の下段では、搬送時間が待ち時間よりも長い場合を示している。この場合には、搬送中に待ち時間が消化されるため、搬送された負傷者は避難所で搬出された後すぐに病床を利用できる。したがって、全体の合計時間は搬送時間と等しい。

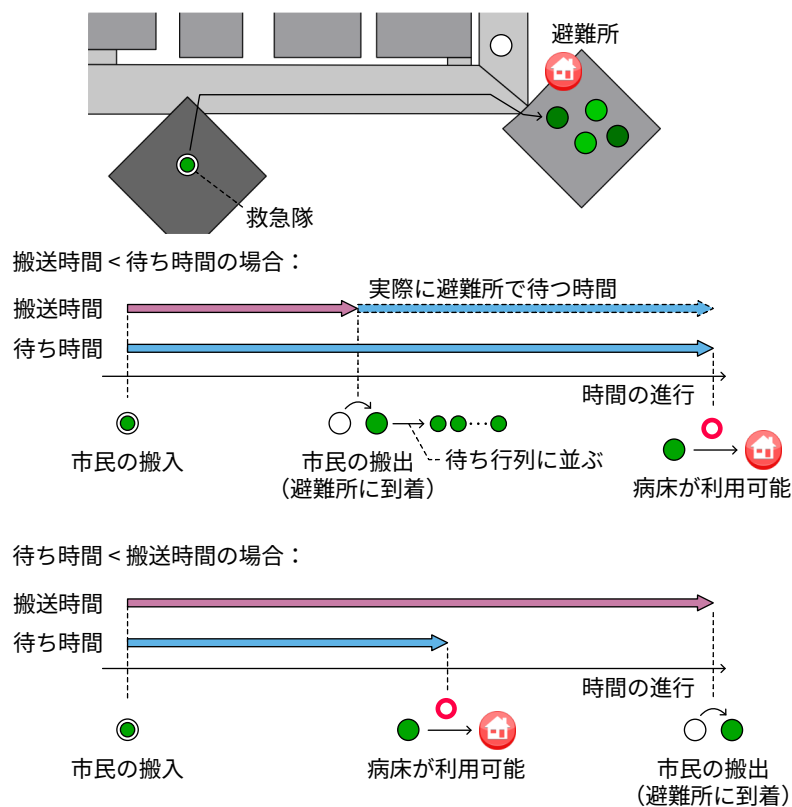


図 3.29 病床が利用可能になるまでの合計時間の例

搬送時間 $T_{transport}(R_i)$ は式 (3.16) に示すように、市民を搬入した地点から避難所までの経路距離を、エージェントの移動速度で割ることで求める。なお、ここで求めている搬送時間はあくまで推定値である。

シミュレーション上のエージェントの移動経路や速度はサブシミュレータの一つである `TrafficSimulator` で再現されている。この再現では、移動ごとのばらつきや他の交通との干渉をモデルに含んでおり、その経路や速度を正確に求めることが難しい。そのため、これらを推定値として扱っている。

$$T_{\text{transport}}(R_i) = \frac{\text{dist}_{\text{path}}(\mathbf{p}_{\text{load}}, \mathbf{p}_{R_i})}{v_{\text{agent}}} \quad (3.16)$$

ここで、 $\text{dist}_{\text{path}}(\mathbf{p}_{\text{load}}, \mathbf{p}_{R_i})$ は搬入したエリアから、避難所 R_i までの経路距離を表す。 \mathbf{p}_{load} , \mathbf{p}_{R_i} はそれぞれ、搬入した地点、避難所 R_i の中心座標である。また、 v_{agent} はエージェントの移動速度を表す。この値には、実験的に得られたエージェントの平均移動速度 40 m/min を用いる。

待ち時間 $T_{\text{wait}}(R_i)$ は搬入時点で救急隊が把握している避難所 R_i の情報から待ち行列理論に基づいて推定する [18]。救急隊の避難所の情報は、基本的に対象の避難所を知覚したときに、更新される。ただし、救急指令所は避難所の情報を常に把握しており、救急隊に共有できる。そのため、本戦略では、指令所がある場合には、避難所の状況に変化があるたびに、指令所からこの情報を送信し、救急隊の情報を更新する。したがって、指令所がある場合には、救急隊はリアルタイムに避難所の状況を把握でき、比較的高い精度で待ち時間を推定できる。

ロボカップレスキューシミュレーションの避難所では、負傷者は1つの待ち行列に並び、利用可能となった病床から順に利用する。このような状況は待ち行列モデル $M/M/c$ で表すことができる。待ち行列モデル $M/M/c$ とは、 c 個の窓口（ここでは病床が相当する）が並行して、1つの待ち行列を処理する状況を表現するモデルである。このモデルにおける平均待ち時間（行列の中で治療順を待つ時間の平均） W_q は式 (3.17) で与えられる。

$$W_q = \pi_0 \frac{\rho(c\rho)^c}{\lambda(1-\rho)^2 c!} \quad (3.17)$$

ここで、 ρ は利用率を表し、各病床の稼働の度合いを示す。この値は式 (3.18) で与えられる。

$$\rho = \frac{\lambda}{c\mu} \quad (3.18)$$

λ は単位時間あたりの到着率であり、避難所に到着する（待ち行列に加わる）負傷者の平均数を意味する。 μ は単位時間あたりのサービス率であり、1人の負傷者が治療を受けるのに必要な平均時間の逆数である。さらに、 π_0 は待ち行列が空である確率を表し、式 (3.19) により計算できる。

$$\pi_0 = \left[\left(\sum_{k=0}^{c-1} \frac{(c\rho)^k}{k!} \right) + \frac{(c\rho)^c}{c!} \frac{1}{1-\rho} \right]^{-1} \quad (3.19)$$

このように平均待ち時間 W_q は、窓口の数 c 、到着率 λ 、サービス率 μ から求められる。この平均待ち時間を関数 $\text{AVERAGEWAITTIME}(c, \lambda, \mu)$ と置き、ロボカップレスキューシミュレーションの避難所の状況に当てはめ、待ち時間 $T_{\text{wait}}(R_i)$ を式 (3.17) として定義する。

$$T_{\text{wait}}(R_i) = \text{AVERAGEWAITTIME}(N_{\text{bed},i}, \lambda_i, \mu_i) \quad (3.20)$$

この式では、それぞれの避難所で状況が異なることから、避難所 R_i における病床の数を $N_{\text{bed},i}$ 、到着率を λ_i 、サービス率を μ_i としている。このうち、病床の数はシナリオで定められているが、到着率とサービス率は避難所の情報から求める必要がある。

病床での治療が完了した市民はその避難所に留まることから、到着率 λ_i を式 (3.21) として定義する。

$$\lambda_i = \frac{N_{\text{weak},i}}{T_{\text{load}}} \quad (3.21)$$

$N_{\text{weak},i}$ は体力が全快でない市民の数を, T_{load} はシミュレーション開始から搬入時点までの時間を表す. この式により, シミュレーション開始から搬入時点までに, 1 シミュレーションステップあたりに何人の負傷者が避難所に到着したかを求める.

また, サービス率 μ_i を式 (3.22) として定義する.

$$\mu_i = \left(\frac{1}{N_{\text{weak},i}} \sum_{j=1}^{N_{\text{weak},i}} d_{i,j} \right)^{-1} \quad (3.22)$$

ここで, $d_{i,j}$ は避難所 R_i に搬送された j 番目の負傷者の負傷度を表す. サービス率は1人の負傷者の治療に要する平均時間の逆数である. 負傷度は病床において, 1 シミュレーションステップあたり, 1 だけ回復することができるため, 各負傷者の治療に要する時間は負傷度に等しい. このことから, サービス率 μ_i をその避難所にいる負傷者の平均負傷度の逆数とした.

本研究では, 避難所を選択するモジュールを新たに `RefugeSelector` として定義した. ここまでに説明した, 待ち時間理論に基づき貪欲法で避難所を選択する方法は, このモジュールのサブクラス `GreedyRefugeSelector` として実現している. 避難所の病床は 2022 年のコンペティションから追加された新しい要素である. そのため, 2025 年現在の ADF で提供される既存のモジュールでは, これを考慮したものがない. 本研究ではそこに新たなひな形として, `RefugeSelector` モジュールを定義した. このモジュールは救急隊の `ExtActionTransport` において, 負傷者を搬入した直後に実行されるものである.

また, 避難所選択の方法には, さまざまなものが考えられるため, 本研究では `RefugeSelector` のうち, 待ち行列理論に基づく避難所選択モジュールを `QueueingModelRefugeSelector` として定義した. `GreedyRefugeSelector` はこのサブクラスの一つである. 他のサブクラスとして, 合計時間 T_{total} の値の比に基づく確率分布から, 適応的に避難所を選択するモジュール `FitnessRefugeSelector` も実装した. 本研究では, 過去のコンペティションのシナリオを用いて, これらのモジュールを救助成果から比較し, `GreedyRefugeSelector` を採用している.

このように本戦略では, 避難所の病床の利用状況を考慮して, 搬送先を選択する. 距離の近さだけでなく, 搬送先の避難所の利用状況を踏まえることで, 搬送先の避難所において, 病床を待つ間に負傷者が死亡するといったリスクを低減する.

3.5 分散型協調戦略の評価

本研究では, 提案した分散協調戦略がさまざまな環境に柔軟に適応できるものとなっているか, を評価するために, サンプルエージェントとの比較実験をおこなう. 各エージェントをさまざまな災害シナリオのもとで実行し, RSL21 スコア関数に基づく最終スコアを比較する. 実装した個々の機能ごとの効果を独立に測定するのは困難であるため, 本研究では戦略全体の挙動を対象とし, この最終スコアに基づく評価をおこなう.

使用したエージェントは, 次の2つである. 両方とも GitHub で公開されているものである. 再現性のためにコミット ID を明示している. このサンプルエージェントは ADF で構築するエージェントのサンプルとして, `RoboCupRescue Simulation` から公式に提供されているものである.

- サンプルエージェント [19] (コミット ID : 46f7f0d)
- 本研究の分散協調戦略 (AIT-Rescue) [20] (コミット ID : 46e1156)

災害シナリオには 2024 年の世界大会の決勝で用いられた次の 10 個を使用した. vc を除き, 各シナリオは実在する世界の都市をモデルに作成されている. 各シナリオの概要を表 3.5 に示す.

表 3.5 使用した災害シナリオ

名称	地図	エンティティの数 (有無)				
	都市名 (国名)	指令所	瓦礫	市民	避難所	病床
bordeaux1	ボルドー (フランス)	なし	多い	少ない	少ない	多い
eindhoven2	アイントホーフェン (オランダ)	なし	多い	少ない	普通	少ない
eindhoven3	アイントホーフェン (オランダ)	なし	普通	少ない	普通	多い
istanbul1	イスタンブール (トルコ)	なし	多い	普通	普通	少ない
kobe2	神戸 (日本)	あり	多い	普通	少ない	少ない
montreal1	モントリオール (カナダ)	あり	少ない	多い	少ない	多い
paris1	パリ (フランス)	あり	少ない	多い	多い	少ない
sf1	サンフランシスコ (アメリカ)	なし	少ない	少ない	普通	多い
sydney1	シドニー (オーストラリア)	あり	少ない	多い	多い	多い
vc2	仮想都市	なし	多い	多い	普通	少ない

サンプルエージェントと AIT-Rescue の最終スコアを表 3.6 に示す. AIT-Rescue はすべての災害シナリオでサンプルエージェントと同等以上のスコアを達成した. この結果から, 提案した分散協調戦略はさまざまな環境に柔軟に適応できるものであることが示唆される.

表 3.6 サンプルエージェントに対する分散救助戦略 (AIT-Rescue) のスコアの比較

災害シナリオの名称	RSL21 スコア関数による最終スコア		
	サンプルエージェント	AIT-Rescue	スコアの差
bordeaux1	13.11	13.11	± 0.00
eindhoven2	5.11	5.11	± 0.00
eindhoven3	19.21	19.26	+ 0.05
istanbul1	225.47	226.67	+ 1.20
kobe2	183.84	190.20	+ 6.36
montreal1	31.60	34.60	+ 3.00
paris1	57.08	65.06	+ 7.98
sf1	20.02	22.04	+ 2.02
sydney1	43.60	47.90	+ 4.30
vc2	37.59	40.38	+ 2.79

最もスコアに差がある paris1 では, ビューアを用いた救助部隊エージェントの動作確認から, 設計した救助戦略が期待どおり働き, 救助部隊が連携して, 市民を救出する場面が確認された. 一方で, スコアに差がみられなかった bordeaux1 や eindhoven2 では, 瓦礫の量が土木隊の数に対して, 非常に多く, 救助活動が停滞していた. 本戦略は重要道路を定義し, その道路の確保を優先するものであるが, これらのシナリオでは, 重要道路の通行を確保しても, その先の道路に消防隊や救急隊が閉じ込められ, 多くの救助部隊が十分に機能していなかった. さらに, 同年の大会で提出された他の救助戦略においても, 市民を救助できていなかったことが確認された. これらの結果から, bordeaux1 や eindhoven2 は救助戦略の差が出づらいため, サン

ブルエージェントや AIT-Rescue にとって、難しいシナリオであることが示唆される。

各シナリオの地図や瓦礫を調査した結果、bordeaux1 や eindhoven2 は特に救助活動が困難であることがわかった。これらのシナリオには、共通して、次の3つの特徴がみられる。

- 活動対象の地域全体が広い
- 道路の多くが瓦礫により封鎖されている
- 多くの瓦礫が重なって生成されている

つまり、これらの特徴をすべて持つような環境が救助活動を困難にしているといえる。

表 3.7 瓦礫量の多い災害シナリオにおける道路と瓦礫の面積

災害シナリオの名称	道路の総面積 (m ²)	瓦礫の総面積 (m ²) ^a
bordeaux1	109,104.30	54142.76
eindhoven2	444,619.20	163154.90

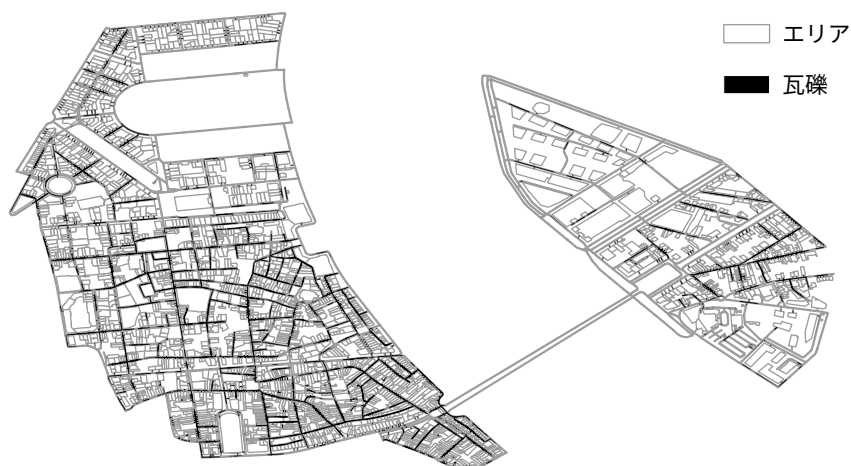
災害シナリオの名称	瓦礫の総量 (m ²) ^a	道路に対して瓦礫が占める割合 (%) ^b
bordeaux1	99742.75	49.62
eindhoven2	211236.10	36.70

a. 「瓦礫の総面積」は地図を上面から見たときに瓦礫が占める面積、「瓦礫の総量」は重なっている部分も含め瓦礫の面積を総和した値

b. 「道路に対して瓦礫が占める割合」は「瓦礫の総面積」を「道路の総面積」で割った値

さらに、各シナリオには特有の課題も存在する。これらのシナリオの道路と瓦礫の面積を表 3.7 に、瓦礫の配置を図 3.30 に示す。bordeaux1 では、図 3.30 に示すように、2つの地域を川が隔てており、長い橋で結ばれている。この橋の片側の入り口が瓦礫で封鎖されているため、これを開通するまで、地域間の移動ができない。本戦略では、重要道路の啓開を一律に近い箇所から進めるため、橋の啓開までに時間がかかり、救助活動が停滞していた。一方、eindhoven2 は表 3.7 に示した道路の総面積からもわかるように、とりわけ広い地域である。本戦略では、対象地域全域に対して漏れなく救助部隊を割り当てるため、各部隊の担当地域が広大となり、救助部隊全体として広域にわたる救助活動が困難になった。

本研究で提案した戦略は、さまざまな環境に柔軟に適応できることが確認された。その一方で、瓦礫の量が多いシナリオでは、救助活動が停滞し、戦略の十分に機能しないことも明らかとなった。これらの停滞が発生したシナリオを分析した結果、その要因がシナリオの特徴に基づいていることがわかった。現行の戦略設計において考慮できていない、これらの特徴に対応するためには、被害を予測し、その結果に応じて戦略を切り替えたり、パラメータの調整したりする仕組みが必要であると考えられる。また、設計において改善すべき対象を明確にするためには、これらの問題と関連する機能を明らかにすることが重要である。したがって、今後は個別の機能の効果を評価できる方法を確立することが課題となる。



(a) bordeaux1



(b) eindhoven2

図 3.30 サンプルエージェントに対して分散型協調戦略の優位性が見られなかった災害シナリオにおける瓦礫の配置

3.6 救助戦略の評価に向けた環境と戦略の関係分析

3.6.1 救助戦略の評価における課題

救助戦略には、その戦略が有効に働く環境と、そうでない環境が存在する。本研究で提案した戦略は瓦礫の少ないシナリオでは、設計したとおりに機能する一方、瓦礫の多いシナリオでは、救助活動が停滞し、十

分に機能しないことが明らかとなった。本研究では、2024年の世界大会決勝の災害シナリオを用いたが、例年、このコンペティションでは、ある災害シナリオにおいて戦略Aが戦略Bに勝る一方、別のシナリオでは戦略Bが戦略Aに勝るといった事例がみられる。このように環境により戦略の優劣が変化することは、救助戦略が有効に働く環境と、そうでない環境が存在することを示している。

ある救助戦略の評価が環境により左右されるのは、評価対象である個々のエージェントの振る舞いが環境に基づいているためであり、このことは自然な帰結である。エージェントアルゴリズムでは、知覚を入力として、行動を決定する。この知覚はエージェントの周囲の環境的要素やその状態に基づいている。そのため、自身の移動や他のエージェントの行動などにより環境が変化すれば、エージェントの行動も変化する。RSL21スコア関数のような救助戦略の評価関数では、このようにして出力した行動の結果を評価しているため、その値は環境によって異なることがわかる。

一方、エージェントの開発やコンペティションにおいては、救助戦略の優劣を評価するために、動作する環境を問わず、戦略自体を評価できる指標が求められている。この指標はエージェント開発においては、開発した機能が救助戦略の改善に寄与しているかどうかを判断するものとなる。また、コンペティションにおいては、提出された救助戦略の優劣を評価するためのものとなる。しかし、このような指標の実現は容易ではなく、現在も標準的なものは確立されていない。

現行のエージェント開発では、開発した機能が救助戦略の改善に寄与しているかどうかは、さまざまな災害シナリオにおけるシミュレーションの可視化とその観察結果を起点に、シミュレーションログやプログラムの動作の分析を経て、判断されている。これに対して、救助戦略の設計段階では、そのエージェントが置かれる環境をある程度想定しながら動作を組み立てる。しかし、マルチエージェントシミュレーションの中でエージェントが実際にどのように振る舞うかは、複数のエージェントおよび環境との相互作用を含んでいるため、そのすべてを想定することは難しい。そのため、実際にシミュレーションで動作させ、その結果を観察しながら、導入した機能が有効なものであるかどうかを確認するほかない。ただし、ここでの評価においても、用意した災害シナリオの中で、その機能が有効に働くかどうかを確認しているに過ぎず、未知の環境においても有効に働くかどうかまではわからない。

コンペティションでは、複数の救助戦略に順位を付けるために、参加しているチーム間での相対的なポイントが用いられている [12]。このポイントは各シナリオでのスコアに基づいて計算され、参加しているチーム数を n としたときに、1ポイントから $2n$ ポイントまでの範囲で与えられる。そして、すべてのシナリオのポイントを合計した最終チームポイントが、最も大きいチームが優勝となる。この方法は各シナリオのスコアを標準化しており、複数のシナリオを跨いで、救助戦略の優劣を相対的に評価できる。

しかし、このポイントもまた参加しているチーム、用意したシナリオのセットに対する相対的なものであり、チームやシナリオのセットが異なる場合には、優劣が逆転する場合がある。そのため、このポイントから劣位であったシナリオに対して改善をおこなったとしても、その改善が他のシナリオでの活動成果を低下させるものとなる可能性があり得る。つまり、このポイントはコンペティションとして、チーム間の優劣を評価するための機能的要件は満たしているが、エージェント開発にも適しているとはいえない。

3.6.2 環境と戦略の関係を分析する研究

現行の評価方法は得られる評価が用意した環境に依存する。また、この方法では評価対象の戦略がどのような環境で有効であるかまではわからない。これらの課題に対し、筆者を含む研究グループでは、環境の特徴を定量的に表現したり、環境と戦略との関係を統計的に分析したりする研究に取り組んでいる [21]。

なお、これらの研究は2021年よりも前のロボカップレスキューシミュレーションを対象としている。そのため、本研究で対象としたものとは仕様が異なっている。ただし、評価における課題自体はこのときから

一貫したものであることに注意されたい。

具体的な違いとしては、災害に火災が含まれ、救助結果の評価もこの火災が考慮されたものとなっている。この評価は都市価値と呼ばれ、式 (3.23) の式で定義される。

$$V(t) = \left(N_{\text{agent}}(t) + \frac{H_{\text{agent}}(t)}{H_{\text{agent}}(0)} \right) \sqrt{\frac{B(t)}{B(0)}} \quad (3.23)$$

ここで、 $V(t)$ はシミュレーションステップ $t \in [0, T]$ における都市価値、 $N_{\text{agent}}(t)$ は同ステップで生存しているエージェントの数、 $H_{\text{agent}}(t)$ は生存しているエージェントの体力の総和、 $B(t)$ は燃え残った、あるいは火災による被害を受けていない建物の面積の総和を表す。

まず、ロボカップレスキューシミュレーションにおける環境の定量化として、エージェントが活動する地図を数量的に表現する指標を定義した。また、この指標により数量化した地図と、エージェントの救助成果との関係を偏相関分析により分析をおこなった [22, 23]。

それぞれの指標は建物、道路、それらの関係から、表 3.8 に示す 16 個の指標を定義した。これらは 5 つのカテゴリに分類されており、地図の構造から数量的に計算できる。また、これらの定義はロボカップレスキューシミュレーションにおける災害状況や救助活動への影響が考慮されている。例えば、 c_{12} で表される建物間の距離が小さな地図では、建物から建物へ火が燃え移りやすく、消防隊の活動が困難になることが想定されている。

また、救助成果の指標として、都市価値維持率を提案した。都市価値はシミュレーション開始時の $t = 0$ のときに最大となるが、この値は災害シナリオで設定されるエージェントの数に影響を受ける。そのため、複数の災害シナリオ間で救助成果を比較するためには、この値を標準化する必要がある。そこで、式 (3.24) に示す都市価値維持率を提案した。

$$V_{\text{rate}} = \frac{V(T)}{V(0)} \quad (3.24)$$

都市価値維持率はシミュレーション開始時の都市価値 $V(0)$ に対する、シミュレーション終了時の都市価値 $V(T)$ の割合を表す。これにより、シミュレーション開始時の都市価値に依らず、エージェントの救助成果を評価した。

環境と戦略との関係を分析するために、さまざまな地図と救助戦略の組み合わせに対してシミュレーションを実行し、これらの指標に基づくデータを収集した。このシミュレーションでは、名古屋市の 20 地域、1-2km 四方の地図、また、対象とする救助戦略には 2007 年のコンペティションにおいて MRL、NAITO-Rescue というチームから提出されたものを使用した。さらに、配置によるばらつきを抑えるために、それぞれの地図と救助戦略の組み合わせに対して、30 回ずつシミュレーションを実行した。

シミュレーション結果を分析した結果、いくつかの指標が救助成果に有意な影響を与えていることが明らかとした。実験の結果、得られた偏相関係数を表 3.9 に示す。この表で、16 個の指標のうち、11 個しか示されていないのは、多重共線性が確認されたものを除外したためである。多重共線性は重回帰モデルにおける複数の独立変数間に、強い相関が存在する場合に発生し、回帰係数の推定が不安定になるという性質である。

結果から、MRL の救助戦略は広い地域での活動に弱いことが示唆された。表 3.9 より、MRL の救助戦略は c_{14} と強い負の相関が示されている。 c_{14} は道路の総延長を表し、この相関関係は MRL の救助戦略が道路の長い地域ほど、能力を発揮できない傾向にあることを示している。 c_{14} は地域の広さに応じて大きくなる傾向にある。そのため、MRL の救助戦略は広い地域における火災発生地点の発見や、埋没した市民の捜索を苦手としていることが考えられる。

一方、NAITO-Rescue の救助戦略は建物が密集した地域での活動に弱いことが示唆された。表 3.9 より、NAITO-Rescue の救助戦略はいずれの指標とも強い相関こそ認められないが、 c_7 、 c_{12} とは中程度の負の相

表 3.8 地図を表現する 16 の指標

記号	定義
建築面積	
c_1	グロスの面積とグロス内の建物面積の割合の平均値
c_2	セミグロスの面積とセミグロス内の建物面積の割合の平均値
c_3	グロスの面積とグロス内の延床面積の割合の平均値
c_4	セミグロスの面積とセミグロス内の延床面積の割合の平均値
建物の要素	
c_5	建物を形成する多角形の周長の平均値
c_6	建物と階数の平均値
建物と建物の位置関係	
c_7	建築面積のばらつき
c_8	最大隣接建物距離の平均値
c_9	最小隣接建物距離の平均値
c_{10}	建物間の距離のばらつき
建物と道路の位置関係	
c_{11}	接道距離の平均値
c_{12}	道路から見た建物間の距離の平均値
c_{13}	沿道建物数の平均値
密度	
c_{14}	道路の総延長
c_{15}	道路密度
c_{16}	棟数密度

関が示されている。 c_7 は建築面積のばらつきを表し、この値が小さいほど建物の面積が不均一であることを示す。また、 c_{12} は道路から見た建物間の距離の平均値を表し、この値が小さいほど道路沿いに建物が密集していることを示す。建物の大きさが不均一である場合、均一である場合に比べ、隣接する建物の数が増える傾向にある。このことから、NAITO-Rescue の救助戦略では、建物が密集した地域において、火災を早期に抑えられず、隣接する建物への延焼を防ぐのを苦手としていることが考えられる。ただし、 c_{12} との関係から、道路沿いに建物が密集している場合には、ある程度、有効な救助活動をおこなえることも示唆される。

このように環境と戦略との関係を分析することで、救助戦略の特徴を明らかにできることが示された。また、この分析に用いた指標は、救助戦略の特徴を説明するのに有効であることも示された。

我々の研究グループでは、さらにこれらの指標に基づく共分散構造分析から、救助戦略が持つ能力を共通する指標から評価する方法を提案した [24]。共分散構造分析とは、対象とする事象から得られた観測や、その背後にある潜在的な要因の関係を、統計的に分析する手法である。偏相関分析とは、潜在的な要因を変数として導入できる点で異なり、より複雑な関係を分析できる。

我々はこの研究で、図 3.31 に示す共分散構造モデルを定義した。共分散構造分析では、与えられたモデルがデータに適合するかどうかを評価する。これに対し、分析者は観測変数と潜在変数の関係を表すモデルを定義する必要がある。このモデルでは、3つの環境的要因と救助成果、地図の特徴との関係を定義してい

表 3.9 環境を表現する指標と救助成果との偏相関係数

指標	MRL	NAITO-Rescue
c_2	0.3462	-0.4816
c_5	-0.1468	-0.1190
c_6	0.1720	-0.3965
c_7	-0.2274	-0.6171
c_8	0.1356	-0.1383
c_{10}	0.06248	0.07780
c_{11}	-0.4950	-0.4476
c_{12}	-0.2787	-0.6477
c_{14}	-0.8960	-0.5566
c_{15}	-0.3155	-0.4091
c_{16}	-0.3659	-0.5868

る。環境的要因は地図の特徴を構成する役割を持つと同時に、救助成果に影響を与えるものとしてと仮定している。

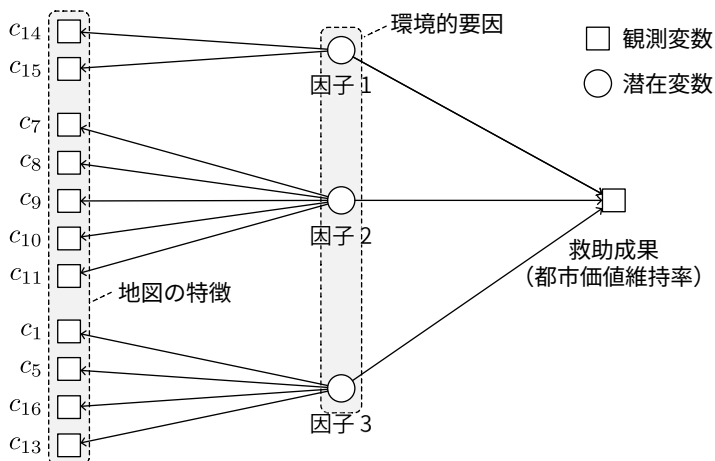


図 3.31 環境的要因と救助成果，地図の特徴との関係を表現する共分散構造モデル

これらの環境的要因を表現する因子は地図の指標に基づくデータから、因子分析により抽出した。因子分析からそれぞれの因子は次のように解釈できることが確認された。これらの因子の性質に基づき、救助戦略を評価する。

- 因子 1. 道路の密度と強く関係する因子である。この因子の影響が強いほど、道路の分枝数が多くなる。
- 因子 2. 建物から道路までの距離に強く関係する因子である。この因子の影響が強いほど、建物から道路までの距離が長くなる。
- 因子 3. 道路沿いの建物の数に強く関係する因子である。この因子の影響が強いほど、道路沿いの建物が多くなる。

統計的に十分なデータを分析対象とするため、災害シナリオ、救助戦略について、48,000 通りの大規模

な実験を実施した。救助戦略には、2018年から2020年のコンペティションで優秀な成績を残している、AIT-Rescue, MRL, Auraの3チームを使用した。災害シナリオについては、現実世界の地震分布に基づき、過去に地震の発生した794の地域から、1,000個の地図データを作成した。さらに、各地図データの下で、エージェントの初期配置による結果の偏りを除くため、これを変更した16通りの災害シナリオを作成し、シミュレーションを実行した。

実験から得られたデータから、共分散構造分析により分析した結果、救助戦略ごとに異なる傾向が示された。表3.10に、環境的要因から救助成果への回帰係数を示す。これらは各救助戦略に基づくエージェントの活動へ与える影響の度合いを意味する。

表 3.10 環境的要因が各救助戦略に基づくエージェントの活動へ与える影響

環境的要因	AIT-Rescue	MRL	Aura
因子 1	0.073	0.081	0.084
因子 2	0.067	0.011	0.062
因子 3	-0.058	-0.080	-0.14

これらの結果を用いることで、それぞれの救助戦略の特定の因子のもとで比較することができる。例えば、Auraの救助戦略は因子1に対して最も大きな回帰係数を持つ。因子1は道路の密度と強く関係する要因であるため、道路の複雑さを表現するものと解釈できる。つまり、この救助戦略は優れた探索能力を有し、道路の複雑な環境において、有効に働くものとなっていると考えられる。一方、Auraの救助戦略は因子3に対しては、他の救助戦略に比べて、最も小さな回帰係数を持つ。因子3は道路沿いの建物の数に強く関係する要因であるため、建物の密集度を表現するものと解釈できる。建物が密集した環境では、火災が広がりやすく、消防隊の活動が困難になる。そのため、この救助戦略は建物が密集した環境における、消火活動を苦手としていることが考えられる。

これらの解釈は分析者により異なるものであるが、救助戦略を開発するうえで、環境に対する性質を理解するのに役立つと考えられる。特に、自身の救助戦略における弱点の部分について、それを得意とする救助戦略と比較することで、その弱点を克服するための方策を検討できる。

3.7 救助戦略の設計と評価に関する考察

本研究では、さまざまな環境に柔軟に適応できる分散型協調戦略を提案した。その結果、提案した戦略は多くの災害シナリオにおいて、有効に働くことが確認された。一方で、提案した戦略は瓦礫の量の多い災害シナリオでは、十分に機能しないことも明らかとなった。

瓦礫の多いシナリオは本戦略の設計において、考慮した状況を超えたものであった。本研究の戦略設計では、地震災害状況に含まれる救出順序の判断や、閉塞した道路の迂回など、いくつかの状況を想定した。しかし、これらの状況は無数に存在し、すべて考慮することはできない。そのため、考慮できていない状況においては、用意した戦略が十分に機能しない場合も存在する。

戦略をあらゆる状況に対応させることは困難であるが、一つでも多くの状況に対応できる戦略へと改善していくには、現行の戦略を適切に評価、分析し、その弱点を明らかにする、またこれを克服する必要がある。さらに、戦略の改善では、適用した改修が本質的な問題に対して有効なものであったかどうかを判断することも重要である。特に、対象とした問題を解決したとしても、その改修により、別の問題が発生する可能性もある。我々の研究グループで取り組んできた、環境と戦略の関係性を分析する研究は、これらの評価と分析

に役立つ方法論の一つであるといえる。

これらから、戦略設計プロセスでは、戦略を改善するための方策、あるいはそれにつながる知見をどのように得るかが課題であるといえる。この課題は戦略の有効性を評価する評価プロセスにおける課題でもある。ロボカップレスキューシミュレーションでは、大きな枠組みとして標準問題が設定されているが、救助戦略の改善においても、それぞれの起点となった問題（状況）を含む、抽象的かつ本質的な問題がそこに存在していると考えられる。環境と戦略の関係分析では、この本質的な問題を環境の特徴群から捕捉し、救助戦略との関係を分析している。しかし、これらの分析結果は戦略の特徴を説明するに留まり、改善対象との結びつきは強いとはいえない。今後の課題として、戦略設計プロセスにおける課題の解決には、どのように改修すれば、本質的な問題の解決につながるかを明らかとすべく、環境と戦略との関係の分析手法を精緻化していくことが挙げられる。

第4章

日本の交通事故要因の空間分析

4.1 交通事故要因の究明を通じた課題の明確化

マルチエージェントシミュレーションを用いた問題解決では、対象とする問題をコンピュータ上で扱うために、問題を抽象化し、モデルとして定義する必要がある。第3章で扱った災害救助問題では、問題がすでにロボカップレスキューシミュレーションとしてモデル化されていた。そのため、このモデルを利用できた。しかし、このように対象がすでにモデル化されているという事例は少ない。多くの場合には、明らかとした問題について「何をエージェントとするか」「エージェントが活動する環境はどのようなものか」などを定義する必要がある。これに向けて、対象の問題を分析し、モデルの定義を検討する手順が必要となる。

本研究では、マルチエージェントシミュレーションを用いた問題解決において、この「モデル化プロセス」の課題を明らかにし、その解決策を示す。このモデル化の対象として、日本の交通事故問題を取り上げ、その要因分析を通じて、この課題を検討する。

交通事故による被害の低減に向けては、過去さまざまな統計的分析や、その結果に基づく対策が実施されてきた。また、関連するマルチエージェントシミュレーションに、マルチエージェントベースの交通流シミュレーションがある。交通流シミュレーションは車両や歩行者といった交通主体をエージェントとして、交通主体の流れを再現するものである。このシミュレーションの利用では、交通の円滑性や関連するサービスの戦略が検討されている [25]。しかし、これらのシミュレーションは平時の交通流を再現するものであり、交通事故は扱われていない。

交通事故は多くの要素が複雑に関係する現象である。また、交通事故の中で最も多い事例である車両間の衝突は、当事者間の相互作用からなる現象であり、まさにマルチエージェントシミュレーションを通じた分析が有効であることが予想される。さらに、交通事故を対象とするマルチエージェントシミュレーションでは、社会全体が交通安全を目指すと同時に、各個人が買い物やドライブといった各々の目的を満たす必要がある。このような多目的な性質を持つ交通事故問題への応用へ挑戦することは、マルチエージェントシミュレーションによる問題解決の体系化を進める、一つのブレイクスルーとなると考えられる。

4.2 交通事故情勢と事故分析における課題

4.2.1 日本の交通事故情勢

交通事故は世界的な社会問題の一つである。WHO（世界保健機関）によると、世界の交通事故による死者数は約130万人、負傷者数は2,000万人以上にのぼる。この深刻な問題を受けて、WHOと国際地域委員会は2021年10月に「Global Plan for the Decade of Action for Road Safety 2021–2030」という計画を策定した。この計画では、2030年までの交通事故による死者数を、2020年から少なくとも50%削減するこ

とを目標に掲げている [26].

国内においても、交通事故による被害は重く受け止められ、国土交通省や警察庁を中心に対策が進められている。特に、交通事故による死者数最多を記録した1970年から半世紀以上の間、国をはじめとする交通安全対策が進められ、現在も減少傾向にある。交通事故とは自動車、鉄道、船舶、航空などの交通手段における、交通機関の故障、運転誤りなどから発生した事故の総称である。日本では、これらの交通事故に対し、総合的に安全対策が講じられている [27]。そのうち、本研究が対象とする道路上の交通事故は道路交通事故と呼ばれる。

道路交通事故はこれらの交通事故の中でも被害が大きく、その対策が特に重要視されている。図4.1は、日本における交通事故死者数の推移を示したものである [28]。各分野における交通安全活動の成果として、交通事故による死者数はすべて減少傾向にあることがわかる。また、多くの人を巻き込むリスクがある鉄道、海上、航空交通における事故は特に少ないことがわかる。一方で、道路交通における死者数は減少傾向にあるものの、他の分野と比べて、その数は多く、2024年も2,663人が亡くなっている。




図4.1 交通事故死者数の推移

このように交通事故の中で最も件数が多いことから、一般には道路交通事故を単に「交通事故」と呼ぶことが多い。本論文でも、特に断りのない限り、交通事故は道路交通事故を指すものとする。また、本研究では交通事故は交通事故統計の定義に従い、人身事故を対象とする。交通事故には人の死亡または負傷を伴う人身事故と、物が壊れるなどの損害に留まり、人の負傷を伴わない物損事故の2種類が存在するが、交通事故統計では人身事故のみが計上される。そのため、事故分析において、交通事故は人身事故を指すものとされている。同様に、交通事故統計の定義に従い、本稿において「死亡事故」は事故発生から24時間以内に当事者が亡くなった場合を指すものとする。

交通安全対策は1970年頃から、開始しており、現在にかけて継続的に実施されている。交通事故による死者数は急速なクルマ社会の発展に伴い増加した。図4.1にも示すように、1970年のピーク時には、16,765人ものが亡くなっている。この1970年に駆けての交通事故の増加は交通戦争と呼ばれている。当時の死者数の多さを受け、国を挙げての交通安全対策が進められることとなった。翌1971年からは、5年ごとの

交通安全に向けた目標とその達成へ向けた施策を定めた交通安全基本計画が作成された。これは現在に至るまで継続的に作成されており、2021年には内閣府によって第11次となる計画が策定されている [27]。現在は第12次の計画の策定や第11次計画の評価が進められている。

現在施行されている第11次交通安全基本計画では、2025年までに交通事故による死亡者数を2,000人以下に、また、重傷者数を22,000人以下にすることを目標に掲げている [27]。この目標は過去のデータの比率から算出されたものである。第11次では、これを達成し、他の各国の交通事故情勢の中で最も死亡者数の少ない国を目指している。また、近年の自動車や医療技術の発展を踏まえ、交通事故の被害が軽減されてきていることへ注目し、死亡者数だけでなく、重傷者数の削減も目標に掲げている。加えて、同年に国土交通省では、さらなる先の目標として、2030年までに死亡者数を1,200人、重傷者数を11,000人まで削減することを目標に掲げている [29]。

これらの安全目標を達成するための対策には、これまでさまざまなものが取り組まれてきている。交通安全基本計画が開始された頃は、道路整備や法令違反の取り締まりが進められた。これらの安全対策から、交通事故による死亡者数は一時的に減少している。しかし、図4.1にも示した、1980年には再び増加に転じ、第2のピークを迎えた。この時期は第二次交通戦争と呼ばれている。この原因について、警察庁の発行する警察白書では、運転免許および自動車の保有者が年々増加する一方で、交通警察官の増員や交通安全施設の整備などが追い付かなくなったことが挙げられている [30]。

第二次交通戦争の状況を受け、さらにシートベルトの着用義務化や飲酒運転の厳罰強化などの法改正、交通安全に関する教育の充実が取り組まれた。これらの対策により、交通事故による死亡者数は再び減少に転じ、2020年頃まで続いている。また、この死亡者数の減少には、エアバッグやアンチロック・ブレーキシステム（ABS：anti-lock brake system）などの車の安全技術の普及、進展の貢献もある。

近年では、死亡者数は横ばいになっており、2023年には8年ぶりに増加に転じている。これは2020年に流行した新型コロナウイルス感染症が一因とされている。新型コロナウイルス感染症の流行時は外出自粛やテレワークの普及から、交通量が減少していた。しかし、コロナ渦が収束し、行動制限が緩和され、社会活動が活発化したためと考えられている [31]。

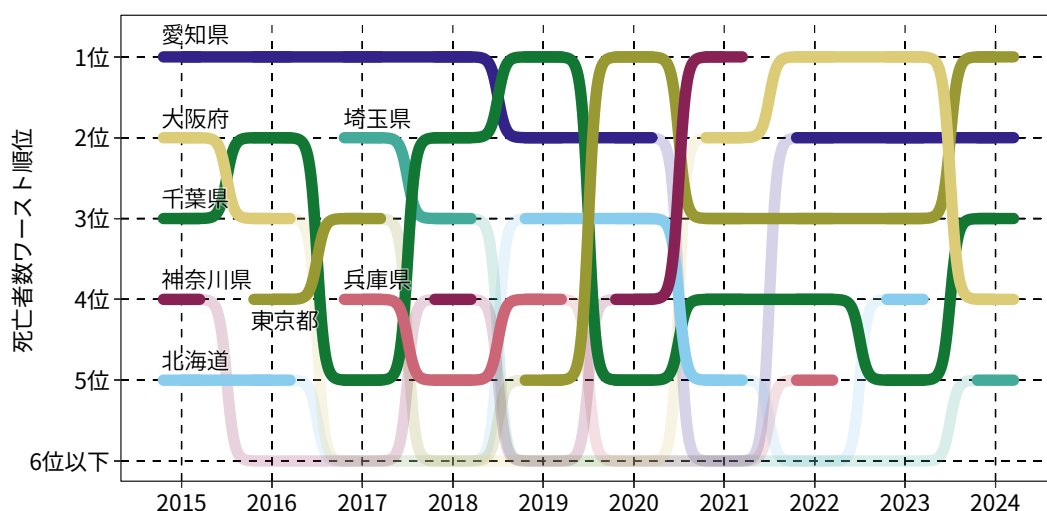
一方で、近年ではさらなる交通事故の被害低減に向けて、さまざまな安全対策が進められている。例えば、携帯電話などを使用しながらの運転「ながら運転」、他の車両への妨害運転を指す「あおり運転」などの新たな危険運転行為に対する罰則が強化された。また、自転車のヘルメット着用の努力義務化、電動キックボードに対する交通ルールの適用など、配達業務やシェアサイクルを中心に増加した小型モビリティを対象とした法改正もおこなわれている [32-34]。さらに、高齢運転者に向けた対策として、70歳以上を対象とする高齢者講習や免許の自主返納が促進されている。法改正の他、道路整備としては、生活道路における歩行空間の安全確保において「ゾーン30」や「ゾーン30プラス」といった区域規制が導入されている。ゾーン30は住宅地などの生活道路において、最高速度30km/hの区域規制を設ける制度であり、ゾーン30プラスでは、これに加え、ハンプや狭さくなどの物理的な交通規制を組み合わせるものである [35]。このように、法改正や道路整備などの多面的な施策により、交通事故の低減が図られている。

4.2.2 愛知県の交通事故情勢

本研究では、マルチエージェントシミュレーションに関する課題検討のために、日本の交通情勢に基づく国内の事故を対象とする。またその中でも、交通事故件数の多い地域として愛知県を中心に分析を進める。この理由としては、本研究が愛知県警察から交通事故データの提供を受けていることに加え、筆者の所属する愛知工業大学が愛知県に所在し、得られた分析結果について意見を収集しやすく、考察を深められるという点が挙げられる。なお、本研究では国外の研究も参考とするが、交通ルールや交通情勢は国内とは大きく

異なる。そのため、国外の交通事故は本研究の対象からは除くものとする。

愛知県の交通事故については、2003年から16年もの間、死亡者数ワースト1位という不名誉な記録が存在する。そのため、愛知県は交通事故死者数の多い地域として、しばしば取り上げられている。図4.2に過去10年間（2015–2024年）の交通事故死亡者数ワーストランキングを示す[36]。愛知県の順位に着目すると、2019年以降はワースト1位から脱したものの、2021年を除く5年は2位に位置し続けている。また、2021年は一時的にワースト5位圏外となったが、これはコロナ禍の行動規制による影響を受けたものと考えられる。さらに、大阪府や千葉県など、他の都道府県の順位は毎年変動している一方で、愛知県は安定して上位に位置している。このことから、愛知県における交通事故の特異性が伺える。



※ 警察庁、年報「交通事故死者数について」より、作成


図4.2 過去10年間の交通事故死亡者数ワーストランキング

このように愛知県の死亡者数の順位は他の都道府県と比較して高い位置で推移している。しかし、その事故件数は減少傾向にあり、交通情勢は年々改善されている。愛知県の交通事故件数および死傷者数の推移を図4.3に示す[37]。愛知県の交通事故は図4.3に示すとおり、全体をみると、事故件数、負傷者数はともに2004年をピークに減少傾向にある。また、死亡者数も1969年の912人をピークとして、増減を繰り返しながらも、減少傾向で推移している。

さらに、人口や自動車保有台数からみた場合、愛知県の交通事故死亡者数は全国平均を下回る。表4.1に、2024年の愛知県と全国の交通事故に関するデータを示す[38,39]。表に示されるように、負傷者数についてはまだ全国平均を上回るものの、死亡者数は人口10万人当たり、自動車1万台当たりのいずれも全国平均を下回っている。これらの結果は愛知県における交通安全対策の効果が表れているものといえる。

愛知県における交通安全対策は愛知県交通安全計画に基づき進められている[40]。この計画は、国の交通安全基本計画に準ずるもので、同様にして5年ごとに交通安全上の目標と施策が定められている。現在は第11次計画が施行されている。表4.2に、過去3回の愛知県交通安全計画における目標値と実績値を示す。

第11次計画では、年間の死亡者数を125人以下、重傷者数を600人以下にすることを目指している。第9次計画では、死亡者数、死傷者数ともに目標を達成できなかったが、第10次計画では目標をともに達成した。これらを踏まえ、第11次計画では、死亡者数のさらなる削減を目標に掲げている。また、死傷者数から重傷者数へ、削減の対象を変更している。これは重傷者の発生する事故防止への取り組みが、死亡者数の減少につながるとする国の計画を踏まえたものである。



※ 愛知県警察本部交通部「愛知県の交通事故（令和6年版）」より作成

図 4.3 愛知県の交通事故件数および死傷者数の推移

表 4.1 人口，自動車保有台数からみた愛知県の交通事故（2024 年）

		単位：人	
		愛知県	全国
死亡者数	合計	141	2,663
	人口 10 万人当たり ¹	1.90	2.14
	自動車 1 万台当たり ²	0.30	0.32
負傷者数	合計	28,822	344,395
	人口 10 万人当たり ¹	386.1	277.1
	自動車 1 万台当たり ²	53.4	41.4

¹ 警察庁，人口 10 万人当たり交通事故発生状況より参照

² 国土交通省，2024 年 12 月の自動車保有台数より算出

愛知県では，交通事故による被害は低減している一方で，その要因は複雑化，多様化している。これは先に述べた自動車保有台数をはじめ，高齢化や規範意識の低下など，さまざまな地域的特性が影響しているとされる [40]。第 10 次計画の期間では，死亡者数のうち，その 5 割以上を高齢者が占めている。また，死亡事故の 8 割は運転者の法令違反であることがわかっている。これらの結果から，愛知県は高齢者の安全確保や交通安全教育の推進を重視している。

また，愛知県の特有の道路交通情勢として，自動車保有台数や運転免許人口の多さが挙げられる。愛知県は自動車産業が盛んなことから，自動車を複数保有する世帯も多い。自動車保有台数は 500 万台を超え，国内で最も多い都道府県である。近年，若者の車離れといった社会傾向が取り上げられるように，自動車の売上や免許取得者は全国的には，少なくなっているが，愛知県の自動車保有台数は現在も増加傾向にある [39]。

表 4.2 愛知県交通安全計画の目標値と実績値（第9-11次計画）

愛知県交通安全計画		交通安全基本計画（全国）	
第9次計画（2011-2015年度）			
目標値	死亡者数 185 人以下, 死傷者数 55,000 人以下	目標値	死亡者数 3,000 人以下, 死傷者数 70 万人以下
実績値	死亡者数 213 人（未達成）, 死傷者数 55,283 人（未達成）	実績値	死亡者数 4,117 人（未達成）, 死傷者数 670,140 人（達成）
第10次計画（2016-2020年度）			
目標値	死亡者数 155 人以下, 死傷者数 39,000 人以下	目標値	死亡者数 2,500 人以下, 死傷者数 50 万人以下
実績値	死亡者数 154 人（達成）, 死傷者数 29,713 人（達成）	実績値	死亡者数 2,839 人（未達成）, 死傷者数 372,315 人（達成）
第11次計画（2021-2025年度）			
目標値	死亡者数 125 人以下, 重傷者数 600 人以下	目標値	死亡者数 2,000 人以下, 重傷者数 22,000 人以下

¹ 警察庁，人口 10 万人当たり交通事故発生状況より参照

² 国土交通省，2024 年 12 月の自動車保有台数より算出

また，これらの保有台数のうち，約 8 割は自家用車であり，通勤，通学などの日常生活において自動車が必要な交通手段となっている。さらに，運転免許人口は東京都，神奈川県に続いて，全国で 3 番目に多く，2024 年末では約 515 万人が免許を保有している [41]。また，高齢者はこの免許人口の 2 割を超え，増加傾向にある。このように愛知県はその地域的特性からも交通事故の被害低減が課題とされている。このような状況に対し，愛知県では免許を返納しやすい環境づくりなど，個別課題に対する施策が進められている。ただし，公開情報からそれらの施策がどの程度，安全化へ貢献しているかは明確でない。

4.2.3 交通事故の要因を調査する研究

日本では，交通事故の被害が減少傾向にある一方で，その死傷者数は少ないとはいえない。また，究極的には交通事故のない社会を目指し，過去の交通事故の傾向からその要因を捉え，効果的な安全対策を講じることが求められている。この目標に向けて，官民の研究機関や自動車メーカーなどが連携し，交通安全に関する分析や対策の検討を進めている。

交通安全基本計画によると，国は特に **ITARDA**^{イタルダ} の活動強化を進めている。ITARDA（交通事故統合分析センター）は道路交通法で交通事故調査分析センターとして指定されている国内唯一の研究期間であり，交通事故の発生状況を集計し，資料として提供している。この資料は交通事故統計といい，国内の事故分析の情報源となっている。

大学，民間研究機関等では，交通事故統計を用いた分析システムの開発や，警察と連携した事故原因の分析が進められている。このように交通安全を目指す研究群は交通安全研究と呼ばれている。以降では，従来研究をそれぞれのアプローチに基づいて大別し，紹介する。

■**事故要因を分析するためのシステム開発** 事故要因を分析するためのシステムとして、データの信頼性を向上させたものや、多様な利用者を考慮したものが報告されている [42, 43]。交通事故のデータは当事者からの聞き取りをもとに、人手で記録されている。そのため、実態と合わないデータや、入力誤りが含まれることがある。ここで、当事者 (party) とは、交通事故において運転者や同乗者など、関係した人物を指す語である。この当事者には、各人の過失の大きさから、第1当事者、第2当事者、…と順位付けられている。また、この順位を当事者順位という。また、事故要因の分析では、道路管理者や交通管理者など、データ分析の専門家以外も参加する場合がある。このような場合には、専門家でなくても使いやすいシステムが求められる。これらの課題を解決するため、事故要因を分析するためのシステムが開発されている。

山田ら (2016) は毎年 50 万件を超える事故の位置情報の管理および分析が困難である問題に対し、位置情報の品質管理から分析までを対象とする総合的な事故分析システムを開発した [42]。このシステムには、正確でない交通事故の位置情報を修正する機能、交通事故データと各種地理空間データを統合したデータベースシステムが含まれる。山田らは同システムを使用して、統計モデルに基づく事故要因の分析、事故多発箇所のクラスタリングを実施した。事故要因の分析では、自動車により通勤、通学する人の多い地域に事故が発生しやすいという結果を得ている。事故多発箇所のクラスタリングでは、統計的仮説検定を用いて獲得したクラスタについて、それらの地域へ対策をおこなったとしても、必ずしも死亡事故や重傷事故の低減へは繋がらないことを示した。また、これらの事故多発箇所のデータは車メーカー、カーナビメーカーへ提供され、ウェブおよびカーナビ上の交通安全マップとして利用されている。

山田・鈴木 (2022) は道路管理者や交通管理者が協力して事故対策を検討できるように、専門分野の異なるユーザが利用しやすい事故対策のためのデータベースシステムを提案した [43]。交通事故はさまざまな要因から発生するが、実務上は分析者の専門分野に基づき、短期的な効果検証や限られた要素に対する分析に留まっている場合が多い。山田・鈴木はこの問題を解決するために、専門領域の異なるユーザも扱いやすく、出力について地域の住民など非専門家も理解できるデータベースシステムの実現を目指した。このシステムは事故データをその属性に応じてクロス集計する機能や、その結果を GIS を用いて地図上に可視化する機能を備えている。実現したシステムは役所職員に対するアンケート評価から、その機能の必要性が高く評価された。一方で、提案システムは汎用性の高い GIS ソフトウェアを土台としたが、一定数のユーザは慣れ親しんだ Excel 以外のツールに対する抵抗感を抱えていることも明らかとなった。これに対し、山田・鈴木はユーザの意見を反映した改善が必要であるとしている。

■**交通事故と交通量の時間的推移に着目した分析** 交通事故を引き起こす環境要因にはさまざまなものが存在する。それらの一部として、交通量や明るさなどは時間的に変化している。そこで、これらの要因と交通事故との関係を時間的推移に着目し、分析する研究がいくらか報告されている [44-46]。特に、交通量の増加は単純に車両同士の衝突の機会を増加させるだけでなく、交通渋滞による心理的な負荷の増加や、交通容量の超過による安全な車間距離の確保が困難になることなど、その影響が大きいことが知られている。

加藤ら (2019) は交通事故件数の多い愛知県の交通事故データに基本的な統計分析をおこない、得られる知見と今後の研究課題について検討した [44]。分析では、新たな知見の獲得が期待できる項目の組み合わせを見いだすために、利用可能なすべての項目間の相関分析を実施した。その結果、事故の重大度 (死亡、重傷、軽傷) と発生した道路形状 (単路、交差点など) の間に比較的強い相関が確認され、この関係が新たな知見を導く可能性のあるものとして注目された。さらに、これらの項目間のクロス集計から、交通事故件数の多い単路や中規模の交差点では、重傷事故が 8 時、18 時付近に多く発生していることが確認された。この傾向に対し、加藤らは通勤時間帯における運転者の心理的な影響が要因として考えられる一方で、交通量の増加による影響も無視できないものとしている。これらの分析を通じ、交通事故のように大規模なデータに対しては、基礎的な統計処理によって確認できる内容には限界があり、データの整備やシミュレーション、地

図を用いた可視化など、応用的な分析が必要であると結論付けている。

さらに、加藤ら（2020）は交通安全の確保に貢献できる知見を獲得するために、事故件数と交通量の関係についても分析している [45]。事故件数と交通量の周期性に着目し、愛知県の4市における推移を季節ごとに比較した。その結果、秋冬の夕方に交通量の影響と無関係に事故件数が増加するという傾向を確認した。この特徴について、加藤らは日没時刻が早まり、薄暗い時間帯が通勤時間帯と重なることで、事故件数が増加したものとして考察している。また、各市の事故件数と交通量との関係を回帰分析している。その結果、一定の交通量を超えると、事故件数の増加量が指数関数的になることを確認した。この結果については、各市の交通上の許容量が潜在的に存在し、これを超えたときに事故件数が急増するものとして考察している。

加藤らは自動車の交通量に着目しているが、同様に歩行者や自転車など、他の交通手段の交通量も事故件数と関係している。これについて、横関・萩田（2020）は交通事故データから、自転車の左側通行の遵守状況の変化を分析している [46]。自転車は自動車と同様に、原則左側通行である。横関・萩田はこの遵守状況の変化を分析するために、交通事故データを応用し、2007年と2017年の事故状況を比較している。その結果、当事者が左側通行を遵守している事故が2007年よりも2017年の方が多いことを確認した。このことから、2007年から10年の間に、自転車の左側通行の遵守率が向上したことを推測している。また、2007年と比較して、2017年は駐車場などから車道に進入する自動車との事故が減少しているという結果を得ている。このような状況の事故は左側通行を遵守していない、右側通行の自転車が巻き込まれる場合が多いため、この結果もまた左側通行の遵守率の向上を示唆するものであるとしている。

■統計モデリングによる要因分析 加藤らや横関・萩田はクロス集計をもとに交通事故について定性的に分析した。これに対し、統計モデリングを用いて、交通事故を定量的に解明しようとする研究も報告されている [47, 48]。代表的なものでは、交通事故リスクとして、発生のしやすさや重大度への繋がりを推定するために、交通事故を表現する属性を用いたモデルを構築するものがある。このようなモデルを構築する研究では、観測された交通事故のデータの背後に何らかの統計モデルを仮定し、そのモデルへデータを当てはめ、パラメータを推定する。そして、推定されたパラメータから交通事故の要因について解釈したり、モデルから事故リスクを予測したりする。交通事故データの項目には、テキスト形式で記録されているものが多く、自由形式のものや、カテゴリが多岐にわたるものなども存在する。そのため、データをモデルへ当てはめるために、交通事故の状況を適切な定量化も必要とされ、そのための手法も含め、研究が進められている。

渡部・中村（2015）は負の二項分布に基づき交通量や沿道状況から、事故類型ごとの事故件数を予測するモデルを構築した。また、このときに推定されたパラメータから、要因の特定をおこなった [47]。負の二項分布はポアソン分布と同様にカウントデータの解析に用いられるが、データの分散が平均より大きい場合に対応できるモデルである。実際の事故データは地点ごとの条件のばらつきから、事故件数の差が大きくなることが多い。そのため、事故件数の予測モデルには、しばしばこの負の二項分布が採用される。渡部・中村は推定されたモデルのパラメータから、道路の混雑解消に伴う旅行速度の向上や、交差点間隔の適切な確保が安全性の向上につながることを明らかにした。また、非幹線道路は利用可能な情報が限定的であり、マクロ分析は難しいため、それぞれの地域を詳細に調べる必要があることを指摘している。

兵頭ら（2017）は交通事故の中でも、事故件数の最も多い追突事故に着目し、ポアソン回帰分析から事故リスクの地域差について明らかにした [48]。この研究では、各地点の事故リスクを事故件数、交通量、道路延長から新たに定義している。そして、ポアソン回帰モデルにより、この事故リスクを推定した。東京都、愛媛県の2地域に対する分析結果の比較から、これらの地域間には事故リスクの傾向が有意に異なることを示した。愛媛県では、交通量の多い時間帯に事故リスクが高くなる傾向がある一方で、東京都では逆に事故リスクが低下する傾向があるという結果が得られた。また、地理空間上の信号交差点の密度について、愛媛県ではこの密度が高い地域ほど、事故リスクが高まる傾向があるが、東京都ではこの密度の影響は見られな

いことも確認された。これらの結果を通じて、事故リスクの評価には、異なる沿道状況や道路幾何構造などを含む地域差を考慮する必要があるとしている。

■交通事故と道路幾何構造の関係分析 兵頭らの研究結果からも示されるように、交通事故は道路幾何構造と関係がある。車両の走行は基本的に道路形状に沿っておこなわれるため、その運動は道路形状の影響を受ける。一方で、道路形状と交通の安全性との関係ははまだ十分に解明されていない。そのため、交通事故が発生した道路の幾何構造を分析し、これらの関係が研究されている [49]。

塩見ら (2016) は交通事故と交差点の道路幾何構造について分析し、交差点の大きさが事故の発生に与える影響を明らかとした [49]。塩見らは交差点の幾何構造と事故件数との関係をポアソン回帰モデルにより分析している。また、この入力データには、Google Earth の航空写真や、Street View の画像から、数量化した交差点の幾何構造と、事故類型および交差点ごとの事故件数と交通量から定義した事故リスクを用いている。分析の結果、交差点の規模が大きいほど、事故リスクが高まることが示された。また、この結果から交差点のコンパクト化が有効であるという仮説を立て、その仮説に基づくシナリオ分析から、事故件数と死者数を削減できる可能性を示している。

向ら (2020) は道路地図画像を用いて、その道路構造から生じやすい事故タイプの推定を試みている [50]。この研究では、愛知県の事故現場周辺の道路画像を入力データとして、それらから追突事故、出会い頭事故、右左折事故の3種類の事故タイプを出力するように畳み込みニューラルネットワークを学習させている。その結果、学習済みモデルは未知の画像の分類に対して、72.5%の正答率を達成した。また、分類した道路画像のうち、正しく分類されたものと、誤って分類されたもののそれぞれの特徴から、分類に道路形状が影響していることを確認した。さらに精度を高めるには、事故タイプと関連する特徴を入力する必要があり、信号の有無や道路の勾配などをその例として挙げた。また、この実験では事故タイプを対象としたが、同様に画像を用いて事故の重大度を推定することで、従来の推定手法の精度を上回る可能性を示している。

向らのように機械学習を用いた分析をおこなった例として、榊原らの研究がある。榊原ら (2024) は深層ニューラルネットワークを用いて、事故内容を予測するモデルを構築した [51]。また、その入力データの作成方法として、形式概念分析を用いた特徴量エンジニアリングを提案している。深層ニューラルネットワークでは、内部構造の複雑さから、予測根拠の説明が困難であるという課題がある。小谷らは形式概念分析から得た因果関係を表現するデータを入力とすることで、この解決を図った。形式概念分析は対象とその性質を表を用いて整理し、結果として含意関係や関連性を獲得する手法である。実験から、コサイン類似度を用いた手法に対し、提案手法は再現率の精度が向上することを示した。また、予測の傾向を地図上へ可視化する方法も提案しており、事故対策への有用性を示している。

4.2.4 事故要因の分析における課題

これまで交通事故の対策に向けて、事故要因はさまざまなアプローチから、研究されてきた。それぞれの従来研究の着眼点と対象を整理したものを表 4.3 に示す。また、それぞれの手法の特徴を整理したものを表 4.4 に示す。これらから、いくつかの知見が得られている一方で、解決すべき課題も多く存在する。

従来研究の分析には、対象地域を限定したものから、全国まで広げているものまで存在する。本稿では、獲得したい知見が広域に向けたものである分析を「マクロ的分析 (macroscopic analysis)」、地域や特定の性質を持つ事故に向けたものである分析を「ミクロ的分析 (microscopic analysis)」とする。なお、本稿での分類は分かりやすさのために、便宜上、表 4.3 としたものであり、絶対的なものではない。分析の焦点がマクロとミクロの中間的なものを指す「メゾ的分析」も存在し、ここで「ミクロ的」としたものが「マクロ的」として扱われている文献も存在する。

表 4.3 事故要因を分析する研究の対象

研究	着眼点	焦点	地域	期間
山田ら (2016) [42]	大規模なデータの品質管理と分析	マクロ的	全国	2006–2016
山田・鈴木(2022)[43]	事故分析システムの利用性	マクロ的	名古屋市(愛知県)	2009–2019
加藤ら (2019) [44]	事故の特徴間の相関	マクロ的	愛知県	2009–2018
加藤ら (2020) [44]	地域ごとの事故件数と交通量の関係	マクロ的	名古屋市, 豊田市, 長久手市, 瀬戸市(愛知県)	2009–2018
横関・萩田(2020)[46]	自転車の左側通行遵守状況	ミクロ的	千葉県	2007, 2017
渡部・中村(2015)[47]	事故類型ごとの事故と周辺環境との関係	ミクロ的	愛知県	2008–2012
兵頭ら (2017) [48]	追突事故リスクの地域差	ミクロ的	東京都, 愛媛県	2012–2014
塩見ら (2016) [49]	交差点の道路幾何構造と事故の関係	ミクロ的	高松市, 中讃地域(香川県), 岡崎市, 西尾市(愛知県), 大津市, 湖南地域(滋賀県)	2008–2014
向ら (2020) [50]	道路地図画像から生じやすい事故類型	ミクロ的	愛知県	2018
榊原ら (2024) [51]	深層学習のための事故の表現方法	マクロ的	富山県	2017–2021

マクロ的分析では、地域を跨いだ要因や傾向を調べるため、地域に依らない、一般化された知見の獲得が期待できる。しかし、この方法では地域ごとの差や、個々の交通事故の影響力は相対的に小さくなるため、これら捉えることは難しくなる。この課題は渡部・中村(2015)の研究の結論でも指摘されている[47]。

一方、道路幾何構造に着目した分析のようなミクロ的分析は、地域ごとの傾向を把握できる。また地域性を考慮することで、その地域の対策に直接役立つ知見を獲得しやすいという利点もある。しかし、兵頭ら(2017)が指摘するように、事故傾向には地域差が存在するため、同一の分析方法が複数の地域で有効とは限らない。そのため、地域ごとに適した分析方法を個別に検討する必要がある[48]。加えて、対象地域が限定されていると、その地域特有の情報が必要である場合や、利用可能なデータが限定されている場合も想定される。このように、分析を実施するコストが高くなるという課題もある。

このようにマクロ的分析とミクロ的分析では、それぞれに利点と欠点が存在し、得られる知見の性質も異なる。したがって、これらの有効な側面を適切に組み合わせ、より実践的な交通安全対策へと結びつけていくことが重要である。マクロ的分析から得られる一般化された傾向を踏まえつつ、ミクロ的分析から得た地域ごとの特徴を補足することで、高い精度で実効性を持つ結論が得られることが期待できる。

交通事故の分析結果は地図上へ可視化することで、その理解が促進される。一般に空間分析では、可視化に基づく分析がなされており、これは交通事故の分析においても有用であると考えられる。山田ら(2016)の研究では、地理的な傾向の把握に、GISを用いた可視化が有用であることが示されている[42]。また、榊原ら(2024)は深層ニューラルネットワークの予測傾向を可視化する際に、根拠に基づく事故のフィルタリン

表 4.4 事故要因を分析する研究の手法

研究	データモデルの設定	統計モデリング	機械学習	地理的な可視化	時間的影響の考慮	道路幾何構造の考慮
山田ら (2016) [42]	○	○		○		
山田・鈴木 (2022) [43]	○			○		
加藤ら (2019) [44]					○	
加藤ら (2020) [44]					○	
横関・萩田 (2020) [46]					○	
渡部・中村 (2015) [47]		○				
兵頭ら (2017) [48]		○				○
塩見ら (2016) [49]		○				○
向ら (2020) [50]			○			○
榊原ら (2024) [51]	○		○	○		

を提案している [51]。このようなインタラクティブな可視化は、事故が持つ複雑な関係を人が理解するのに役立つと考えられる。また、ここから得られる新たな洞察が次の分析の起点となることも期待できる。しかし、これらの可視化において、どのような情報をどのように表現するのが有用であるかは、明らかでない。

交通事故は多様な要因が複雑に絡み合って発生する現象であり、加藤ら (2019) が示すように、基本的な統計分析でこの関係を捉えるには限界がある。向ら (2020) や榊原ら (2024) の研究のように、人工知能を活用した分析はこの課題を克服する可能性を持つが、現時点では、まだ十分に研究が進んでいるとはいえない。

交通事故の要因をより精緻に明らかにするためには、交通事故データだけでなく、交通量データや道路形状データなど、さまざまなデータを組み合わせて分析する必要がある。これは山田ら (2016) の研究や加藤ら (2019) の研究からも示唆されている。また、分析対象とすべき要素には、当事者の心理状態や能力など、直接観測できないものも多く存在する。したがって、このような潜在的要因を推定するためには、交通主体 (自動車、自転車、歩行者など) のモデル化、継続的なデータの収集および管理が重要であると考えられる。

従来研究から、確認できる事故要因の分析における課題を整理すると、次のとおりである。

- マクロ的分析、ミクロ的分析の両面からのアプローチの統合方法
- 地域ごとの要因の発見方法
- 事故要因を説明するための空間的な分析と可視化
- 複雑な交通事故の性質を捉えるための人工知能アプローチに基づく応用的な分析
- 交通主体 (自動車、自転車、歩行者など) のモデル化
- 事故要因を分析するための各種データの継続的な収集と管理

本研究の要因分析では、これらの課題に対して横断的な解決を図る。交通事故をマルチエージェントシミュレーションで再現するには、交通主体および交通環境のモデル化に向けた知見獲得が鍵となる。本研究では、広域的な交通環境に関するものから交通主体の振る舞いまで、幅広い知見を収集することを目指す。そのために、マクロからミクロへと、段階的に焦点を移しながら分析をおこなう。また、これらの分析を可能とするための分析システムの構築もおこなう。これらの取り組みを通じ、マルチエージェントシステムのモデル化プロセスにおける課題とその解決策について示す。

以降、次の節に渡り、交通事故の要因分析について説明する。第4.3節では、この分析システムの中核となるデータベースシステムについて述べる。ここでは、交通事故のデータを扱うのに適したデータモデルについて論じる。次に、第4.4節では、マクロ的な分析として交通事故リスクの高い箇所を検出する手法について述べる。さらに、第4.5節では、事故リスクから事故要因へ、焦点をマイクロなものへ移しながら、分析を進める。この分析は交通事故をモデル化するための核心部分であり「なぜ交通事故が発生するのか」というメカニズムを探求するものである。

4.3 交通事故データベースの設計と構築

4.3.1 交通事故データベースの要件

事故要因の分析には、さまざまなデータが必要である。交通事故はさまざまな要素が複雑に絡み合って発生している。そのため、この対策の検討においてはさまざまなデータを用いた、多角的な分析が必要である。従来研究では、表4.5に示すようなデータが利用されている。

表4.5 事故要因を分析する研究で使用されたデータ

研究	データ名称	提供元	分析に使用された項目
渡部・中村 (2015) [47]	交通事故データ	愛知県警察	重大度, 死亡者数など
	道路交通センサス	国土交通省	区間交通量, 旅行速度など
	国土数値情報	国土交通省	道路密度, 道路延長, 使用区分, 標高, 勾配など
塩見ら (2016) [49]	DRM データ	日本デジタル道路地図協会	道路形状, 道路幅員, 制限速度など
	交通事故データ	(記載なし)	緯度, 経度, 事故類型など
	道路交通センサス 道路幾何構造データ	国土交通省 (Google Earth から作成)	区間交通量, 旅行速度など 右折車線, 停止線間距離など
兵頭ら (2017) [48]	交通事故データ	愛媛県警察/ ITARDA	時刻, 緯度, 経度, 事故原因, 事故類型など
	道路交通センサス	国土交通省	区間延長, 交通量, 沿道状況, 車線数など
向ら (2020) [50]	交通事故データ 道路地図画像	愛知県警察 (Mapbox から作成)	緯度, 経度, 事故類型 —
加藤ら (2020) [44]	交通事故データ 断面交通量情報	愛知県警察 JARTIC	曜日, 季節, 市区町村 計測時刻, 断面交通量

各研究では、交通事故データとそれぞれの分析の目的に応じたデータが併用されている。交通事故データは対象地域の警察から提供されるものや、ITARDAが管理するものが使用されている。また、併せて使用されているデータリソースには、公的機関や民間法人から提供されている既存のデータや、分析のために地図サービスを利用して独自に作成されたものなどが存在する。

渡部・中村の研究(2015)では、事故件数と交通環境との関係を表現するために、交通量や道路形状の情

報が利用されている。交通量の情報源には、国土交通省の提供する道路交通センサス（全国道路・街路交通情勢調査）を利用している。道路交通センサスは全国の主要道路に設置された交通量センサから収集されたデータである。このデータには、交通量や旅行速度などの情報が含まれている [52]。旅行速度とは、ある区間を通過するのに要する平均的な速度のことであり、信号待ちや渋滞による停止を含む移動速度のことである。また、道路形状の情報源には、国土数値情報や DRM データが利用されている。国土数値情報は国土交通省が提供する、道路、行政区域、地形など、国土に関するさまざまなデータのことであり、道路データには、道路の長さや密度などの情報が含まれている [53]。一方、DRM データは日本デジタル道路地図協会が管理、提供する道路地図データである。このデータには、道路をネットワークとして扱うための情報や、道路幅員、制限速度などの各道路の詳細情報が含まれている [54]。

塩見らや、向らの研究では、分析のためのデータが独自に作成されている。塩見らの研究（2016）では、交差点の幾何構造と事故リスクとの関係を分析するために、Google Earth の航空写真や、Street View の画像から、交差点の幾何構造を数値化したデータが利用されている。また、向らの研究（2020）では、畳み込みニューラルネットワークに、道路構造と事故類型との関係を学習させるために、Mapbox を利用して、事故現場周辺の道路地図画像が作成されている。なお、Mapbox は地図開発のためのプラットフォームであり、API を通じてさまざまな地図を作成できる。

加藤らの研究（2020）では、他の研究と同様に事故リスクとの関係を調べるために、交通量を用いている。ただし、使用しているのは区間交通量ではなく、断面交通量である。区間交通量は道路の一定区間に平均して何台の車両がいるかを示す指標であり、道路交通センサスに含まれる。この値は半日単位で集計され、道路の混雑状況を区間全体で把握できる。一方、断面交通量は道路のある地点を通過した車両の数を表す。JARTIC（日本道路交通情報センター）により5分ごとに集計されたデータが公開されており、時間的な変化を詳細に捉えられるという利点がある。ただし、断面交通量は1地点での通過台数を測定するため、渋滞などで交通の流れが遅い場合にも値が小さくなる可能性がある。これに対し、区間交通量は2地点間の平均的な交通量を示すため、この影響を受けにくい。

このように要因分析をおこなう交通安全研究では、さまざまなデータが必要とされている。それぞれの目的に応じて、使用されるデータは異なるが、いずれも交通事故データを中心としてデータが組み合わせられ、分析に利用されている。データを組み合わせ、利用する場面では、交通事故データと関連データを統合的に管理するデータベースの存在が不可欠である。しかし、各研究ではそれぞれの分析目的の違いから、独自にデータの収集や整形、データベースの構築をおこなっている。そのため、本研究を含め、新たに事故要因を分析する際には、一からデータベースを構築するほかない。

そこで、本研究では交通安全研究のための、汎用的なデータベースを設計する [55]。これは従来研究の分析手法や使用されたデータを踏まえ、さまざまな分析に対応可能なものとする。以降、このデータベースを「交通事故データベース」と呼ぶ。このようなデータベースは従来研究が持つアイデアや結果といった資源を有効に活用でき、それらを比較、統合するなどの将来の発展的な研究の土台となり得ると考えられる。

従来研究の内容から、交通事故データベースはユーザの要求として、少なくとも次の点を満たす必要があると考えられる。本研究では、これらを要件として満たすデータベースの設計と構築を目指す。

- 要求 1. 事故状況を表現するデータの操作に適したデータモデルが利用できること
- 要求 2. 多様な属性の追加、データの連携が可能であること
- 要求 3. 標準的なコンピュータ上で効率的にデータの操作が可能であること

要求 1. はユーザが交通事故データを分析する際に、その分析目的に適したデータモデルが利用可能であることを意味する。提案するデータベースは、汎用のデータベースでなく、交通事故の分析に特化したもので

ある。したがって、このデータベースのユーザは事故状況を表現するためのデータの登録や検索といった操作をおこなう。そのため、事故状況を表現するデータモデルはこれらの操作に適したものである必要がある。

次に、要求2.は将来の交通安全研究での利用を見据えた、拡張性に関するものである。交通事故の発生に関係する要素は多岐にわたる。このなかには未知の、あるいは潜在的な属性も含まれている。したがって、従来研究で対象とされてきた属性に対応できるだけでなく、将来の研究で新たに必要となる属性にも柔軟に対応可能であることが求められる。

最後に、要求3.はこのデータベースシステムが一般的なコンピュータを利用して、実用的に運用できることを求めるものである。データの登録や検索といった基本的操作に要する時間的および空間的な計算資源は、現実的なものである必要がある。当然ながら必要となる計算資源は扱うデータ量に応じて異なり、任意の規模のデータに対して、常にこれを保証することは困難である。この要求は従来研究を踏まえて想定される規模のデータを対象とした場合に、十分に実用可能な性質を有するという意味を意味する。

4.3.2 交通事故のデータモデル

従来研究では、交通事故データの分析手法として、空間分析の有用性が示されている [42, 44]。空間分析 (spatial analysis) とは、位置情報に基づいて現象を解析する手法の総称である。交通事故を対象とする場合には、事故の発生地点に基づいて、それらの密度や分布傾向から、事故リスクの高い領域を検出する分析などが該当する。また、発生した道路や周囲の建物などの位置関係を用いた分析なども空間分析に含まれる。これらの分析から得られた結果は地図上に可視化できる。そのため、直観的に理解しやすく、具体的な施策へ結びつけやすいという利点がある。

本研究では、交通事故データベースをさまざまな研究で利用可能なものとするため、各事故の状況を表現するデータモデルに地理空間データを採用する。地理空間データ (geospatial data) は地図に表現される地球上の物や出来事を表現するためのデータモデルであり、空間分析において一般的に利用される。この例として、ある昼頃の晴天時に発生した1件の軽傷事故の情報を地理空間データで表現したものを図4.4に示す。このように地理空間データで表現される個々の対象物は^{ちぶつ}地物 (feature, フィーチャ) と呼ばれる。交通事故を対象とした分析では、交通事故に加え、発生した道路や周囲の構造物などを地物として表現できる。

発生時刻	天候	事故内容	...	ジオメトリ
12:20	晴れ	軽傷事故	...	(35.15..., 137.11...)



図4.4 地理空間データとして表現した交通事故の例

地理空間データは空間データと属性データという2種類のデータから構成される。交通事故データベースでは、これらのデータから交通事故がどこで、どのように発生したかを表現する。

空間データ (spatial data) は地物の位置や形状を表現するものであり、経緯度^{*1}や地図上の座標などを用いて記述される。図 4.4 では、項目「ジオメトリ」がこれに該当し、交通事故発生地点の経緯度を表現している。空間分析では、この項目を比較、演算することで、地物の分布や地物間の関連性を調べる。なお、ジオメトリ (geometry) とは、形状を表すデータを指す言葉で、空間データの項目名としてよく用いられる。

一方、属性データ (attribute data) は地物に不随する非空間的な情報を表現するものであり、数値や文字列など一般的なデータ型により記述される。図 4.4 では、「発生時刻」「天候」「事故内容」といった、事故の状況や詳細を説明する情報がこれに該当する。これらの情報は一般的な統計分析に利用できる。

一方、交通事故の重要な性質として、空間的な傾向だけでなく、時間的な傾向も持つということが挙げられる。例えば、朝夕の通勤時間帯には、他の時間帯と比べ、発生件数が増加しやすいことが明らかとされている [45]。そのため、しばしば交通事故は時空間データとして表現され、時系列分析の対象にもなる。これに対し、地理空間データは事故の発生した日付や時刻を表現でき、時空間的な検索にも対応できる。

本研究では、このようにして交通事故やその発生に関連する要素を地理空間データとして定義し、これらを地理空間データベースの上で関連付け、交通事故データベースを構築する。地理空間データベース (geospatial database) とは、地物を地理空間データとして扱うためのデータモデルや、操作を提供するデータベースをいう。具体的に空間データに対する操作には、地物間の距離計算や、ある領域内に存在する地物の検索など、さまざまな幾何的操作が含まれる。

地理空間データベースでは、各テーブルが地物の種類に対応する。また、それぞれのレコードは個々の地物を表現する。これに従い、交通事故データベースでは、交通事故、道路、建物など、事故の発生に関連する地物の種類をテーブルに対応させ、そこへ各地物の情報をレコードとして登録する。

また、交通事故とその要因との関係を扱うために、レコードの情報を突き合わせ、複数のテーブルを関連付ける。例えば、事故と地域の特徴との関係を調べるために、ある市で発生した交通事故を、その市の情報と関連付けるといったことである。このテーブルの関連付けは基本的にリレーショナルデータベースと同じである。リレーショナルデータベース (RDB: relational database) は表形式のデータを扱うデータベースであり、テーブル間の関係を定義し、それら进行操作するためのデータモデルである。ただし、地理空間データベースはリレーショナルデータベースで扱われる非空間的な関係に加えて、空間的な関係からもテーブルを関連付けられるように拡張されている。

本研究では、図 4.5 に示す関係モデルを定義した。この図は対象とするデータとして「交通事故」「道路」「交通量」などを定義し、それらの関係を示している。また、地域メッシュ統計へ対応するため、「地域メッシュ」も定義した。地域メッシュ統計とは、緯経度に基づき地域を隙間なく網目上に分割した区域を単位に編成された統計データをいう [56]。総務省統計局から提供されるデータには、行政区域を単位としたものに加え、この地域メッシュ統計に基づくものも存在する。

また、この図はわかりやすさのために、ER 図を簡略的に記述したものである。ER 図 (entity relationship diagram, 実体関連図) とは、データベース設計において、データモデルの構成要素とそれらの関係を表現するための図である。図中に示されたブロックは交通事故に関する要素を表している。また、ブロック同士の接続は要素間に関係が存在することを表している。ER 図において、これらはそれぞれエンティティ、リレーションと呼ばれる [57]。

図中のリレーションはテーブル間の属性データから結ばれた非空間的な関係のみを示し、空間的な関係は省略している。交通事故データベースには、ほぼすべてのテーブルに空間データを持たせ、それらのテーブルを空間的に関連付けられるようにしている。そのため、これらの関係の記述すると複雑になるため、空間的な関係は省略して、記述している。

*1 経度および緯度のこと

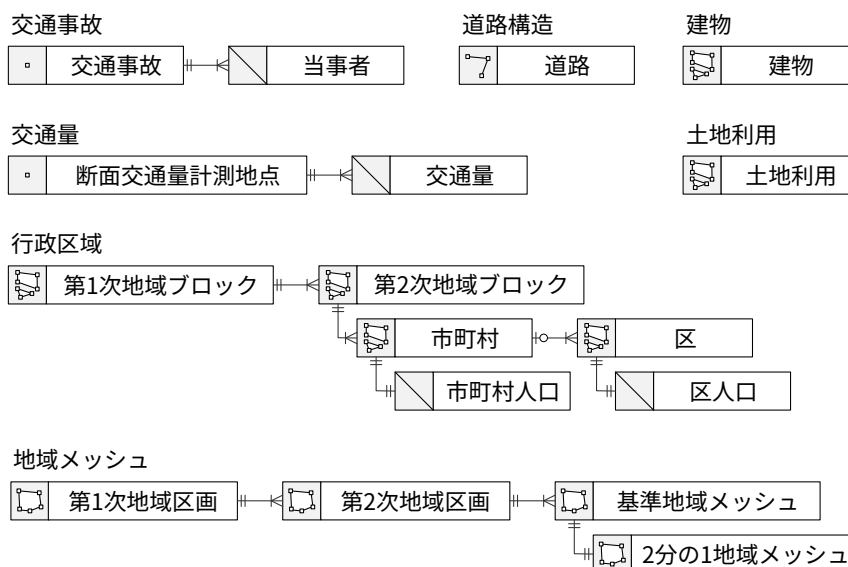



図 4.5 交通事故データベースの関係モデル

リレーションの端に付けられた丸や線の記号は、関係の種類を表し、図 4.6 に示す、3 種類が存在する。これらの記号はリレーションにおけるカーディナリティを表している。カーディナリティ (cardinality, 多重度) とは、あるデータに対して、別のデータがいくつ関連付けられるかを示す概念である。例えば、交通事故は単独事故かつ同乗者がいない場合を除き、複数の交通主体の衝突から発生するため、1 件の交通事故に対して、複数の当事者が関連付けられる。これは 1 対多の関係であり、図 4.6 に例示するように、交通事故側に「1 つ」を意味する記号が、当事者側に「1 つ以上」を意味する記号が付けられる。なお、これらの記法は ER 図で一般的に用いられるものであり、カラスの足に似ていることから、Crow's Foot Notation (Martin-Notation, IE 記法) と呼ばれる [57]。



例：交通事故と当事者は1対多の関係

図 4.6 カーディナリティの種類と表現の例

また、図 4.5 のブロックの左側に示している記号は、各エンティティの地理空間データ型を表している。これらのデータ型には、点 (point), 折線 (linestring), 多角形 (polygon) を基本とした、さまざまなものが存在する。これらのデータ型やその操作は **Simple Features** により標準化されている。Simple Features (SFA: Simple Feature Access, ISO 19125) とは、国際標準化機構 (ISO) と Open Geospatial Consortium (OGC) により策定された、地理空間データベースにおける地理空間データ型とその操作を定義した標準規格である [58]。多くの地理空間データベースシステムやライブラリは、この規格に準拠している。そのため、これを採用することで、汎用的なシステムを構築できる。

交通事故データベースでは、図 4.7 に示す 4 種類のデータ型を使用している。これらのデータ型は Simple

Features において、図 4.7 に示すように階層的に定義されている。すべてのデータ型は Geometry 型を継承しており、これを基底クラスとしている。Geometry 型のように抽象的なデータ型をテーブルに設定すれば、特定の形状に依存せず、さまざまなデータを扱える。しかし、このようにすると、画一的な操作ができない、テーブルの意味付けが曖昧になるなどの問題がある。そこで、本研究では、OpenStreetMap で使用される定義を参考に、それぞれの地物に適切なデータ型を設定した。OpenStreetMap (OSM, オープンストリートマップ) は、ユーザが自由に編集できる地理空間データのプロジェクトである [59]。空間分析を含む研究だけでなく、観光案内アプリ、位置情報ゲームなど、広く一般に使用されている。

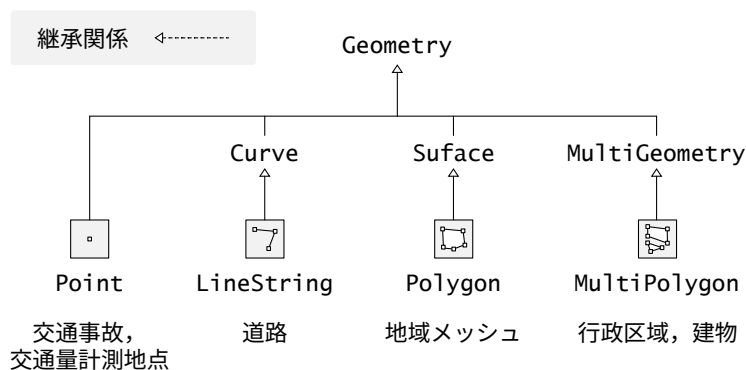


図 4.7 交通事故データベースで使用する地理空間データ型の種類

定義した関係モデルでは、すべてのデータを交通事故のデータと関連付けられるよう、すべての独立エンティティに空間データ型を設定している。独立エンティティとは、他のエンティティに依存しないエンティティである。交通事故データベースでは、「交通事故」や「建物」などのエンティティが該当する。反対に、「当事者」のように元となる交通事故がなければ、成り立たないエンティティは依存エンティティと呼ばれる。すべての独立エンティティが空間データ型を持つことで、交通事故地点との空間的な関係から対応付けられる。依存エンティティはそれぞれが依存する独立エンティティの空間データを介して、交通事故のデータと関連付けられるようになっている。

具体例として、各市の交通事故と人口密度との関係を調査するためのデータを取得する場合を考える。この場合には、交通事故の発生地点と各市の領域を空間的に結合し、対応するデータを取得すればよい。図 4.8 のように、各事故がある市（この図では、名古屋市）の領域に含まれているかどうかを調べ、含まれていればその市の情報を事故データに追加する。人口密度の情報は各市の人口のデータに含まれているため、交通事故と各市のデータが結合されることで、交通事故と人口密度の関係を調査できるようになる。

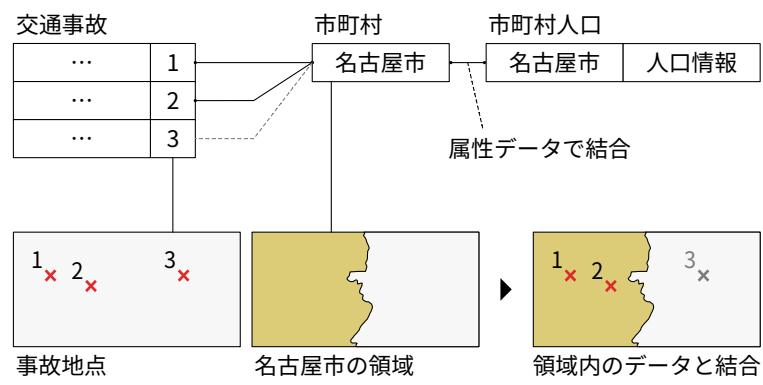


図 4.8 交通事故データと他のデータとの空間的な関連付けの例

4.3.3 サンプルデータベースの実装

本研究では、交通事故データベースを評価するため、定義したデータモデルに基づくデータベースを実装した。このデータベースを実装の一例として、以降「サンプルデータベース」と呼ぶ。サンプルデータベースには、表 4.6 に示すテーブルを実装した。各テーブルはデータの検索のために、主キーとして、それぞれを一意に識別可能な識別子あるいはコードをしている。また、定義した関係モデルに従い、外部キーを設定しており、相互に関連付けられている。

表 4.6 サンプルデータベースのテーブル

テーブル名	カラム名 (属性データ)
交通事故データ	
accidents	<u>accident_id</u> , occurrence_date, weather, collision_type, ...
parties	<u>accident_id</u> , <u>party_id</u> , <u>car_id</u> , passenger_id, ...
交通量データ	
traffic_volume_points	<u>point_id</u> , point_name
traffic_volumes	<u>time</u> , <u>point_id</u> , traffic_volume
用途地域データ	
land_use	<u>land_use_id</u> , land_use_category
行政区域データ	
first_regional_blocks	<u>first_regional_block_id</u> , first_regional_block_name
second_regional_blocks	<u>second_regional_block_id</u> , <u>first_regional_block_id</u> , ...
cities	<u>city_code</u> , <u>second_regional_block_id</u> , city_name, city_kana
wards	<u>ward_code</u> , <u>city_code</u> , ward_name, ward_kana
人口データ	
city_populations	<u>city_code</u> , population_total, population_density, ...
ward_populations	<u>ward_code</u> , population_total, population_density, ...
地域メッシュデータ	
first_grid_squares	<u>first_grid_square_code</u>
second_grid_squares	<u>second_grid_square_code</u> , <u>first_grid_square_code</u>
basic_grid_squares	<u>basic_grid_square_code</u> , <u>second_grid_square_code</u>
half_grid_squares	<u>half_grid_square_code</u> , <u>basic_grid_square_code</u>

下線は主キー、破線下線は外部キーを示す。

これらのテーブルに本研究で利用可能であったデータをそれぞれに登録した。データセットの一覧を表 4.7 に示す。交通事故データには、愛知県警察より提供いただいた非公開の交通事故データを登録した。これらのデータには、2007 年から 2021 年までの交通事故の情報が含まれている。交通量データには、JARTIC が公開している断面交通量データを使用した。これらには、2017 年から 2021 年までの記録が含まれている。なお、計測地点情報は JARTIC から有料で提供されているものを使用している。用途地域、行政区域、人口データには、国土数値情報や国勢調査として、政府が公開している統計データを利用した。地域メッシュ

データはこれを提供するデータ自体はなかったため、地域メッシュを計算するための `jpmesh` というパッケージから、愛知県の地域メッシュデータを作成し、登録した [60].

表 4.7 サンプルデータベースの登録元データセット

データ名称	登録先テーブル
交通事故データ	<code>accidents, parties</code>
断面交通量情報	<code>traffic_volume_points, traffic_volumes</code>
国土数値情報	<code>land_use, first_regional_blocks, second_regional_blocks, cities, wards</code>
国勢調査	<code>city_populations, ward_populations</code>
(<code>jpmesh</code> より作成)	<code>first_grid_squares, second_grid_squares, basic_grid_squares, half_grid_squares</code>

なお、道路と建物のデータについては、あえてテーブルを用意していない。これは分析したい内容によって、適する方法が異なるためである。このサンプルデータベースでは、OpenStreetMap から直接取得したものを利用することとしている。交通事故の分析では、地域差を考慮する必要があり、複数の局所的な地域を対象とする場合が多く、このような分析において、地域ごとに柔軟にデータを取得できるためである。また同時に、OpenStreetMap の最新の情報を参照できるという利点もある。

一方、愛知県全体の道路の取得を取得したい場合などには、必要なデータが膨大であり、OpenStreetMap サーバへの負荷や通信時間を考慮すると、事前に一括取得したデータをデータベースへ登録した方が望ましい。加えて、適宜取得したデータを利用する場合には、地図が更新されたことにより、結果が変わってしまうという再現性の問題もある。そのため、道路や建物といった地図情報は分析内容に応じて、その管理方法を定めるべきである。

また本研究では、サンプルデータベースが多くの研究者に利用、拡張されることを目的に、データベースの構築、およびこれを用いた分析の例（チュートリアル）を含むスクリプトを GitHub 上で公開した [61]. 実装したスクリプトの一覧を表 4.8 に示す。なお、これらのスクリプトには、データベースの構築、チュートリアル、およびそれらの処理内で用いる関数が含まれている。

サンプルデータベースのデータベースマネージャには、ドキュメントの豊富さと拡張性の高さから、ポストグレスキューエル PostgreSQL を採用した。また、地理空間データの管理に ポストジーアイエス PostGIS という拡張モジュールを採用した。PostgreSQL はオープンソースのリレーショナルデータベースマネージャであり、高い拡張性と豊富な機能を持つことで知られている。また、**PostGIS** は地理空間データの管理と操作を可能にする PostgreSQL の拡張モジュールであり、Simple Features に基づいて実装されている。さらに、PostGIS は提供する関数の数が、MySQL や SpatiaLite (SQLite の拡張) など、他の地理空間データ向け拡張と比較しても多く、高度な空間分析機能を備えている。

また、スクリプトの実装には、R というプログラミング言語を用いた。R は統計解析やデータ可視化に長けた言語であり、さまざまなパッケージを導入することでその機能を拡張できる特徴を持つ。また、空間分析や再現性の高い分析を実現するためのパッケージが盛んに開発されている。そのため、研究用途として、交通事故データベースの構築や地理空間への可視化を含む分析では、高い信頼性を持つものを実現できる。空間データの処理には、`sf` というパッケージを利用した。`sf` は PostGIS と同様に、Simple Features に基づいて開発されている。そのため、これらの間では、基本的に同じ操作を同じ名前の関数で実行でき、ユーザにとって、理解しやすいものとなっている。

表 4.8 スクリプトの一覧

ファイル名称	分析または関数の内容
分析スクリプト	
build-database.R	サンプルデータベースを構築する
visualize-accident-count-heatmap.R	交通事故発生件数のヒートマップを作成する
db-register-[target_data].R	target_data に対応するテーブルを作成し、データを登録する
関数定義スクリプト	
db_connect.R	PostGIS データベースへ接続する
db_execute.R	指定された SQL を指定されたデータベースへ向けて実行する
db_import-[target_data].R	target_data に対応するデータをデータベースへ取り込む
extract-[table].R	table に対応するデータファイルからデータを読み出し、整形する
unzip_to_temp.R	指定された ZIP 形式のデータを一時ディレクトリへ展開する
convert_deg.R	DMS 形式 (時分秒) の経緯度を DEG 形式 (10 進形式) に変換する

なお、本研究では、R の sf を用いてこれらの実装をおこなったが、Simple Features に対応していれば、他のツールやライブラリを用いることも可能である。代表的なものとしては、地理空間データベースの閲覧、分析のためのアプリケーションである QGIS^{キュージーアイエス} や、Python で地理空間データを扱うためのライブラリである GeoPandas^{ジオパンドラス} などが挙げられる。そのため、交通事故データベースはユーザが自身の理解しやすいツールや言語を用いて、操作できるようになっている。

これらのスクリプトでは、図 4.9 に示す流れで、データベースの構築と分析をおこなう。まず、交通事故データベースに各種テーブルの作成とデータ登録をおこなう。登録したデータと OpenStreetMap の情報に基づき、モデリングや可視化などの分析を実行する。さらに、この結果は必要に応じて、再びデータベースに登録し、より深い分析にこの結果を利用する。

この分析の流れは探索的データ分析 (EDA: exploratory data analysis) と呼ばれる手法をもとにしている。探索的データ分析とは、大規模なデータセットから意味のある特徴や構造を見出すデータ探索 (data exploration) を体系化したものである。この手法では、仮説検定のようにデータから分析結果を一度得るだけでなく、その結果から、新たに仮説を生み出し、得たい結論が得られるまで検証を繰り返す。また、仮説の生成では、データの可視化とその観察を重視するという特徴がある。

探索的データ分析は 50 年以上前から、John Tukey をはじめとする、さまざまな研究者により、検討されている手法である [62]。そのため、このモデルには、さまざまなバリエーションが存在する。本研究では、Posit 社 (旧 RStudio) のチーフ・サイエンティストとして知られる Hadley Wickham^{ハドリー・ウィックカム} らが提唱したものをもとにしている [63]。このモデルは近年のデータサイエンスでよく用いられており、R ではこのモデルをベースとしたパッケージが多く開発されている。

Wickham らが示したデータ探索の流れを図 4.10 に示す。データサイエンスでは、データからモデルを構

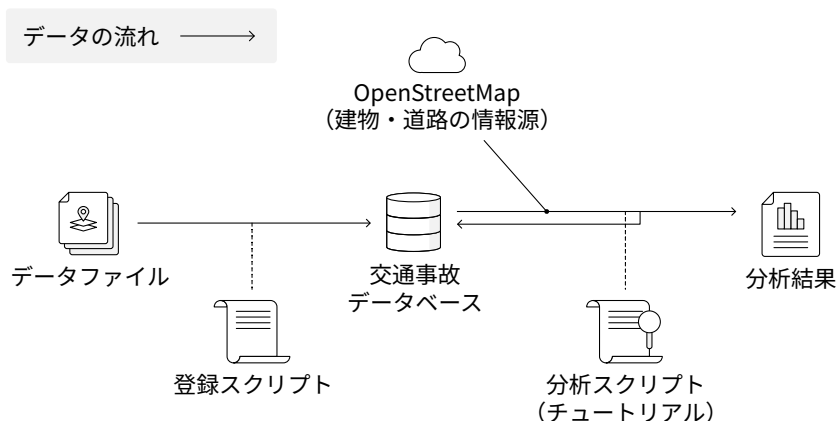


図 4.9 交通事故データベースを用いた分析フロー

築するだけでなく、得られた結果の意味が他者に伝わるものとなることも重要である。そのため、このデータ探索のモデルでは、データを分析環境へインポートするところから、その結果を他者と共有するまでの一連の流れを示している。加えて、これらのプロセスを横断するツールとして、プログラミングは有用であり、関連するタスクの解決を自動化に役立つと位置付けられている。

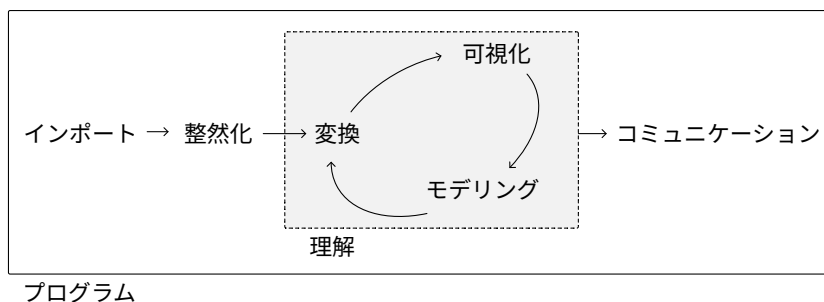


図 4.10 Wickham らが示したデータ探索の流れ (R for Data Science より引用)

このモデルでは、データのインポートの後に整然化と呼ばれる、データの前処理をおこなうプロセスが存在する。また、データの理解のために、変換、可視化、モデリングというプロセスの繰り返しが必要とされている。これらのプロセスを以下に説明する。

整然化 (tidy) 表形式のデータを各列が変数を、各行が観測値を表すように整理するプロセスである。このように整然化されたデータは整然データ (tidy data) と呼ばれる。データの形式を整然データに一貫することで、分析者は画一的にデータを操作でき、関心のある問題の解決に集中できる。

変換 (transform) 関心のある要素や関係に焦点を当てるために、データを絞り込んだり、新しい変数を定義したりするプロセスである。データを変換することで、観測データのままで、捉えるのが難しい要素を表現し、可視化やモデリングでそれを対象にできる。

可視化 (visualize) データの特徴や傾向を把握するために、データを視覚的に表現するプロセスである。棒グラフや折れ線グラフのように一般的なグラフだけでなく、地図へのプロット、アニメーション、インタラクティブな可視化など、さまざまな手法を含む。適切にデータを可視化することで、新しい洞察を得たり、そこから仮説を生成したりできる。

モデリング (modeling) 可視化から得た仮説に基づいて、データの関係や性質を数学的に表現するプロセ

スである。表現したモデルの正しさを検証することで、可視化で得られた洞察を裏付けたり、反証したりできる。

本研究で実装したスクリプト群は、この探索的データ分析の流れに基づいている。特に、Rで探索的データ分析を意識して開発されたパッケージ群である、^{タイディバース}**tidyverse**を活用しており、それぞれのプロセスに基づいて拡張可能なよう設計している。交通事故データベースにおいては、分析の結果を再びデータベースに登録することで、この探索的データ分析のサイクルを実行できるようにしている。

さらに、本研究では、交通事故データベースを含む分析環境を Docker ベースのシステムとして、まとめたものを構築した。これを「交通事故データ分析システム」と呼び、本研究の分析ではこのシステムを用いる。Docker はアプリケーションを各自のコンピュータの環境からできる限り分離し、その実行に必要なライブラリや設定をコンテナという単位でパッケージ化し、どこでも同じように動作させることを可能にする技術である。交通事故データ分析システムは図 4.11 に示すような構成になっている。

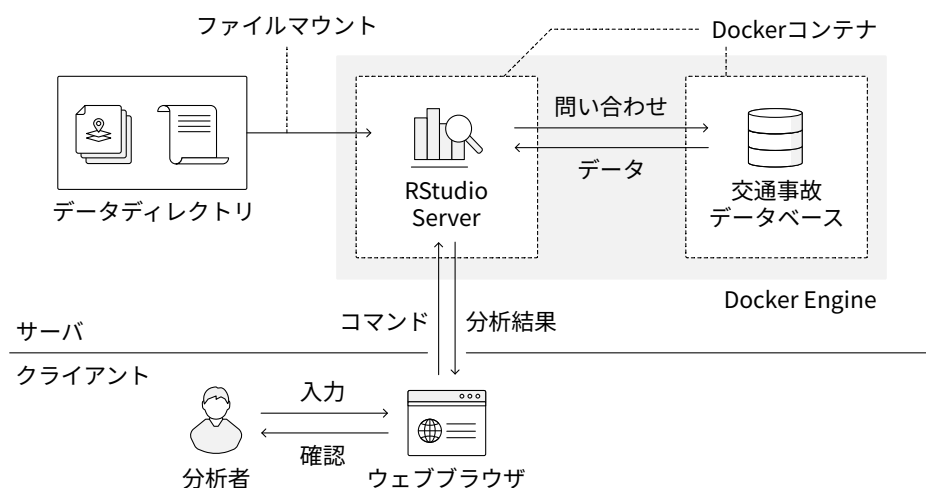


図 4.11 交通事故データ分析システムの構成

このシステムはデータベースシステムに加えて、RStudio Server を Docker 上で動作させている。RStudio Server はウェブブラウザから R の統合開発環境（IDE）である RStudio を利用できるようにするサービスである。Docker 上で RStudio Server と交通事故データベースはそれぞれ独立したコンテナとして動作しているが、これらは同じ仮想ネットワーク上で接続されている。分析者はウェブブラウザ上の RStudio を通じて、データベースを利用した分析、ファイル操作、分析結果の可視化などをおこなえる。

このシステムにより、分析者は自身のコンピュータの環境に依存せず、交通事故データベースを用いた分析を実現できる。サーバをリモートで動作させる場合には、ローカルコンピュータ上では、ウェブブラウザのみが動作するため、分析上、OS を含む環境の影響を受けることはない。また、サーバをローカルコンピュータ上で動作させる場合においても、Docker コンテナ内で動作する R やパッケージのバージョンが固定されていることから、R の環境の違いによる影響を小さくできる。

また、このシステムは Docker Compose により、一括で起動するように構成されている。そのため、内部的には複数のシステムから構成されているが、ユーザは特に個別のシステムを意識することなく、Docker Compose のコマンドの一つで、システム全体を起動できる。

4.3.4 交通事故データベースの性能評価

本研究では、交通事故データベースをデータモデルおよび拡張性に関する要件を満たすように、設計した。交通事故データベースは地理空間データとして交通事故の状況を表現し、交通事故のデータ分析に必要な時間および空間を指定した検索や演算に対応できる。また、関心のある、任意の種類データを加えることができる。さらに、Simple Features に基づくツールやライブラリとの互換性もある。これらから、目的に応じた拡張が可能であり、将来の分析に向けた拡張性も備えているといえる。

本研究では、これらの要件に加え、交通事故データベースが実用に耐えうる性能を有しているかを評価する。この評価として、サンプルデータベースの構築と、チュートリアルとして提供している分析シナリオの実行のそれぞれに要するリソースを計測する。

チュートリアルシナリオは図 4.12 に示すように、事故の発生件数を地域メッシュに基づいて空間集計し、その結果に基づき、各メッシュに彩色してヒートマップを生成するというものである。このような空間集計は事故の空間的分布を把握するための基礎的な手法である。このシナリオを通じて、交通事故データベースが日常的な分析操作において十分な性能を持つかどうかを評価する。

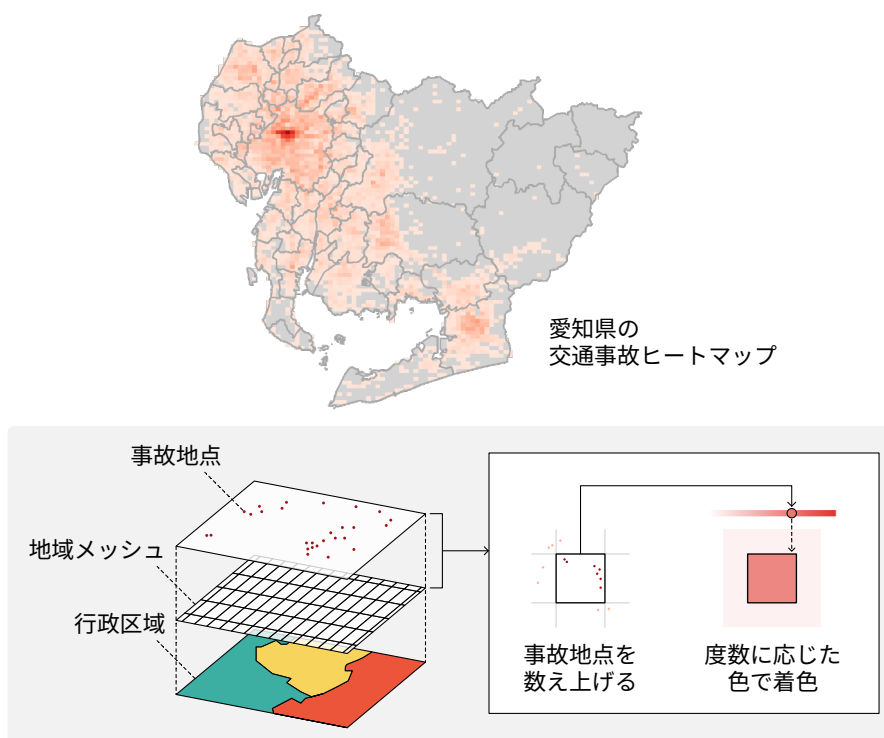


図 4.12 交通事故データベースを用いたヒートマップ作成シナリオ

実験の結果、サンプルデータベースの構築には約 2 時間を要し、チュートリアルシナリオは 19.79 秒で完了した。データベースの構築時間は登録するデータ量に依存するため、参考として表 4.9 に各データセットの登録件数と処理時間を示す。実験に使用したコンピュータは、CPU が AMD Ryzen 5 3600 (6 コア)、メモリ容量は 8 GB の構成である。このうち、CPU は 2 コアのみを使用し、最大使用率は約 77.8%、メモリの最大使用量は 7.609 GB であった。

これらの結果から、時間的および空間的資源の両面において、交通事故データベースは実用上十分な性能

表 4.9 サンプルデータベースへのデータ登録件数および時間

データ種別	登録レコード数 (件)	合計登録時間 (秒)
交通事故データ	1,657,130	396.42
交通量データ	215,346,415	5,726.62
用途地域データ	5	4.54
行政区域データ	149	15.18
地域メッシュデータ	26,649	869.12
合計	217,030,348	7,011.88

を有しているといえる。本シナリオでは愛知県全体を対象としていたため、多量のデータを一括して分析環境に取り込む必要があり、相応のメモリ量を要した。しかし、このメモリ使用量は一般的な研究用コンピュータの容量内に収まっており、特別に高性能な計算資源を必要としないといえる。

このように、本研究では交通事故に関するデータを総合的に扱うデータベースを設計した。設計したデータベースはこれまでに示したとおり、交通事故の分析に必要な性能を有しているといえる。以降、本研究では、この交通事故データベースを用いて、事故要因の分析をおこなう。

4.4 ホットスポットの検出

4.4.1 カーネル密度推定を用いた事故リスクの推定

交通事故の対策において、事故の発生しやすい地域や時間帯を検出することは非常に重要である。このような地域や時間帯はホットスポット (hotspot) と呼ばれる。実際におこなわれる具体的な事故対策には、交通警察官の配備や交通安全施設の設置などが挙げられるが、これらの実施に利用可能な人的、金銭的資源には限りがある。そのため、対策の効果を高めるために、有効なホットスポットを検出する方法が求められている。また、交通環境や運転者の行動は地域や時間帯に依存して、異なる。そのため、ホットスポットの検出は要因の差を明確化する観点においても、重要であるといえる。

交通事故のホットスポットの検出では、まず事故リスクの分布を推定する。それから、分布の中で事故リスクの高い地域や時間帯をホットスポットとする場合が多い。事故リスクの指標はそれぞれの分析目的により異なるが、主に交通事故の発生確率や重大度 (死亡、重傷、軽傷) が対象とされている。本研究の目的はマルチエージェントシステムとして交通事故を捉えることであり、対象とする事故リスクが発生確率であっても、重大度であっても、本質的な洞察を得ることができる。以降、本研究では便宜上、交通事故の発生確率を事故リスクとして扱う。

本研究では、事故リスクの分布を推定する代表的な手法であるカーネル密度推定 (KDE: kernel density estimation, 以降、KDE と記す) という手法を用いる。この手法はある確率変数について、過去の観測値から確率密度関数を推定する手法の一つである。したがって、交通事故の分析においては、過去に発生した事故のデータから、事故リスクの分布を推定できる。

また、KDE は事象の母集団が依存する分布として、正規分布やポアソン分布など、特定の分布を仮定しないノンパラメトリック (non-parametric) な手法の一つである。交通事故は複雑な発生メカニズムを持ち、その大部分が明らかでない。したがって、事象がどのような分布から生成されているかを仮定できない。そのため、ノンパラメトリックな手法である KDE が採用されている。このような性質は交通事故に限らず、さまざまな事象に通ずる。そのため、KDE は汎用性が高く、幅広い分野でさまざまな対象に応用されている。

単純な具体例から、KDEについて説明する。この例では、ある地域における交通事故の発生時刻に対する事故リスクの分布を推定する。つまり、ある時間に交通事故がどの程度発生しやすいかを推定する。この場合、KDEでは、過去の交通事故の発生時刻から推定する。ここでは、次の5件のデータが得られているとする。なお「10」とあるデータは10時に1件の交通事故を観測したことを意味する。

10	12	13	17	18
----	----	----	----	----

これらの交通事故の発生時刻から、最終的にKDEで推定される確率密度関数を図4.13に示す。KDEでは、図中の曲線で示された確率密度関数 \hat{f} が推定される。確率密度関数 (PDF: probability density function) はその積分を確率とする関数である。例えば「12-13時に交通事故が発生する確率」は面積 $\int_{12}^{13} \hat{f}(x)dx$ として求められる。また、KDEで推定する確率密度関数は、標本の分布を滑らかにしたものであり、観測されたデータ点の密度が高い部分ほど、確率密度関数の値が大きくなる。この図からも、交通事故の発生データのある12-13時の確率 $\int_{12}^{13} \hat{f}(x)dx$ は大きい一方で、発生データのない14-15時の確率 $\int_{14}^{15} \hat{f}(x)dx$ は小さくなっていることが読み取れる。




図 4.13 カーネル密度推定により推定された、交通事故の発生確率についての確率密度関数

KDEでは、カーネルの和から確率密度関数を推定する。カーネル (kernel) とは、標本周辺に与えられる重みを表現する関数であり、標本からの距離と重みの大きさを対応付ける。これは観測された標本に対して、その周辺で事象が観測される確率を表現したものである。例のように、13時に交通事故が観測された場合、その前後の12時や14時にも交通事故が発生する可能性があると考えられる。このようにカーネルは得られている標本の周辺において、同様の要因から事象が発生する可能性を表現している。代表的なカーネルには、標準正規分布に基づくガウシアンカーネル (Gaussian kernel) や、一定の範囲内で均一な重みを与える一様カーネル (uniform kernel) などがある。

この例では、図4.14に示すように、個々の標本に対して、ガウシアンカーネルを与え、これらを足し合わせることで、滑らかな確率密度関数を求めている。点線で示された曲線がカーネルであり、それぞれの標本を中心に広がっていることが分かる。これらを足し合わせた曲線が実線で示した、推定された確率密度関数である。また、ここでは縦軸をカーネルの値の和としているが、図4.13に確率密度関数はこのカーネルの和を、全体の面積が1になるように正規化したものである。




図 4.14 個々の標本（交通事故の発生時刻）に与えられたカーネル

数学的には、カーネル関数を K とすると、KDE で推定される確率密度関数 \hat{f}_h は式 (4.1) で表される。

$$\hat{f}_h(x) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x-x_i}{h}\right) \quad (4.1)$$

ここで、 h はカーネルのバンド幅を表す。バンド幅はカーネルの広がりを表現するパラメータである。また、 $x_i \in \mathbf{X} = \{x_1, x_2, \dots, x_n\}$ は i 番目の標本を表す。 n は標本の総数であり、全体を nh で割ることで、確率密度関数として正規化している。

4.4.2 従来のホットスポットの検出手法とその課題

従来のホットスポットの検出では、事故リスクの推定において、KDE を道路ネットワークに適用したものや、さらに時間方向へ拡張した 2 次元の KDE などが提案されている [64]。Xie・Yan (2008) は一般的な空間分析に用いられる地理空間カーネル密度推定の問題を指摘し、道路ネットワークに KDE を適用する手法を提案した [64]。

地理空間カーネル密度推定 (Geo-KDE: geospatial kernel density estimation, 以降、Geo-KDE と記す) は KDE を地理空間に適用したもので、土壌調査や犯罪調査など、幅広い分野で用いられる。Geo-KDE により、交通事故を推定する例を図 4.15 に示す。なお、この図において、地理空間が格子状に分割され、離散化されているのは、コンピュータで扱いやすいように、分析上、空間モデルをこのように構成する場合が多いことによるものである。ここでは、格子 (セル) ごとの推定値を色で表現している。

Geo-KDE の計算方法は基本的に KDE と同じである。標本に対して地理空間方向に広がる 2 次元のカーネルを与え、これらを足し合わせることで、確率密度関数を推定する。そのため、図中に示したとおり、事故が多く発生した場所はカーネルの和が大きくなり、事故リスク (確率密度) が高い地域として見積もられる。また、反対に事故が発生していない場所では、事故リスクが低く見積もられる。

しかし、Geo-KDE により事故リスクを推定すると、事故地点との関連性の低い場所に対しても、事故リスクを高く見積もってしまう場合がある。例えば、図 4.16 に示すように、川を挟んで 2 本の道路が並行して走っている場合を考える。このとき、Geo-KDE では、事故地点からの距離に応じて重み付けるため、図に示すように道路に沿って一定距離進んだ地点と、川を挟んで対岸の地点の事故リスクを同等に評価してしまう。しかし、実際には同じ道路上の地点と、川を挟んだ対岸の地点では、車線数や交通量など、交通環境が大きく異なることが想定される。同様にして、路外や立体交差などについても、事故リスクが実際よりも




図 4.15 地理空間カーネル密度推定による事故リスクの推定例

高く評価されてしまう場合がある。




図 4.16 地理空間カーネル密度推定による事故リスクの推定における問題点

この問題に対し、Xie・Yan は交通事故が道路上の事象であることを考慮し、道路ネットワークを対象としたネットワークカーネル密度推定 (Net-KDE: network kernel density estimation, 以降、Net-KDE と記す) を提案した。この手法は図 4.17 に示すように、道路に沿う形状の事故リスクの分布を推定する。左側の図はいくつかに分岐した道路で事故が発生したことを示している。右側の図はこれらの事故の位置情報から、Net-KDE により推定した事故リスクの分布を示している。また、Net-KDE の場合にも、Geo-KDE と同様にコンピュータ上で計算しやすくするために、道路ネットワークを一定の長さのセグメントに離散化し、それらのセグメントに推定値を割り当てる。

Net-KDE では、事故地点を中心とする、道路ネットワークに沿って広がるネットワークカーネル (network kernel) により重み付けられる。図 4.18 に 1 つの事故地点に対するカーネルの例を示す。図にあるように、ネットワークカーネルでは、事故地点からの経路距離が長くなるほど、重みが小さくなるように設計されている。カーネルが道路ネットワークに沿っていることから、Net-KDE は Geo-KDE の問題である「事故地点から路外を経由して離れた地点にまで重みが与えられてしまう問題」を解決している。また、路外の部分は道路ネットワークに存在しないため、評価の対象外となっている。なお、車両同士の衝突や歩行者の巻き込み事故などでは、事故地点が道路外に記録される場合も少なくない。そのため、通常は各事故地点を最も近い道路ネットワーク上の地点にスナップして、Net-KDE の適用をおこなう。

さらに、Xie・Yan (2013) は Net-KDE により推定された事故リスクの空間的自己相関から、ホットス

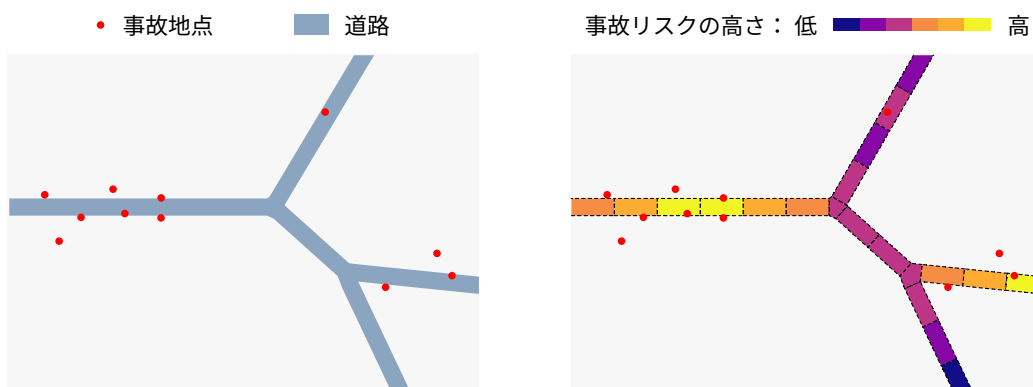


図 4.17 ネットワークカーネル密度推定による事故リスクの分布の推定例




図 4.18 経路距離の長さに応じて重み付けるネットワークカーネルの例

ポットを検出する方法を提案した [65]. 空間的自己相関 (spatial autocorrelation) とは、地理空間上のある地点における事象が、その近傍の事象と影響し合う関係をいう。Xie・Yan は道路ネットワークの各セグメントについて、空間的自己相関をローカルモラン統計量という指標を用いて数量的に評価した。そして、各セグメントの評価値から、注目している地点とその周囲が共に高い事故リスクを持つ性質を満たす地域を抽出した。さらに、モンテカルロシミュレーションにより事故件数の配置を入れ替えた事故分布を生成し、それらの分布群と比較することで、統計的に有意に事故リスクが高いといえる地域をホットスポットとして検出している。

この検出方法で得られるホットスポットは、事故リスクに対し、一定の閾値を設け、ホットスポットを検出する単純な方法と比較して、信頼性が高い。閾値によりホットスポットを抽出する場合、この閾値を適切に設定することが難しく、主観的なものとなりやすい。また、交通事故は空間に対する発生数が少なく、スパースな事象である。そのため、非常に小さな領域に偶発的に事故が重なってしまった場合に、その箇所の事故リスクが強められ、ホットスポットとして検出されてしまうことがある。Xie・Yan の手法では、ホットスポットを空間的な傾向から検出しているため、このようなノイズを抑えられる。さらに、仮説検定を用いてホットスポットを判定していることから、仮説に基づいてホットスポットを解釈できる。

Net-KDE では、事故リスクの分布を表現する空間について、交通事故が道路上で発生することを考慮し、一般の地理空間モデルである 2 次元平面でなく、道路ネットワークを採用している。この空間モデルをさらに発展させ、時間方向へ拡張したモデルが Romano・Jiang により提案されている。Romano・Jiang (2017) は交通事故の発生が時間と空間の両方に依存していることを考慮し、その両方が解釈できる事故リスクの分布として、時空間的な分布の推定と表現を目指した。そのために、Net-KDE を時間方向へ拡張し、時間

と空間の両方を考慮した空間モデルと、そのモデルに基づく KDE を提案した [66]。この道路ネットワークを時間方向へ拡張した空間モデルを時空間ネットワーク (spatiotemporal network) という。また、この時空間ネットワークにおける KDE を時空間ネットワークカーネル密度推定 (STN-KDE: spatiotemporal network kernel density estimation, 以降, STN-KDE と記す) という。

時空間ネットワークによる交通事故の分布の表現例を図 4.19 に示す。時空間ネットワークは水平方向に道路ネットワークの広がり、垂直方向に時間の流れを表現した空間モデルである。また、時空間ネットワークでは、道路ネットワークが層状に積み重なっている。図中で「12 時台の層」について示すように、各層は一定の時間における事故の分布を表現している。時空間ネットワークはこれまでの空間モデルと同様に、コンピュータ上で扱いやすいように、一定の時間、一定の長さの道路セグメントからなるブロック状の空間に、離散化されている。交通事故の分布を時空間ネットワークで扱う場合、事故データは近くのブロックに集約され、各ブロックがその情報を持つ。この図では、赤色の濃さで事故件数の多さを表現しており、中心付近の Y 字路では、12 時台に多くの事故が発生していることが分かる。




図 4.19 時空間ネットワークによる交通事故の分布の表現例

この時空間ネットワーク上でブロック状に表現された時空間の単位はさまざまな呼び方が存在するが、本論文では一般的な空間分析の用語に合わせ、時空間セグメント (spatiotemporal segment) と呼ぶ。また文脈上、時空間を対象としていることが明確な場合には、単に「セグメント」と呼ぶこととする。なお、Romano・Jiang は論文上でこれを **arixel** と呼称している。これは Net-KDE のセグメントを線形のピクセルと捉え「lixel (linear pixel)」とし、これに対して、このブロック状に表現された時空間の単位を「arixel (aerial lixel)」としたものである。本論文とは、異なる表現を用いているため、注意されたい。

STN-KDE では、この時空間ネットワークの上で事故リスクの分布を推定する。図 4.20 に STN-KDE による推定例を示す。左側の図は図 4.19 で示した、事故件数の分布である。右側の図はこの事故件数の分布から、STN-KDE により推定された事故リスクの分布を示している。推定された事故リスクの分布は時空間ネットワーク全体に渡って表現される。他の KDE と同様に、事故件数の多い時空間では、事故リスクが高

く見積もられていることが分かる。また、事故が発生していない時空間についても周囲の事故件数に基づき、事故リスクが推定されていることが分かる。このように、STN-KDE により推定された事故リスクの分布はいつ、どこが、どの程度事故が発生しやすいかを 3 次元的に把握できるという特徴を持つ。

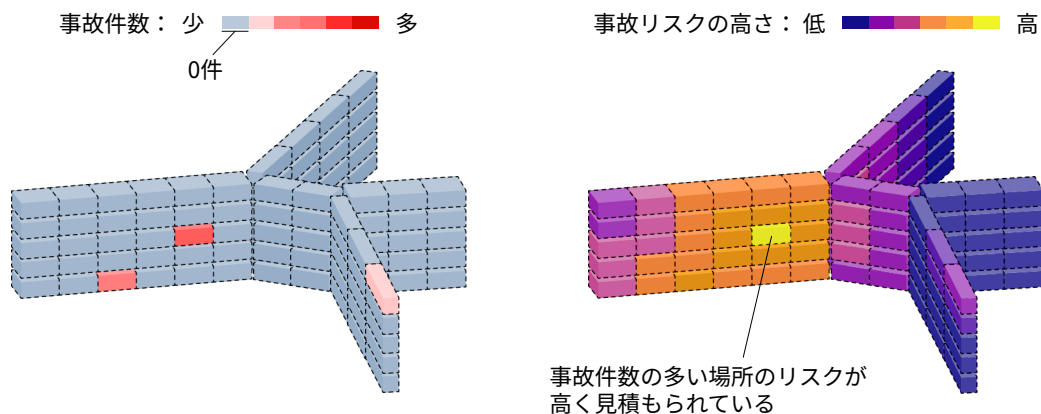


図 4.20 時空間ネットワークにおける事故件数の分布と、カーネル密度推定により推定された事故リスクの分布の例

この STN-KDE では、推定に図 4.21 に示すような時空間カーネルが用いられる。時空間カーネル (spatiotemporal kernel) は時空間ネットワークの上で、事故のあった時空間を中心に広がるカーネルである。このカーネルは Net-KDE にも用いられるネットワークカーネル (図中、右上) と、時間方向に広がる時間カーネル (図中の右下) を組み合わせたものとなっている。時間カーネルは単純な 1 次元のカーネルであり、事故が発生した時間から離れるほど、重みが小さくなるように設計される。STN-KDE では、便宜上、ネットワークカーネルと区別して、時間カーネルと呼ばれる。時空間カーネルの重みはこれらのカーネルの積として計算され、事故のあった時空間から、空間的にも時間的にも離れるほど、小さくなる。STN-KDE では、すべての事故についての時空間カーネルを足し合わせることで、事故リスクの分布を推定している。

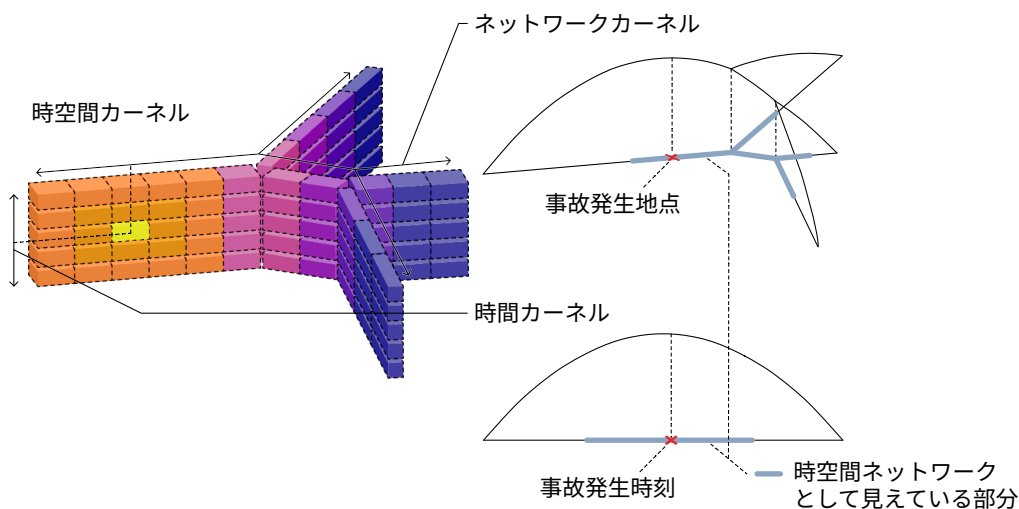


図 4.21 ネットワークカーネルと時間カーネルからなる時空間カーネル

Net-KDE や STN-KDE のように、KDE における空間モデルとそれに合わせたカーネルの拡張は、事故

の発生する空間をより適切に表現し、事故リスクの推定を正確にする。一方で、これらの手法で用いられたネットワークカーネルには、交差点付近において事故リスクを過大評価してしまうという問題が Okabe らにより指摘されている [67]。

Xie・Yan が提案したネットワークカーネルは、経路距離に応じて重みを与えるカーネルである。このカーネルは交差点において分岐し、その先の道路セグメントへも、経路距離に応じて減衰した重みを与えられるように設計されている。分岐した先のカーネルの形状は、元のカーネルと同じ形状であり、カーネルの一部が複製されたような形を持つ。そのため、交差点付近では分岐した数に応じて、事故リスクが過大評価されてしまう。ここで、KDE では事故リスクを確率密度関数の区間を積分した面積として解釈していることに注意されたい。つまり、交差点付近の一定の範囲について、積分した面積が事故リスクとして評価され、その値が分岐の数に応じて大きくなってしまいうことである。

また、通常の KDE では、カーネルの中心から各方向への重みの総和が等しく、対称性を持つ。しかし、このネットワークカーネルでは、枝分かれの数に応じてカーネルの一部が複製されるため、対称性がなくなり、空間全体に対する重みが偏るという問題もある。

Okabe ら (2009) はこれらの問題を解決した 2 種類のネットワークカーネルを提案している [67]。これらのカーネルの形状を図 4.22 に示す。一つは等分割カーネルである。等分割カーネル (equal-split discontinuous kernel) では、交差点で分岐した先の各道路セグメントに対し、元のカーネルの重みを枝分かれの数に分割して与えるというものである。もう一つは等分割連続カーネルである。このカーネルは、等分割カーネルに基づいて、さらに交差点付近でカーネルが連続するように調整したものである。




図 4.22 Okabe らの提案したカーネル：等分割カーネル（左）と等分割連続カーネル（右）

Okabe らは提案したこれらのカーネルについていくつかの観点から評価した。これらのカーネルには、それぞれ利点と欠点が存在し、使い分ける必要がある。等分割カーネルは枝分かれた先の重みを分割することで、中心からそれぞれの方向への重みの総和を等しくしており、対称性を持つ。しかし、交差点において不連続であるため、推定値が急激に変化してしまうという欠点もある。特に、事故件数が少ない場合には、この不連続性が顕著に現れ、不自然な結果となる。一方、等分割連続カーネルは連続性を満たすように調整されているため、この問題を解決している。しかし、調整を加えたことで、対称性が失われている。また、等分割カーネルよりも計算コストが高くなるという欠点もある。これらの性質から、対象とするネットワークがバンド幅よりも短いリンクを多く含むような場合には、等分割カーネルが実用的であり、交差点において連続的なカーネルが必要な場合には、等分割連続カーネルが適していると結論づけている。

さらに、Gelb・Apparicio (2024) は Xie・Yan が提案したものと、Okabe らが提案したものを含む 3 種類のネットワークカーネルを選択的に組み込むことが可能な STN-KDE を提案した [68]。また、KDE で一般的に利用される偏りの補正手法や、バンド幅の調整手法も組み込み、STN-KDE の精度向上を図っている。Gelb・Apparicio はモンリオールの歩行者を含む交通事故を対象に、この STN-KDE の有用性を評価した。推定された事故リスクの分布を、時間の流れに応じて変化するアニメーションとして可視化した。この

アニメーションから、事故リスクの経時的な変化を把握できるとしている。

このように事故リスクの分布をより正確に推定するために、従来研究では KDE を拡張したさまざまなモデルが提案されてきた。しかし、これらの手法には、ホットスポットの検出や評価に関してはいくつかの課題が残されている。例えば、STN-KDE は時間と空間の両方を考慮した事故リスクの分布を推定できる点で優れているが、この分布に基づく、ホットスポットの検出手法は提案されていない。一方、ホットスポットの検出方法については、Xie・Yan の Net-KDE を対象としたものなど、提案されているが、検出された結果の評価方法については十分に検討されていない。さらに、KDE では対象とできるデータの条件として同一分布から独立にサンプリングされた集合であることが求められる。しかし、従来研究では、対象の交通事故データがこれを満たしているかどうかについては、示されていない。したがって、より信頼度の高いホットスポットを検出するために、これらの課題を解決した検出および評価のための手法の確立が必要である。

4.4.3 時空間的なホットスポットの検出手法の提案

本研究では、従来研究の課題を解決するために、時空間的なホットスポットの検出手法を提案する [69]。従来研究では、交通事故の発生する空間として、道路ネットワークを考慮したものが提案されているが、交通事故の発生する時間を考慮したものはない。そこで、本研究は Xie・Yan のホットスポットの検出手法に、STN-KDE による時空間的リスク分布の推定を組み込み、時空間的なホットスポットの検出手法を検討する。また、検出されたホットスポットの評価方法についても合わせて検討する [70]。

本研究で提案するホットスポットの検出手法の手順は次のとおりである。

- 手順 1. KDE の前提条件の検証
- 手順 2. STN-KDE による事故リスクの推定
- 手順 3. モンテカルロシミュレーションに基づくホットスポットの検出

まず、手順 1. では、対象とする交通事故データが KDE の前提条件である、同一分布から独立にサンプリングされた集合であるかどうかを検証する。本研究では、時空間的性質が時間の経過に対して一定であるデータを同分布から得られたものとして判定する手法を提案する。なお、一般に個々の事故は独立に発生していると考えられるため、独立性については満たしているものとみなす。

次に、手順 2. では、STN-KDE を用いて、交通事故の時空間的な事故リスクの分布を推定する。本研究では、Okabe らが提案した等分割カーネルを組み込んだ時空間カーネルを提案する。そして、この時空間カーネルに基づく STN-KDE を用いて、事故リスクの分布を推定する。

最後に、手順 3. では、推定された事故リスクの分布に基づき、ホットスポットを検出する。この検出には、Xie・Yan が提案した手法を用いる。この手法では、まず道路ネットワークの各セグメントについて、空間的自己相関をローカルモラン統計量により評価する。さらに、モンテカルロシミュレーションに基づく仮説検定から、統計的に有意に事故リスクが高いといえる地域をホットスポットとして検出する。

検出されたホットスポットの評価には、PAI という指標を用いる。PAI (predictive accuracy index) は空間分析に用いられる指標で、交通事故が発生すると予測されるホットスポットの面積に対して、そのホットスポットによる事故的中率を評価するものである [71]。本研究では、この PAI を用いて、検出されたホットスポットの評価し、提案手法の有用性を検証する。なお、交通事故の特徴には地域差があり、この評価結果は地域により異なることが想定される。そこで本研究では、複数の地域における評価を実施し、地域の特徴に対する提案手法の汎用性についても確認する。以降では、各手順の詳細について述べる。

KDE の前提条件の検証

従来研究においても、事故リスクの分布が KDE により推定されているが、交通事故データは KDE の適用条件を満たしていない場合がある。KDE では、観測データが同じ分布から独立にサンプリングされた集合であるとみなし、その元となった分布を標本から推定している。そのため、対象のデータが同分布から得られたものでない場合には、KDE により正確な分布を推定できない可能性がある。

一方、交通事故は発生する地点や時間帯の傾向が期間により変化することがある。例えば、冬場の路面凍結によるスリップ事故の増加や、事故対策による事故発生頻度の減少、薄暮時間帯の変化など挙げられる。このように交通事故は季節や年次経過に伴い、時空間分布が変化する可能性があり、場所や時期によっては同分布であるとみなすことが難しい場合がある。

対象のデータが同分布から得られたものかを確認する必要があるかどうかは、目的とする結果に応じて異なる。Gelb・Apparicio は長期的な事故リスクの分布の変化を捉えるために、2016年から2019年までの事故データを1日ごとに離散化し、期間全体を1つの分布として推定した [68]。この研究では、推定対象の分布自体に季節や年次経過に伴う変化が含まれている。そのため、時期による分布の変化を考慮する必要はない。これに対し、本研究では、どの場所が何時頃に事故リスクが高いかという結果を得るために、1日の中での事故リスクの分布を推定する。したがって、時期によっては、分布の傾向が異なる可能性があり、同分布であるかどうかを確認する必要がある。

本研究では、愛知県の交通事故の多い地域を対象に、事故リスクの分布の推定をおこなう。分布が異なることが想定される時期的影響として、季節と年次経過に伴う環境変化が考えられる。このうち、季節による変化については、事故件数全体の増減はあるものの、空間的または時間的な傾向の変化はないことを予備的に確認した。そのため、本研究では年次経過に伴う変化を対象に、分布の傾向が変化していないかを確認する。特に、愛知県では事故対策が積極的におこなわれており、年次経過に伴う事故件数の減少は顕著である。そのため、特定の時間帯や場所へ対策がおこなわれている場合には、その影響が分布に現れると考えられる。

年次経過に伴う変化を確認するために、各年の分布を推定すれば、この傾向の変化を直接的に確認できる。しかし、これは推定を年数分実施するために、本来の目的の分析よりも、多大なコストが掛かってしまう。そこで、本研究では時空間セグメントごとに各年の性質を調べる。そして、その傾向が一定であるかどうかを仮説検定により検証することで、分布の傾向に変化があるかどうかを判定する。

空間分析では、空間分布の傾向を把握するのに、空間的自己相関が用いられる。本研究では、時空間を対象とするため、これを時間方向に拡張した時空間的自己相関に基づいて、時空間分布の傾向を調査する。時空間的自己相関 (spatiotemporal autocorrelation) とは、ある時空間セグメントにおける事象が、その近傍、つまり前後の時間帯や周囲の道路セグメントと影響し合う関係をいう。また、相関関係と同様にこれには正の自己相関と負の自己相関がある。注目しているセグメントの観測値が高い場合に、近傍の観測値も高い場合には正の自己相関、逆に近傍の観測値が低い場合には負の自己相関があるという。例えば、12時台のある交差点で多くの事故が観測されている場合に、その場所の11時台や13時台、または近くの道路でも事故件数が多く観測されている場合には、正の時空間的自己相関があるという。

空間的自己相関を評価する指標には、目的に応じて、いくつかの種類が存在するが、本研究では局所的な自己相関を測るために、ローカルモラン統計量を用いる。また本研究では、この指標に基づく4つ性質を用いてセグメントの性質を評価する。ローカルモラン統計量は対象地域を分割した小地域ごとの空間的自己相関を評価する指標である。本研究では、時空間ネットワークを離散化した各セグメントを小地域として扱う。

セグメント i におけるローカルモラン統計量 I_i は式 (4.2) で定義される [72].

$$I_i = (x_i - \bar{x}) \sum_{j=1}^n w_{ij} (x_j - \bar{x}) \tag{4.2}$$

注目しているセグメントについて、この値が正であれば正の自己相関を持ち、負であれば負の自己相関を持つことを表す。また、絶対値は自己相関の強さを表す。ここで、 n はセグメントの総数、 x_i, x_j はそれぞれセグメント i, j における事故件数を表している。また、 \bar{x} はすべてのセグメントにおける事故件数の平均値、 w_{ij} はセグメント i と j が近傍にあるかどうかという関係を表現した重みである。

また、重み係数 w_{ij} には、さまざまな設定が存在するが、ここではルーク型の 2 進的重み係数を採用する。2 進的重み係数 (binary weight) は、小地域 i と j が隣接している場合に $w_{ij} = 1$ 、それ以外の場合に $w_{ij} = 0$ とするものである。また、地域メッシュのようなラスタデータ*2に対して、この重み係数を用いる場合には、隣接判定をチェスの駒の動きに例えたルーク型とクイーン型がよく用いられる。ルーク型は上下左右の 4 方向のみを隣接とするのに対し、クイーン型は斜め方向も含む 8 方向を隣接とする。

なお、ローカルモラン統計量は空間的自己相関を測るものであり、時間は考慮されていないが、時間方向についても、空間方向と同様に w_{ij} により近傍関係を定義することで、自然な拡張が可能である。本研究では、セグメント i と j が時空間ネットワーク上の時間あるいは空間方向に隣り合う場合には $w_{ij} = 1$ 、それ以外の場合には $w_{ij} = 0$ とする。ただし、セグメントが斜めに位置している場合、すなわち、隣り合う道路セグメントで 1 単位だけ時間方向にずれている場合には、隣接していないものとして $w_{ij} = 0$ とする。

また、図 4.23 に示すように、本研究で対象とする時空間ネットワークでは、セグメントの位置により隣接するセグメントの数が異なる。時間方向の空間はトーラス状*3になっており、端が存在しない。そのため、すべてのセグメントは前後の時間を表す 2 つのセグメントと必ず隣接する。一方、道路ネットワーク上では、道路の端、すなわち行き止まりのセグメントは 1 つのセグメントとしか隣接していないため、他のセグメントよりも隣接するセグメントの数が少なくなる。また、交差点付近のセグメントは交差点を經由して、複数の道路と接続するため、その本数に応じて、隣接するセグメントの数が多くなる。

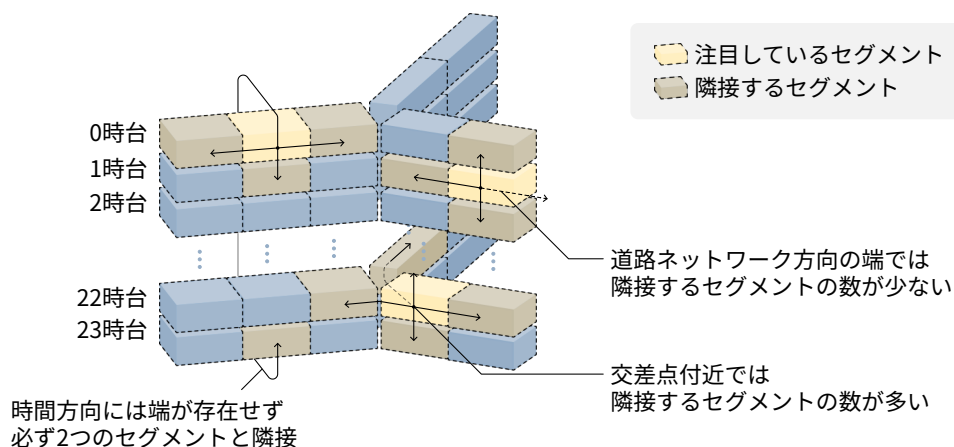


図 4.23 時空間ネットワークとセグメントの近傍関係

本研究では、このローカルモラン統計量に基づき、セグメントを 4 つの時空間的性質に分類する。ローカルモラン統計量は式 (4.2) に示したように、平均から自身との差 $(x_i - \bar{x})$ と、平均から近傍集合との差

*2 格子状に配置されたセル (ピクセル) で構成されたデータ形式のこと。画像や地理情報システムでよく用いられる。

*3 ドーナツのように面が循環している形状のこと。

$\sum_{j=1}^n w_{ij}(x_j - \bar{x})$ の積として定義されている。それぞれを X 軸、 Y 軸にとった散布図をモラン散布図という。ただし、モラン散布では、両方の軸を標準偏差で割り、標準化した値が用いられる。また、 Y 軸に用いられる、標準化された平均から近傍集合との差を空間ラグという。このモラン散布図では、セグメントが属する象限に応じて、次の4つの性質に分けられる。なお、HHという性質は「ホットスポット」とも呼ばれるが、本研究では時空間的性質を指す場合には「HH」と表記し、交通事故の多発する空間を指す「ホットスポット」とは区別して扱う。

- 第1象限 (HH: High-High, ホットスポット): 自身と近傍集合の事故件数が両方とも平均よりも高い場合 (正の自己相関)
- 第2象限 (LH: Low-High, ホワイトスポット): 自身の事故件数が平均よりも低く、近傍集合の事故件数が平均よりも高い場合 (負の自己相関)
- 第3象限 (LL: Low-Low, クールスポット*⁴): 自身と近傍集合の事故件数が両方とも平均よりも低い場合 (正の自己相関)
- 第4象限 (HL: High-Low, ブラックスポット): 自身の事故件数が平均よりも高く、近傍集合の事故件数が平均よりも低い場合 (負の自己相関)

この分類に基づき、セグメントごとに4つの性質を調べることで、時空間的な分布の傾向を把握する。モラン散布図と時空間的性質に基づいて塗分けられたセグメントの例を図4.24に示す。この塗分け図は Anselin が空間的性質に基づくクラスタを可視化するために提案したもので、LISA クラスタマップと呼ばれる [72]。本研究では、時空間ネットワークを対象としているため、これを LISTA クラスタマップ (local indicators of spatialtemporal association cluster map) と呼ぶこととする。




図 4.24 モラン散布図 (左) と LISTA クラスタマップ (右) の例

LISTA クラスタマップでは、4つの時空間的性質、HH, LH, LL, HL に応じてセグメントを塗分ける。特に赤色で示した HH であるセグメントは、近傍のセグメントと共に事故件数が高く、ホットスポットの候補として注目される。しかし、この性質が期間全体を通じて、変化しないものであるかは分からない。

本研究では、この LISTA クラスタマップを対象期間の年ごとに作成し、各セグメントが属する性質が経年的に変化していないことを統計的検定から確認する。そして、変化していないセグメントを、KDE の前提条件を満たしているものとして扱う。空間分析では、対象の性質についての事前知識がない場合に、事象

*⁴ コールドスポット (coldspot) とも呼ばれる。

が完全にランダムに発生しているという仮定、完全空間ランダム性 (CSR: complete spatial randomness) を仮定し、これが正しいか否かを判定するところから分析をおこなうことがある。本研究でも同様に、交通事故の分布の傾向について事前の情報はないため、各セグメントの時空間的性質は完全にランダムであるという仮説を立てる。そして、これが棄却された場合、そのセグメントは特定の傾向を持つと判断する。

まず、各セグメントが最も多く属した性質をそのセグメントの尤もらしい性質とする。そして、尤もらしい性質でない年数が何年あるかを求める。この年数は式 (4.3) のように定式化される。

$$\begin{aligned} n_i^{\text{diff}} &= |\mathcal{Y} \setminus \mathcal{Y}_i^*| \\ \mathcal{Y}_i^* &= \{y \in \mathcal{Y} \mid C_{i,y} = C_i^*\} \\ C_i^* &= \text{mode}_{y \in \mathcal{Y}}(C_{i,y}) \quad (C_{i,y} \in \{HH, HL, LL, LH\}) \end{aligned} \quad (4.3)$$

ここで、 $C_{i,y}$ はセグメント i が年 y に属した時空間的性質、 C_i^* は尤もらしい性質を表している。尤もらしい性質 C_i^* は最も多く属した性質であり、最頻値 (mode) として計算できる。また、 \mathcal{Y} は対象期間の年数の集合、 \mathcal{Y}_i^* はセグメント i が尤もらしい性質に属した年数の集合を表す。尤もらしい性質に属していない年数 n_i^{diff} は \mathcal{Y} から \mathcal{Y}_i^* を除いた集合の要素数として求められる。

セグメントの性質が完全にランダムであるとする、4種類の性質に属する確率は等しく、尤もらしい性質 C_i^* に属する確率は $\frac{1}{4}$ 、属さない確率は $\frac{3}{4}$ である。尤もらしい性質に属さない確率を p とすると、帰無仮説と対立仮説は次のように定義される。

- H_0 (帰無仮説): $p = \frac{3}{4}$, セグメント i の性質は完全にランダムである。
- H_1 (対立仮説): $p < \frac{3}{4}$, セグメント i の性質には傾向があり、完全にランダムでない。

ここでは、KDE が適用可能であるように、各セグメントには一定の傾向があることを期待している。そのため、セグメントの性質が異なる性質に変化する確率は、少なくとも完全にランダムな場合の $\frac{3}{4}$ よりも小さくなることを対立仮説 H_1 に設定している。

尤もらしい性質に属さない年数 n_i^{diff} は二項分布 $Bi(m, \frac{3}{4})$ に従う。したがって、観測された n_i^{diff} が帰無仮説 H_0 のもとで得られる確率 (片側検定の P 値) は式 (4.4) で表される。

$$P\text{-value} = P(X \leq n_i^{\text{diff}} \mid H_0) = \sum_{k=0}^{n_i^{\text{diff}}} \binom{m}{k} \left(\frac{3}{4}\right)^k \left(\frac{1}{4}\right)^{m-k} \quad (4.4)$$

$$X \equiv n_i^{\text{diff}} \sim Bi\left(m = |\mathcal{Y}|, p_0 = \frac{3}{4}\right)$$

この確率が有意水準 α 以下であれば、帰無仮説 H_0 は棄却され、セグメント i の性質には傾向があると判断する。 H_0 が棄却できなかったセグメントは、性質がランダムでないとはいえない。したがって、KDE の前提条件を満たしていないものとし、分析の対象から除外する。

なお、帰無仮説を棄却できない、性質がランダムに変化するセグメントはごく少数であることが予想される。この検定では、最終的に得られるクラスタの信頼性を高めるため、性質が安定しない例外的なセグメントを除外することを目的としている。そのため、対立仮説を満たすセグメントは、少なくとも一定の傾向を有すると考えられるが、必ずしも強い傾向を示すとは限らない。

また、除外されるセグメントにも事故が含まれる。本研究では、ホットスポットとして、過去多くの事故が観測された場所、時間帯に関心を置いている。そのため、これらのセグメント内の事故は相対的に事故リスクの低い時間帯や場所で偶発的に発生したものとして、分析から除外している。しかし、これらの事故も全く無視してよいというわけではない。事故の時間と位置だけでは特定できない潜在的な要素から、説明で

きる可能性がある。このような事故をどのようにして分析に取り入れるかは、今後の課題としたい。

STN-KDE による事故リスクの推定

Xie・Yan が提案した Net-KDE のネットワークカーネルは、経路距離のみから評価されるもので、交差点付近における事故リスクが過大評価されてしまうことが知られている [67]。この問題は同じネットワークカーネルを利用している、Romano・Jiang の STN-KDE においても交差点付近では同じ問題が発生し得る。

そこで、本研究ではこの問題を考慮した等分割カーネルを、従来の時空間カーネルへ組み込んだ新たなカーネルを提案する。そして、このカーネルを用いた STN-KDE から、より正確な分布の推定を実現する。

このカーネルのイメージを図 4.25 に示す。このカーネルは従来の時空間カーネルと同様に事故発生点を中心に、時間方向と道路ネットワーク方向に広がる。図では、事故発生地点 x 、事故発生時刻 $t = t_0$ を中心に広がるカーネルを示している。ネットワーク方向に広がるカーネルは時刻 $t = t_0$ から離れるにつれて、徐々に小さくなっている。加えて、ネットワークカーネルに等分割カーネルの考え方を取り入れ、交差点では分岐した道路の本数に応じて重みを等しく分割する。これにより、交差点付近における事故リスクの過大評価を防止している。




図 4.25 交差点付近における事故リスクの過大評価を防止する時空間カーネル

STN-KDE により推定される時空間ネットワーク上の時刻 t 、地点 x における確率密度は、式 (4.5) として定義される。

$$\hat{f}_{h_x, h_t}(x, t) = \frac{1}{n} \sum_{i=1}^n K_{x_i}(x) K_{t_i}(t) \quad (4.5)$$

ここで、 h_x 、 h_t はそれぞれ道路ネットワーク方向、時間方向のバンド幅を表す。これらのバンド幅は交通事故の発生点を中心とした影響範囲を決定するパラメータである。また、 n は標本数であり、 $K_{x_i}(x)$ 、 $K_{t_i}(t)$ はそれぞれネットワークカーネル、時間カーネルを表すカーネル関数である。STN-KDE では、それぞれの方向に独立したカーネルの積を足し合わせ、確率密度関数を推定する。

本研究では、ネットワークカーネルに Okabe らの提案した等分割カーネルを採用する。等分割カーネルは交差点における過大評価の問題が考慮されたカーネルである。なお、この問題を考慮したカーネルには、等分割連続カーネルもあるが、本研究では、計算コストが低く、実用的であるとされる等分割カーネルを採用する。等分割カーネルは次の式 (4.6) で定義される。

$$K_{x_i}(x) = \frac{k(d_x(x_i, x)/h_x)}{h_x(n_1 - 1)(n_2 - 1) \cdots (n_s - 1)} \quad (4.6)$$

ここで、 $k(d_x(x_i, x)/h_x)$ はバンド幅 h_x のベースカーネルを表す。KDE を拡張した手法において、複雑なカーネルは基本となるカーネル関数が拡張される形で定義されることが多い。この基本となるカーネル関数をベースカーネル (base kernel) という。ベースカーネルの引数に与えられている $d_x(x_i, x)$ は事故地点 x_i から地点 x までの最短経路距離であり、この経路距離に基づいて重みが計算される。

分母の項は重みを枝分かれた道路の本数で分割することを表している。 n_1, n_2, \dots, n_s は、事故発生点 x_i から地点 x までの最短経路上に存在する交差点の次数、すなわち接続している道路の本数を表す。カーネルは事故地点を中心に広がるように重み付けをおこなう。そのため、交差点では一方向から進入し、出ていく道路の本数だけ分割する必要がある。したがって、 j 個目の交差点での分割数は $n_j - 1$ ($j = 1, 2, \dots, s$) となる。さらに、経路上の各交差点で重みが順に分割されるため、分母にはこれらの積が含まれる。

ネットワークカーネルのベースカーネルには、エパネチニコフカーネル (Epanechnikov kernel) を採用する。KDE でよく用いられる 2 種類のカーネルとして、ガウシアンカーネルとエパネチニコフがある。これらの形状を図 4.26 に示す。なお、図中のカーネルの形状では、バンド幅は 1、中心は 0 に設定している。また、これらの特徴をまとめた表を??に示す。




図 4.26 カーネルの形状

表 4.10 エパネチニコフカーネルとガウシアンカーネルとの比較

	エパネチニコフカーネル	ガウシアンカーネル
カーネル関数の定義	$K(x) = \frac{3}{4}(1 - x^2) \quad (x \leq 1)$	$K(x) = \frac{1}{\sqrt{2\pi}}e^{-x^2/2}$
考慮される範囲	バンド幅 h までの範囲 (有限)	対象領域の全域 (無限)
計算量	少ない	多い
滑らかさ	滑らか	非常に滑らか
バンド幅が 1 のときのピーク値	0.75	0.45

エパネチニコフカーネルはガウシアンカーネルと同様に標本を中心に滑らかに広がるカーネルである。一方、ガウシアンカーネルが無限に広がるのに対し、エパネチニコフカーネルはバンド幅 h の範囲内 $|x| \leq h$ でのみに影響する。加えて、双方共に面積は 1 に正規化されていることから、エパネチニコフカーネルはガウシアンカーネルよりも高いピーク値を持つ。

これらのカーネルは分析対象とする事象の特性や推定の目的に応じて使い分けられる。対象とする事象に

ついて全く事前知識がない場合には、空間全体に広がるガウシアンカーネルが用いられる。一方、エパネチニコフカーネルはバンド幅の範囲にまで重み付けることから、事象の影響範囲が限定されている場合に適する。空間分析では、その事象が無限遠の位置まで影響を及ぼすことは現実的でないと考えられるため、エパネチニコフカーネルがよく用いられる。本研究が対象とする交通事故も、その影響範囲は同じ交通環境を持つ範囲と考えられる。したがって、エパネチニコフカーネルを採用する。

また、エパネチニコフカーネルは計算コストが低いという利点もある。道路ネットワークを対象とした KDE では、影響範囲に対する経路探索が必要となるが、ガウシアンカーネルの場合、対象領域全体を探索する必要がある。一方、計算範囲がバンド幅に限定されているうえ、その値の計算も単純な二次関数で定義されているから、計算コストが低く、本研究の用途に適しているといえる。

時間カーネルは式 (4.7) として定義される。

$$K_{t_i}(t) = \frac{k(d_t(t_i, t)/h_t)}{h_t}, \tag{4.7}$$

ここで、ネットワークカーネルと同様に $k(d_t(t_i, t)/h_t)$ はバンド幅 h_t のベースカーネルを表す。ベースカーネルには、ネットワークカーネルと同様にエパネチニコフカーネルを採用する。時間方向は道路ネットワークのように交差点が存在しないため、単純な 1 次元カーネルと同様にして計算をおこなう。

また、本研究では、境界効果を考慮して、ネットワークカーネルを補正する。境界効果 (boundary effect) とは、KDE で分析対象とする領域の端において、カーネルの一部が領域外に出てしまうことで、推定値が過小評価される現象をいう。道路ネットワークでは、次数が 1 のセグメント、すなわち行き止まりの道路付近で、この現象が発生しやすい。なお、時間方向には端が存在しないため、境界効果は発生しない。

境界効果の対策については、様々な手法が提案されているが、本研究では Diggle の提案した手法を採用する [73]。具体的には、図 4.27 に示すように、カーネルの一部が領域外に出てしまう場合に、その分だけカーネルを大きくすることで、この問題を解決する。




図 4.27 境界効果を考慮したカーネルの補正

図の左側はカーネルの一部が領域外にはみ出した状況を示している。本来は一つのカーネルはその面積が 1 となるが、領域外にはみ出した部分があるため、領域内での面積は 1 未満となってしまう。そこで、図の右側に示すように、領域内に存在するカーネルの面積を計算し、その逆数をカーネルに掛けることで、領域内での面積が 1 となるように補正する。

この補正は式 (4.8) として定式化される。

$$S_{x_i} = \int_L K_{x_i}(x) dx \tag{4.8}$$

$$K'_{x_i}(x) = \frac{1}{S_{x_i}} K_{x_i}(x)$$

ここで、 $K_{x_i}(x)$ は補正前のネットワークカーネル、 $K'_{x_i}(x)$ は補正後のネットワークカーネルを表す。また、 S_{x_i} は領域内に存在するカーネルの面積、 L は x を中心として、最短経路距離がバンド幅以内となる道路ネットワーク上の領域を表している。このようにネットワークカーネルを補正することで、全体としてより正確な事故リスクの推定を実現する。

モンテカルロシミュレーションに基づくホットスポットの検出

Xie らは道路ネットワークを対象とする Net-KDE により推定された事故リスクを用いて、各セグメントのローカルモラン統計量を計算した。そして、仮説検定によりそれらの値が統計的に有意であるかを評価し、有意なセグメント群をホットスポットとして検出した [65]。

本研究ではこれと同様に、STN-KDE における各時空間セグメントに対して、この手法を適用する。ローカルモラン統計量の計算は KDE の前提条件の検証と同じ、時空間的自己相関を測るように拡張したものを用いる。本研究で得られるホットスポットは時空間ネットワークを対象とするため、場所だけでなく時間においても、事故リスクが有意に高いことを意味する。

ローカルモラン統計量を用いた仮説検定には、z-score に基づくものと、モンテカルロシミュレーションに基づくものが存在する。z-score を用いた手法はローカルモラン統計量が正規分布に従うことを前提としている。しかし、交通事故を対象としたローカルモラン統計量は正規分布に従わないことがすでに Moon らの実験から明かにされている [74]。モンテカルロシミュレーション (Monte Carlo simulation) はランダムなサンプリングを繰り返し実行することで、ある範囲の結果が発生する可能性を評価する手法である。このモンテカルロシミュレーションに基づきローカルモラン統計量をサンプリングする方法は、正規分布を仮定する検定と比較して、ロバストな結果が得られることが確認されている [65]。そのため、本研究では、モンテカルロシミュレーションに基づく手法を採用する。

本研究では、アルゴリズム 2 に基づき、ホットスポットの検出をおこなう。本手法では、得られた事故リスクの時空間的自己相関が偶然のものでないことを検定する。そのため、まず観測された事故地点から事故リスクのローカルモラン統計量を算出する。各事故発生点 p を時空間的に最も近いセグメントで発生したものととして、セグメントごとの事故件数 c_i をカウントし、事故件数の分布 \mathbf{C} を構築する。次に、この事故件数の分布 \mathbf{C} から、STN-KDE により事故リスク \hat{f} を推定する。推定された事故リスクの分布 \hat{f} は各セグメントに事故リスクが割り当てられている。この事故リスクの時空間的自己相関をローカルモラン統計量 I_i として算出する。

さらに、モンテカルロシミュレーションにより、疑似的な事故件数の分布を生成し、その分布に基づくローカルモラン統計量の標本分布を構築する。ここで、分布を生成するのは、各セグメントにおける事故件数が偶然その位置に配置されたものであることを帰無仮説とするためである。まず、観測された事故件数の分布 \mathbf{C} をランダムにシャッフルし、疑似的な事故件数の分布 \mathbf{C}' を生成する。このシャッフルは、各セグメントに割り当てられた事故件数をランダムに入れ替える処理を指し、事故件数が偶然その位置に配置されたものであることを表現している。そして、観測データと同様に、この疑似的な事故件数の分布 \mathbf{C}' から STN-KDE により事故リスク \hat{f}' を推定し、ローカルモラン統計量 I'_i を算出する。この処理を N_{sim} 回繰り返し、各セグメント i に対する N_{sim} 個のローカルモラン統計量からなる標本分布 \mathbb{D}_i を構築する。

そして、帰無仮説に基づく標本分布 \mathbb{D}_i と観測データから得られたローカルモラン統計量 I_i を比較し、セグメント i がホットスポットであるかを判定する。標本分布 \mathbb{D}_i の $1 - \alpha$ 分位点を p 値として計算する。セグメント i の時空間的性質が HH であり、かつローカルモラン統計量 I_i がこの p 値よりも大きい場合、帰無仮説は棄却され、セグメント i はホットスポットであると判定される。ここで帰無仮説が棄却されることは、セグメント i における事故リスクの時空間的自己相関が偶然によるものではないことを意味する。なお、時空間的性質が HH であるのに限定する理由は、本研究で関心のあるホットスポットが、事故リスクが高いセ

アルゴリズム 2 ホットスポットを検出するためのモンテカルロシミュレーションに基づく仮説検定

```

function DETECT-HOTSPOTS-MONTECARLO( $\mathbb{P}$ ,  $N_{\text{sim}}$ ,  $\alpha$ ) returns  $\mathbb{S}$ 
   $\mathbf{C} := \{c_1, c_2, \dots, c_n\} \leftarrow \mathbf{0}$                                 ▷ 疑似的に生成された事故件数の分布
   $\mathbb{D} := \{\mathbb{D}_1, \mathbb{D}_2, \dots, \mathbb{D}_n\} \leftarrow \mathbf{0}$                                 ▷ ローカルモラン統計量の標本分布
   $\mathbb{S} := \{s_1, s_2, \dots, s_n\} \leftarrow \mathbf{False}$                                 ▷ 各セグメントのホットスポット判定結果
  for each  $p$  in  $\mathbb{P}$  do
     $i \leftarrow \text{GET-SEGMENT-INDEX}(p)$                                 ▷ 事故地点から最も近いセグメントのインデックスを取得
     $c_i \leftarrow c_i + 1$                                             ▷ 各セグメントの事故件数をカウント
  endfor
   $\hat{f} \leftarrow \text{STN-KDE}(\mathbf{C})$                                         ▷ STN-KDE により事故件数から事故リスクを推定
  for  $i \leftarrow 1$  to  $n$  do
     $I_i \leftarrow \text{LOCAL-MORAN}(\hat{f})$                                 ▷ 各セグメントのローカルモラン統計量を計算
     $T_i \leftarrow \text{CLASSIFY-CLUSTER}(I_i)$                                 ▷ 各セグメントの時空間的性質 (HH, HL, LH, LL) を判定
  end for
  for  $j \leftarrow 1$  to  $N_{\text{sim}}$  do
     $\mathbf{C}' \leftarrow \text{SUFFLE}(\mathbf{C})$                                     ▷ 事故件数の分布をランダムにシャッフル
     $\hat{f}' \leftarrow \text{STN-KDE}(\mathbf{C}')$                                 ▷ STN-KDE により疑似的な事故リスクを推定
    for  $i \leftarrow 1$  to  $n$  do
       $I'_i \leftarrow \text{LOCAL-MORAN}(\hat{f}')$                                 ▷ ローカルモラン統計量を計算
       $\mathbb{D}_i \leftarrow \mathbb{D}_i \cup \{I'_i\}$                                 ▷ ローカルモラン統計量の標本分布に追加
    end for
  end for
  for  $i \leftarrow 1$  to  $n$  do
     $p \leftarrow \text{QUANTILE}(\mathbb{D}_i, 1 - \alpha)$                                 ▷ ローカルモラン統計量の  $p$  値を計算 ( $1 - \alpha$  分位点)
    if  $T_i = \text{HH}$  and  $I_i > p$  then
       $s_i \leftarrow \mathbf{True}$                                             ▷ セグメント  $i$  はホットスポットであると判定
    end if
  end for
  return  $\mathbb{S}$                                                     ▷ 各セグメントのホットスポット判定結果を返す
end function

```

グメントであるためである。HL のセグメントもホットスポットになり得るが、ホットスポットの検出を目的とする研究では、より顕著に事故リスクが高い HH セグメントに注目することが一般的であり、本研究も同様である。

さらに、Xie らはホットスポットの検出において異なる仮説に基づく 2 種類のモンテカルロシミュレーションを実施している [65]。それぞれのモンテカルロシミュレーションでは、疑似的な事故件数分布を生成する SUFFLE 関数の内容が異なる。本研究でも同様に、次の 2 種類を実施する。

- 完全ランダム化 (complete random) : 各セグメントの事故について「ランダムに発生した場合の一例に過ぎない」という帰無仮説 H_0^c を仮定するものである。この仮定に基づくシミュレーションでは、すべてのセグメントに割り当てられた事故件数をシャッフルする。
- 条件付きランダム化 (conditional permutation) : 各セグメントの事故について「過去に事故の発生し

た地域の一例に過ぎない」という帰無仮説 H_0^b を仮定するものである。この仮定に基づくシミュレーションでは、事故件数が0でないセグメント同士でのみ、事故件数をシャッフルする。

これらの方法から交通事故のホットスポットを検出する。そして、得られたホットスポットから、本手法の有効性を評価する。

4.4.4 ホットスポットの検出と評価

本研究では、2015年から2020年までの愛知県の交通事故データから、ホットスポットを検出した。本手法では、事故の発生場所と時刻を使用するため、交通事故データのうち、事故位置の緯経度、発生時刻（0から23までの整数値）のみを使用した。また、次の8つの行政区域を対象とした。これらは道路延長1kmあたりの事故件数が多い地域であり、ホットスポットの検出に適していると考えられるためである。

- 名古屋市中区
- 名古屋市千種区
- 名古屋市東区
- 名古屋市熱田区
- 名古屋市中村区
- 大治町
- 名古屋市区
- 愛西市

分析する範囲は各行政区域の役所あるいは役場を中心として、東西に6.5km、南北に4.5kmの範囲とした。役所、役場は市民のアクセス性が考慮された位置に建てられており、一定量の道路が対象領域に含まれると考えられる。時空間ネットワークにおけるセグメントの大きさは、道路ネットワーク方向に20m、時間方向に1時間とした。道路ネットワークの大きさが大きいと、地図へ可視化した際にセグメントの境界が強く表れてしまう。そのため、推定された分布の変化が連続的に見える程度の大きさとしている。また、時間方向の大きさについては、交通事故データの粒度に依存したものである。愛知県の交通事故データは発生時刻が1時間単位で記録されているため、時間方向のセグメントの大きさも1時間としている。

以降、一連の実験内容は交通事故データ分析システムで利用可能なように、**pavement** というRパッケージとして実装した [75]。これを用いて、実験の再現が可能である。pavement では、道路ネットワークをOpenStreetMapから取得し、Net-KDEやSTN-KDEによる事故リスクの推定、ホットスポット検出、およびその可視化機能を提供している。

KDEの前提条件を満たしているかどうかを検証するため、各行政区域、各年のデータをセグメントごとに時空間的自己相関を測定し、仮説検定を実施した。その結果、すべての地域のほとんどのセグメントで、帰無仮説が棄却され、KDEの前提条件を満たしていることが確認された。表4.11に、各行政区域におけるKDEの前提条件を満たすセグメント群とそれらに含まれる事故の数および割合を示す。

表4.11に示したとおり、各行政区域における有効なセグメント数は全体の86%以上を占める。つまり、ほとんどの地域は事故件数の分布に一定の傾向を持ち、その時空間的性質が年々、ランダムに変化していることはないことが確認された。また、交通事故件数については、STN-KDEの前提条件を満たしているものが59%以上を占めることも明らかとなった。よって、半数以上の交通事故は毎年同じような時間、場所で発生しているといえる。

一方、愛西市のように全事故件数の少ない地域では、有効な事故件数が少ないことも確認できる。これは有効なセグメントの多くが事故の発生していない道路であることを示している。また同時に、事故の発生した道路のいくらかはランダムな傾向を持つものと判定されたことになる。このように特定の傾向を持たないことの本質的な理由は、本研究のデータから明らかにすることはできないが、一般に全事故件数の少ない地域は、その人口、交通量も少ないことから、本来はリスクのあるセグメントにおいても、パターンとして表れるほど、事故発生につながる、車両が交錯する機会がなかったことが考えられる。

表 4.11 行政区域ごとの有効な事故件数とセグメントの件数および割合

行政区域名	全セグメント数	有効なセグメント数	全事故件数	有効な事故件数
名古屋市中区	1,001,088	900,311 (89.933 %)	15,276	11,462 (75.0 %)
名古屋市東区	992,496	891,244 (89.798 %)	13,449	10,008 (74.4 %)
名古屋市中村区	979,656	882,157 (90.048 %)	10,301	7,679 (74.5 %)
名古屋市西区	993,432	892,426 (89.833 %)	10,759	7,933 (73.7 %)
名古屋市千種区	831,600	820,299 (98.641 %)	5,766	4,651 (80.7 %)
名古屋市熱田区	961,848	836,322 (86.949 %)	7,616	5,063 (66.5 %)
大治町	859,272	765,065 (89.036 %)	4,573	3,188 (69.7 %)
愛西市	684,024	648,521 (94.810 %)	1,139	679 (59.6 %)

そして、これらの仮定を満たしていないセグメントは対象データから除外した。これらの件数は全体の半数未満であり、大域的な事故リスクの推定、ホットスポットの検出への影響は限定的であると考えられる。ただし、全事故件数の少ない地域では、有効な事故件数が少なくなることから、得られる結果の信頼性も十分でない可能性も考えられる。このような地域が持つ、密度が疎なデータに対し、どのように事故リスクを推定すべきかについては、今後の課題としたい。

次に、提案した時空間カーネルの効果を確認するために、従来のカーネルを用いた STN-KDE と比較した。図 4.28 はそれぞれのカーネルを用いて推定した事故リスクを可視化したものである。

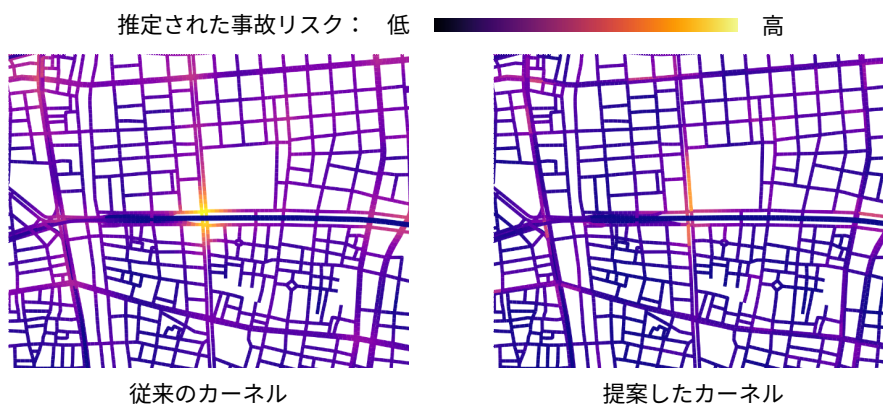


図 4.28 従来のカーネルと提案したカーネルを用いた事故リスクの比較 (名古屋市中区の一部地域)

各図の中心付近には事故リスクの高い交差点が位置している。左図に示した従来のカーネルを用いた場合、この交差点付近での事故リスクが高く評価されており、強く明るくなっていることがわかる。しかし、この評価は他の道路に比べると、過大なものとなっている。他の交差点についても、地図全体からそれらが強調されるように、事故リスクが分布してしまっている。これに対し、提案したカーネルでは、交差点付近での事故リスクが適切に分散されている。したがって、交差点だけが事故リスクのある場所ではなく、周辺の道路にも事故リスクが存在していることが示されている。このことから、提案したカーネルによる推定からは現実的な分布が得られていると考えられる。

STN-KDE により推定された事故リスクを用いて、各行政区域におけるホットスポットを検出した。その結果の一例として、名古屋市中区における事故地点の分布とそこから検出されたホットスポットを図 4.29 に

示す。

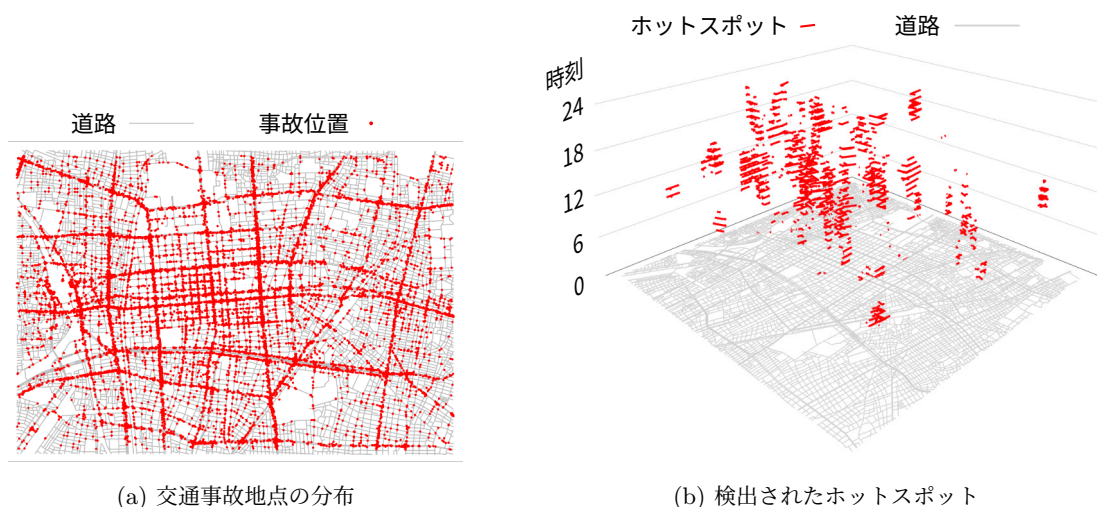


図 4.29 名古屋市中区における事故分布とホットスポットの検出結果

可視化した結果から、ホットスポットの位置はその地域の交通に関する傾向が反映されていることを確認した。図 4.29(a) では、交通事故の件数が非常に多いことはわかるものの、その分布の傾向を把握することは困難である。一方、図 4.29(b) では、ホットスポットが 3 次元的に示されており、交通事故が多発している場所と時間帯を特定できる。この図では、水平方向に道路ネットワーク、垂直方向に時間を表している。結果から、名古屋駅のある中心部の日中にホットスポットが多く検出された。これはこの時間帯に駅を中心に、多くの人が移動していることが事故が多発していることに影響していると考えられる。

また、本研究ではパラメータの検討として、狭いものと広いものの 2 種類のネットワークバンド幅、完全ランダム化と条件付きランダム化の 2 種類のモンテカルロシミュレーションの、計 4 通りの組み合わせでの実験結果を比較した。その結果、広いネットワークバンド幅で、条件付きランダム化を用いた場合には、実用的なホットスポットが検出されることが確認された。

各実験の条件とホットスポットとして判定されたセグメントの数を表 4.12 に示す。各実験では、250 m と 100 m の 2 種類のネットワークバンド幅と、完全ランダム化と条件付きランダム化の 2 種類のモンテカルロシミュレーションを組み合わせている。特に、交通事故がどの程度まで同じ交通環境に影響されるかは明確でないため、これらの 2 種類のバンド幅を設定した。また、時間バンド幅については、交通事故の発生時間が 1 時間単位で記録されていることから、すでに十分広いため、バンド幅として設定できる最小の値として、2 時間に設定した。これらの条件の下で、ホットスポットの検出を実施した。なお、各実験で有意水準は $\alpha = 0.01$ に設定している。

表 4.12 から、完全ランダム化を用いた、実験 1, 3 では、ホットスポットとして非常に多くのセグメントが検出された。つまり、事故のあった多くのセグメントにおいて、その事故件数は全くの偶然ではないことを意味している。しかし、これらの実験結果は可視化が困難であるうえ、ホットスポットとして対象を絞れていない。そのため、完全ランダム化が置く仮定は、その条件が緩く、ホットスポットの検出条件としては十分でないことがわかった。

一方、条件付きランダム化をおこなった、実験 2, 4 では、可視化できる数のセグメントが検出された。それぞれの結果を可視化したものを図 4.30 に示す。

ネットワークバンド幅を 100 m にした実験 4 では、検出されるホットスポットが局所的なものとなり、ば

表 4.12 実験条件ごとのホットスポットとして検出されたセグメントの個数

実験条件	実験 1	実験 2	実験 3	実験 4
ネットワークバンド幅	250 m	250 m	100 m	100 m
シミュレーションの種類	完全ランダム化	条件付きランダム化	完全ランダム化	条件付きランダム化
時間バンド幅	2 時間	2 時間	2 時間	2 時間
検出されたセグメント	125,671 個	4,591 個	67,006 個	2,874 個

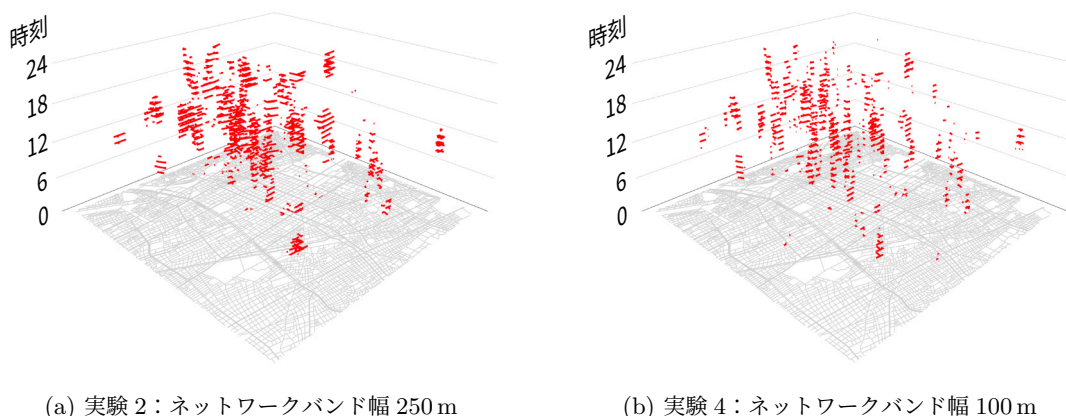


図 4.30 条件付きランダム化を用いたホットスポットの検出結果の比較

らついていることがわかる。一方、ネットワークバンド幅を 250 m にした実験 2 では、ホットスポットがより広範囲にわたって検出されており、凝集度の高い結果となっている。これらの結果から、本研究ではまとものあるホットスポットを検出するために、ネットワークバンド幅にはある程度の大きさが必要であることがわかった。

提案手法の評価のために、提案手法と従来の STN-KDE のそれぞれでホットスポットを各行政区域を対象に検出し、それらを PAI により評価した。PAI は検出されたホットスポットの面積に対し、その中で含まれる事故件数から、その検出手法の精度を測るものである。PAI は次の式 (4.9) で求められる [71]。

$$PAI = \frac{HitPercentage}{RegionPercentage} = \frac{\frac{n}{N} * 100}{\frac{a}{A} * 100} \tag{4.9}$$

ここで、*HitPercentage* は的中率といい、は対象地域内の事故件数 N に対して、ホットスポット内に含まれる事故件数 n の割合をパーセンテージで表したものである。同様に、*RegionPercentage* は面積率といい、対象地域の面積 A に対して、ホットスポットの面積 a の割合をパーセンテージで表したものである。したがって、より小さな面積に多くの事故件数が含まれるホットスポットほど、良い検出手法として PAI の値は大きくなる。特に、このようなホットスポットは人的および金銭的資源の限られた事故対策において、実用的なものであることを評価できる。なお、本研究では、時空間ネットワークを対象としているため、道路ネットワークのリンク長と時間からなる、セグメントの総面積として計算した。この計算では、道路ネットワークをセグメント化したときに発生する 20 m に満たない端数部分のセグメントも考慮した。

各行政区域において従来手法と提案手法を適用し、それぞれで検出されたホットスポットの PAI を表 4.13

に示す。結果から、提案手法の精度はすべての行政区域で従来手法を上回っていることがわかる。また、愛西市や大治町のような、事故件数が比較的少ない地域で精度が高い。これは事故件数の増加に伴い、事故要因が多様化するため、ホットスポットの検出が困難になることが影響していると考えられる。また、事故件数の多い地域は都市部となることから、交差点が多く、本研究で提案したカーネルの効果により発揮されることも影響していると考えられる。これらから、提案手法は従来手法点よりも、ホットスポットの検出に有効であることが示された。

表 4.13 従来手法と提案手法のそれぞれにより検出されたホットスポットの精度比較

行政区域名	事故件数	従来手法	提案手法
名古屋市中区	11,426	2.409	7.137
名古屋市東区	10,086	2.545	8.077
名古屋市中村区	8,839	2.586	8.748
名古屋市西区	8,101	2.534	7.427
名古屋市千種区	7,220	2.640	8.934
名古屋市熱田区	5,878	2.464	7.901
愛西市	836	4.265	9.635
大治町	3,304	2.945	9.642

さらに、これらの PAI が得られた要因を調査するために、1 時間ごとの事故件数の分布に基づき、PAI、的中率、面積率を算出した。名古屋市中区における各時間の PAI、的中率、面積率を図 4.31 に示す。




図 4.31 各時間の PAI、的中率、面積率の比較（名古屋市中区）

各時間における PAI から、提案手法はほとんどの時間において従来手法を上回る精度を持つことがわかった。一方で、1時から6時までの間では、従来手法の方が精度が高い。また、5時台には従来手法の精度が極端に上回っている。これについて、深夜から朝方にかけては、交通量が少なく、事故件数も少ないため、精度が安定していないことが考えられる。また、従来手法は面積率が小さく、的中させた事故1件あたりの影響が大きい。そのため、PAIが時間によって大きく変動している。つまり、偶然、ホットスポットに含まれた事故がこの極端に高いPAIをもたらしている可能性がある。これに対し、提案手法は的中率、面積率ともに安定して変化している。特に、朝方と夕方の通勤時間帯に面積率が大きくなることから、提案手法は事故件数に応じてホットスポットの範囲を適切に調整できていることがわかる。したがって、提案手法は事故件数がある程度以上ある場合には、従来手法よりも安定して高い精度を発揮できると考えられる。

これらの結果から、提案手法は地域によらず、事故の多い、時空間的なホットスポットを検出できることが示された。本手法は実際の事故が多く発生する場所および時間帯を特定するのに、有効であり、交通事故対策に役立つと考えられる。また、このような領域の検出はそこにどのような交通環境が存在しているかを調査するための基礎情報としても有用である。したがって、事故が発生する交通環境のモデル化にも有用であると考えられる。

4.5 環境要因との関係分析

4.5.1 交通事故における環境要因と分析の目的

交通事故はさまざまな要因が複雑に絡み合って発生する事象である。交通事故の統計や交通安全研究では、その要因は次の3つに分けられている [76]。

- 人的要因：当事者の能力や心理状態など、人に関わる要因
- 車両要因：車両の性能や整備状態など、車両に関わる要因
- 環境要因（もしくは、交通環境要因）：道路形状や気象条件など、交通環境に関わる要因

このうち、環境要因は当事者と車両の両方に影響を与え、交通事故の発生に大きく関与していると考えられる。第4.4節では、交通事故の発生しやすい場所や時間帯を特定する手法について述べた。ここで検出されたホットスポットもそれらの形成には、いくらかの環境要因が関与している可能性がある。

環境要因はまた、他の内在的な要因と異なり、比較的、収集可能なデータから読み取ることができる。また、その場所に関連付いた空間的なデータとして分析可能であるという特徴もある。従来研究では、交通環境に関するデータから、環境要因との関係分析がなされてきた。本研究においても、収集可能なデータから、環境要因に着目した分析をおこなう。これらのデータを用いた分析は、開発した交通事故データ分析システムにより可能である。

本研究では、交通事故と環境要因との関係についての理解を深めるために、この関係を空間分析や機械学習などのアプローチから、探索的に分析する。従来研究では、統計モデリングが主に用いられてきたが、これらの手法では要素間の複雑な関係を十分に捉えきれないことが示唆されている。一方、機械学習をはじめとする人工知能的なアプローチは、これらの関係を柔軟に捉えられる可能性がある。

具体的には、交通事故と環境要因との関係として、次の異なる3つの関係に着目した分析をおこなう。

- 分析 1. 交通事故の特徴の傾向と地域との関係
- 分析 2. 事故時の運転者の行動と交通環境との関係
- 分析 3. 正面衝突事故の多発箇所とその交通環境の分析

分析 1. では、交通事故の特徴の傾向をマクロな視点で捉え、従来研究でも述べられている事故要因の地域差に着目する。ここでは、地域ごとに特徴の異なる事故をどのように空間的に捉えると、各地域に対する有用な知見が得られるかを検討する。

分析 2. では、事故発生時の運転者の行動と交通環境との関係进行分析する。事故要因として計上される内容は、よそ見や漫然運転などの運転者の行動であることが多い。しかし、それらの行動は周囲の交通環境から心理的あるいは物理的に影響を受けていることが想定される。この分析では、そのような環境と行動との関係について明らかとする。

分析 3. では、ミクロな視点で、事故類型を正面衝突事故に限定し、交通環境、特に道路曲率との関係进行分析する。従来研究においても、道路幾何構造に着目した分析はおこなわれているが、正面衝突事故に特化した分析はない。この分析では、対象とする事故を限定することで、より詳細な関係を探る。

本研究では、交通事故のモデル化に向け、これらの異なる3つの分析から、環境要因との関係を明らかとする。これらの分析結果は事故がどのように発生しているかを理解するのに役立ち、モデル化の際に、考慮すべき要素やそれらの関係を特定するものと考えられる。以降では、それぞれの分析について詳述する。

4.5.2 交通事故に関する特徴的な傾向を持つ地域の検出

従来研究においても示されているように、発生する交通事故の特徴には地域差が存在する。そのため、広域に対し、画一的な分析を実施することは難しいと考えられる。これに対し、分析対象とする地域や要素を限定した分析が有効であると考えられる一方で、どのような地域や要素に着目すべきかは明らかでない場合が多い。この状況では、試行錯誤的に要素を検討するほかなく、分析に多くの時間を要してしまう。このように地域による交通環境の差は、事故分析を難しくしている要因の一つである。

そこで、本研究では、交通事故の特徴と地域との関係を明らかとすべく、発生した事故の位置と状況を表すデータから、事故の特徴が類似する地域群を検出する。この地域群では、交通環境が似ており、同じ環境要因から事故が発生していることが想定される。そのため、特定の環境要因の下で事故が発生した地域として、一つの空間的な分析単位とすることができると考えられる。

本研究では、愛知県の交通事故データを対象とする。事故の類似する地域の検出のため、愛知県を小地域に分割し、各小地域の事故傾向を機械学習モデルに学習させる。そして、学習済みモデルから、特徴の類似する地域を発見する。しかし、交通事故データをそのまま学習の入力としても、期待する結果を得るのは難しい。なぜなら、交通事故データは多くの変数を持ち、その多くがカテゴリデータとなっており、数量的に扱うことができない。また、変数には意味が重複しているものや、値に傾向がないもの、誤りや欠損などのノイズデータなども含まれている。

本研究では、このデータに関する課題を解決するため、複数の前処理から、交通事故の特徴について、特に強い傾向を持つ地域群を検出するためのデータセットを構築する。また、作成したデータの類似度から、目的とする地域群を検出するために、クラスタリングをおこなう [77]。この手法としてニューラルネットワークの一つである、自己組織化マップを用いたクラスタリングを検討する。

データセットの構築

本研究では、分類する小地域の特徴として、2つの期間の間での事故傾向の変化を扱う。愛知県における事故被害はこれまでの事故対策から低減傾向にある。そのため、2つの期間の間で事故傾向の変化が大きい地域群は、事故対策の効果が大きく表れているものと考えられる。したがって、これらの地域群を分析することで、対策のしやすい事故や対策により現れた潜在的な特徴などを明らかとできる可能性がある。

本研究では、2つの期間として2009年と2019年を対象とする。この10年間の変化を特徴量とするデー

タの分類をおこなう。分析に用いる交通事故データは、愛知県警察より提供を受けた2007年から2021年までの記録が存在する。ただし、2007年と2008年については、年間を通じたデータが揃っていない。これは事故の発生日と警察への計上日との間にタイムラグが存在するためであり、なんらかの理由から過去に発生したデータが2009年以降の計上データとして登録されていると考えられる。また、2020年以降のデータは新型コロナウイルス感染症に伴う移動制限の影響を受けており、通常交通状況を反映していないことが報告されている[78]。これらの理由から、本研究では利用可能なデータのうち、最も古い2009年と最も新しい2019年を分析対象年として採用した。

本研究では、地域の分割単位に地域メッシュを採用する。空間集計をおこなう分析では、集計単位として行政区域と地域メッシュがよく用いられる。行政区域は人々の社会的な活動単位として広く認識されているため、分析結果を解釈しやすい。また、他の統計データとの統合が容易であることが利点として挙げられる。一方、地域メッシュは均一な面積で地域を分割できるため、空間的な偏りを抑えやすいという利点がある。交通事故の傾向を対象とした場合には、行政区域を対象とすると、豊田市などの面積の広い地域では、結果の粒度が粗くなってしまうことが想定される。また、行政区域の境界は、これを跨いだときに、事故の傾向が変化するとは考えにくく、空間的な傾向を捉えるには不適切であると考えられる。これらの点から、本研究では均一な面積で地域の空間的な傾向を捉えられる地域メッシュを採用する。

また、地域メッシュには大きさの異なる複数の種類が存在するが、本研究では基準地域メッシュを採用する。基準地域メッシュは緯経度を基準に、日本全国を約1km四方の区画に分割したものである[56]。このメッシュは地域メッシュの中で3番目に細かいものであるが、名前に「基準」とあるように、国勢調査をはじめとして広い種類のデータで対応されているものとなっている。そのため、得られた結果を他のデータと統合しやすいという利点がある。また、さらに細かい地域メッシュも存在し、これを採用することで、より詳細な空間的傾向を捉えられる可能性がある。しかし、一方で各区画に含められる事故件数が少なくなり、傾向そのものを捉えられなくなってしまうことから、本研究ではこの基準地域メッシュを採用することとした。

交通事故データは天候や道路形状など、その多く項目がカテゴリデータで構成されている。これらはそのまま数量的なデータを扱う機械学習モデルの入力とすることができない。そこで本研究では、小地域内で発生した交通事故の特徴を数え上げて、その割合を算出することで、各小地域の事故傾向を数量的に表現する。さらに、2つの期間における変化を捉えるため、各特徴量を2009年と2019年でそれぞれ算出し、両期間の変化量を新たな特徴量とする。

図4.32を用いて、この特徴量の算出例を示す。この例では、ある小地域で2009年には6件の事故が、2019年には4件の事故の記録があったことを表している。各年の交通事故データには、事故発生時の天候や道路形状など、そのときの状況を説明する情報が含まれている。例えば、2009年の1件目の事故は雨天時の交差点で発生したことを表す。まずはこれらの情報に基づき、各年の各小区域に対するその特徴の割合を算出する。例えば、雨天時という特徴に注目すると、2009年には6件中4件が雨天時に発生している。そのため、この割合は約0.67(=4/6)になる。同様に2019年についても求めると、4件中2件が雨天時に発生しているため、その割合は0.50(=2/4)になる。これらから、この小地域における雨天時の事故発生割合は、2009年の0.67から2019年の0.50へと減少している。この変化をクラスタリングの入力データとする。同様にして、他のすべての事故の特徴を集計し、それぞれの変化量を算出する。

変化量は2019年の割合から2009年の割合を引いた差から表現する。降雪時のように絶対的に割合が少ない特徴では、このような計算では特徴の変化が捉えられない。そこで、比を用いた表現と差を用いた表現の2つを検討した。比を用いた場合、2009年からの相対的な値となり、絶対的には小さな変化も大きく捉えられる。なお、比を用いた計算では、2009年の件数が0件であるときに、分母が0となるために変化量を定義できない。この場合には、その特徴に該当する事故件数が大きく増加したのものとして、その特徴についての

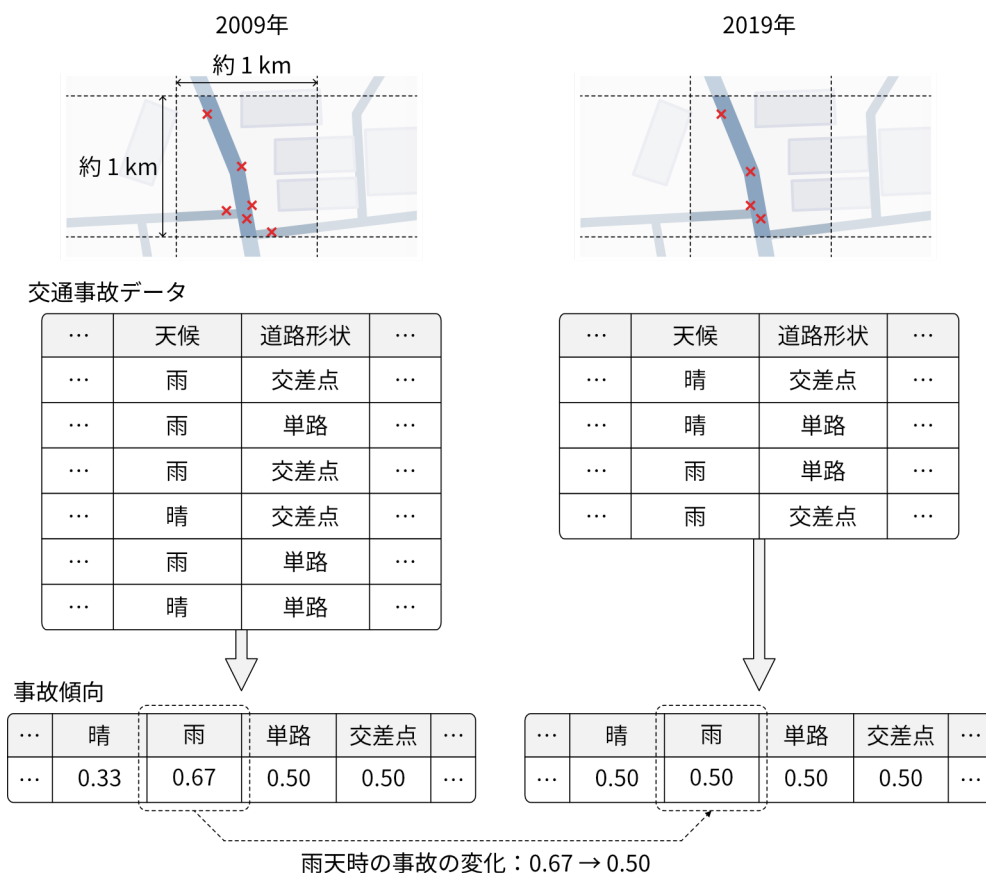


図 4.32 事故傾向の変化を表現する特徴量の算出例

最大値を割り当てる。また、2009年と2019年の両年でその特徴に該当する事故が0件であるような場合には、変化なしという意味から、特徴量を1とした。

このような条件から、2つのデータセットを構築し、クラスタリング結果を比較したところ、比を用いた結果では、検出されたクラスタが単一の特徴のみに依存して検出されてしまうことがわかった。これは比によって表現した特徴量の分布に強い偏りがあり、特定の特徴量がクラスタリングに強く影響を与してしまうためであると考えられる。一方、差を用いた場合には、そのような偏りは見られなかった。したがって、本研究では、変化量の表現として差を用いることとした。

また、小地域で発生した事故件数が著しく少ない場合、1件の事故の特徴が持つ影響が大きくなる。そのため、偶然発生した事故の特徴が結果を大きく歪めてしまう可能性がある。これを防ぐために、小地域で発生した事故件数の分布から、その第一四分位数を参考に、対象とする小地域は2009年と2019年の両年で、4件以上の事故が発生した地域に限定した。これを満たす小地域は1,620個存在する。対象とする地域を図4.33に示す。

このように特徴量を設計すると、各項目が取り得るカテゴリの種類だけ、データの次元数が増加してしまう。当事者の情報も含めると元の交通事故データの項目は50個以上あるため、このように集計すると、特徴量の次元数は膨大な数になってしまう。そこで、本研究では各項目のカテゴリを精査し、類似する意味を持つものの類型化をおこなった。加えて、全データの1%に満たないカテゴリは得られる知見が限定的であると考え、除外した。これらの前処理から、特徴量の次元数は大きく削減できた。しかし、その次元数はま




図 4.33 2009 年と 2019 年の両年で 4 件以上の事故が発生した基準地域メッシュ（愛知県）

だ 100 を超えており、これをクラスタリングしても、学習の収束や解釈が困難であることが想定される。

そこで、さらに空間的自己相関に基づく特徴選択をおこなう。分析結果として得られる類似する地域群は、空間的に連続していることが望ましい。なぜなら、空間的に連続した地域群は、共通する交通環境を特定しやすいと考えられるためである。また、一般に交通環境には地形や都市構造などの空間的な傾向が存在すると考えられる。これらのことから、空間的に連続する地域群を得るために、空間的自己相関指標であるモランの測度 I を用いて、各特徴量の空間的自己相関を評価し、その値が高いものを選択する。

モランの測度 I は、ある変量が空間的にどの程度自己相関を持つかを表す指標である [79]。局所的な空間的自己相関を測るグローバルモラン統計量とは異なり、対象地域全体に対してその変量の空間的な自己相関を一つの値で表すものである。このモランの測度 I は、式 (4.10) で定義される。

$$I = \frac{n}{W} \frac{\sum_{i=1}^n \sum_{j=1}^n w_{ij} (x_i - \bar{x})(x_j - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (4.10)$$

ここで、 n は小地域の数、 x_i 、 x_j は小地域 i 、 j における変数の値、 \bar{x} はその平均値、 w_{ij} は地域 i と j の空間的な重み、 W はすべての空間的な重みの和である。このモランの測度 I は -1 以上 1 以下の値をとる。 $I > 0$ の場合、値が大きいくほど近接関係にある小地域間の属性値が類似していることを表す。逆に $I < 0$ の場合、値が小さいほど近接関係にある小地域間の属性値が離れていることを表す。また、 I が 0 に近い場合、対象の空間分布はランダムな分布であることを表す。

なお、重み係数には、クイーン型の 2 進的重み係数を採用する。この重み係数では、上下左右斜めの 8 方向に隣接する小地域を隣接地域として扱うものである。事故の特徴はその位置関係が斜めであるかは重要でない。そのため、斜めの隣接関係を含み、より多くの小地域との類似性を考慮できるクイーン型を採用する。

モランの測度 I を計算した結果から、値の大きい上位 10 個の特徴量を使用する。これらの特徴とそのモランの測度 I を表 4.14 に示す。

選択された特徴には、道路形状に関するものが多く含まれている。これは空間的自己相関の性質から、道路が複数の小地域を跨いで、連続して存在しているためであると考えられる。本研究では、これらの特徴を含む、事故傾向の変化を表すデータセットを自己組織化マップの学習に用いる。

自己組織化マップを用いたクラスタリングの検討

本研究では、事故傾向の類似する地域群を検出する手法として、自己組織化マップに基づくクラスタリングの有効性を検討する。自己組織化マップ (SOM: self-organizing map) とは、T. Kohonen によって提案された高次元のデータを視覚化するための手法である。また、ニューラルネットワークの一種であり、高次

表 4.14 選択された空間的自己相関の強い特徴

特徴名	意味	モランの測度 I
晴天	晴天下で発生した事故	0.123
県道	県道で発生した事故	0.111
中交	中規模の交差点で発生した事故	0.0910
狭路	狭い道路で発生した事故	0.0902
広路	広い道路で発生した事故	0.0778
歩道	歩道上で発生した事故	0.0725
前方	前方不確認から発生した事故	0.0692
漫然	漫然運転から発生した事故	0.0575
発進	車両発進時に発生した事故	0.0521
徐行	車両速度が 10 km/h 以下の事故	0.0462

元のデータの特徴を2次元空間へ写像する手法としても知られている [80]。入力空間と出力空間の二層のみからなるニューラルネットワークのモデルで、マップ空間と呼ばれる出力空間は、格子状に配置された複数のユニットから構成される。自己組織化マップの学習では、元のデータの位相関係をこのユニット群に少しずつ反映させ、入力データを2次元空間に写像する。

自己組織化マップによって写像されたデータは、元のデータの位相関係を維持し、類似するデータは近くのユニットに配置される。そのため、クラスタリングの前処理として有効であることが知られている。また、2次元空間に写像されることから、データやクラスタの可視化にも適している。クラスタリングでは、元のデータを対象にする代わりに、ユニットの特徴空間上での座標を用いておこなわれる。各データが属するユニットがクラスタに分類されることで、元のデータは間接的にクラスタリングされる。この手法は高次であるために特徴を捉えるのが難しいデータのクラスタリングにおいて、その効果を発揮することが知られている [80]。また、地理空間データへの応用例は多くはないが、環境学の分野でその有用性が報告されている [81]。

本研究では、事故傾向の変化を入力データとして、自己組織化マップを学習させる。そして、その出力を用いてクラスタリングをおこなう。この流れを図 4.34 に示す。まず、前述した前処理を経て、交通事故データから事故傾向の変化を表すデータセットを構築する。このデータはそれぞれの小地域に対応し、複数の数値から表現されたベクトルデータとなっている。自己組織化マップでは、これらのベクトルデータを入力として、マップ空間との対応関係を学習する。

学習では、まずランダムに初期化されたマップ空間に対し、入力データを一つずつ順番に入力する。マップ空間は与えられた入力データに最も類似度の高いユニットとその周囲のユニットが反応し、それらのユニットが持つコードブックベクトルが入力データに近づくように更新される。コードブックベクトルとは、各ユニットに属するデータを代表するベクトルであり、自己組織化マップではこのコードブックベクトルが対象のデータに合わせて変化することで、データの特徴を捉える。また、入力データとコードブックベクトルとの類似度には、ユークリッド距離を用いる。すべてのデータを学習した後も、マップが安定するのを目指して、再度1件目のデータから順に学習し、これを繰り返す。このような学習において、データが1巡するのを1エポック (epoch) と呼ぶ。マップが安定するまでに何エポック必要であるかは入力により異なる。本研究では、100 エポック学習を進めるたびにその結果を取り出し、確認することとした。

次に、学習が完了したマップ空間を用いて、クラスタリングをおこなう。このクラスタリングでは、各ユ

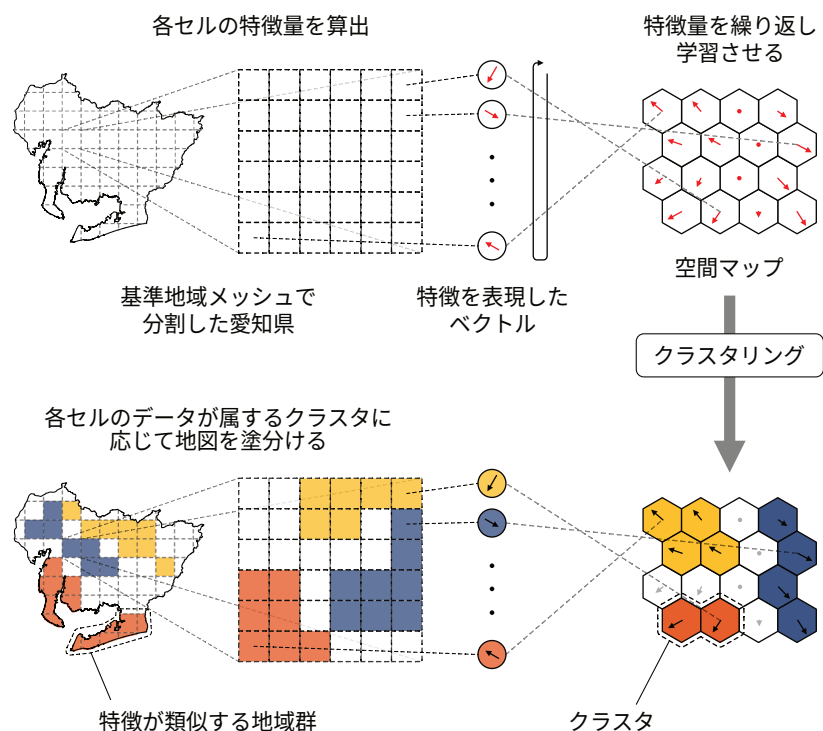


図 4.34 自己組織化マップによるクラスタリングを用いた地域群の検出の流れ

ニットのコードブックベクトルの類似度を用いる。クラスタリング手法には、ワード法による階層的クラスタリングをおこなう。この方法では、クラスタの凝集度を考慮し、クラスタ中心からクラスタに属する各データまでの平方和が最小となるように各コードブックベクトルをクラスタに合併していく。また、階層的クラスタリングでは、あらかじめクラスタ数を指定する必要があるが、このクラスタ数は複数のものを試し、それらの結果から判断することとする。

そして、クラスタリングされたユニットに基づき、各小地域をクラスタに分類する。また、各データが属するクラスタに基づいて、地域を塗分け、特徴が類似する地域を発見する。

自己組織化マップでは、マップ空間にローブ状、球状などさまざまな形状が採用される。マップ空間の形状はデータの位相関係を捉えるためのものであり、学習の収束や精度に影響する。本研究では、トーラス状の六方格子を採用する。六方格子は六角形を並べたハニカム状の格子形状である。一般的な正方形を用いた正方格子では、斜めに位置するユニットとの距離が上下左右のユニットとの距離と比べ、長くなり、不均一になる。しかし、六方格子ではすべてのユニット間の距離が均一であり、学習にゆがみが生じにくい。また、隣接するユニット数が多く、密度が高いことから、少ないユニット数でより多くのデータの位相関係を捉えられる利点を持つ。さらに、マップ空間の端で隣接するユニットの数が少なくなることから、学習結果に偏りが生じるのを防ぐために、端同士を接続したトーラス状の六方格子を採用する。

また、マップ上のユニットの数は、縦横にそれぞれ 14, 16 個の計 224 個とした。自己組織化マップでは対象のデータの特徴を捉えるのに、 $5\sqrt{n}$ 個のデータが必要であるとされている。ここで、 n は入力データの数である [80]。また、マップ空間の縦横の比は、入力データの第 1, 第 2 主成分の固有値の比に合わせるの

が望ましいとされている。これらから、縦横のユニット数は式(4.11)のように計算できる。

$$m = 5\sqrt{nm_1} = \sqrt{m\sqrt{\frac{\lambda_2}{\lambda_1}}n_2} = \sqrt{m\sqrt{\frac{\lambda_1}{\lambda_2}}} \quad (4.11)$$

ここで、 n_1 、 n_2 はマップ空間の縦横の比 λ_1 、 λ_2 は各主成分の固有値である。本研究では、この式に対象のデータを当てはめ、縦横のユニット数を決定した。

自己組織化マップのパラメータとして、コードブックベクトルの更新では、どのように重みを与えるかを設計できる。本研究では、特徴空間におけるコードブックベクトルが張る空間を滑らかなものとするため、ガウシアン型の近傍関数を採用する。この近傍関数では、最も類似度の高いコードブックベクトルを持つユニットを中心に、その周囲のユニットへ正規分布に従い、重みを与える。

本研究では対象とするデータが1,620個、次元数が10次元、ユニット数が224個と実験規模が大きい。そのため、この学習には非常に時間がかかることが想定される。そこで、本研究ではここまで述べた自己組織化マップを並列して計算できるように拡張されたアルゴリズムである並列バッチ自己組織化マップ (parallel batch self-organizing map) を用いる [82]。実装上は自己組織化マップとその拡張アルゴリズムを提供する R パッケージ、**kohonen** を用いる [83]。このアルゴリズムでは、自己組織化マップの基本的な流れは同じであるが、コードブックベクトルの更新を1エポック分まとめて実行する点で異なる。また、各スレッドは1エポック分の学習を進め、その差分を蓄積する。全体の学習が完了した後に、全体の差分を集約し、コードブックベクトルをまとめて更新する。これにより、複数のスレッドで学習を並列化でき、大規模なデータの学習が比較的高速に実行できるようになっている。

これらの方法から、事故傾向の変化を自己組織化マップに学習させる。そして、得られたユニット群のクラスタリングから、類似する地域群を検出し、可視化する。

クラスタリングの結果

自己組織化マップが事故傾向の変化を捉えるのに適しているかどうかを確認するため、本研究では、**k-means** 法によるクラスタリングと比較した。なお、**k-means** 法では、作成したデータセットを直接クラスタリングする。本研究では、最終的にクラスタの解釈性の高さから、クラスタ数を4に設定した。両手法によるクラスタリング結果を図4.35に示す。なお、AからDのクラスタの記号は属する小地域の数に付与しており、各手法で対応はない。

自己組織化マップでは、多くの小地域がクラスタAに属し、局所的にクラスタB、C、Dに属する小地域が分布する結果となった。これはクラスタAが全体の平均的な事故傾向を表し、クラスタB、C、Dが特定の事故傾向を持つ地域群を表していると考えられる。一方、**k-means** 法では、このような小地域の数への偏りはみられなかった。また、名古屋市が位置する一部地域にはクラスタAに属する小地域が固まっているものの、他の地域においては各クラスタに属する小地域が混ざり合うように分布している。このことから、**k-means** 法では、空間的な連続性を捉えられていないと考えられる。これらの結果から、本研究では、自己組織化マップを用いたクラスタリング手法の方が、交通事故の空間的な傾向を捉えるのに適していると判断した。以降では、図4.35(a)に示した自己組織化マップによる結果について述べる。

各クラスタの事故件数の変化を図4.36に示す。この箱ひげ図では、各クラスタに属する小地域で発生した事故件数について、2009年と2019年の各年の分布を表している。クラスタごとに分布全体のずれはあるものの、いずれのクラスタにおいても、2019年の事故件数は2009年と比べて減少していることがわかる。

各クラスタの特徴量分布を図4.37に示す。ここで、すべてのクラスタにおいて、事故件数が減少していることから、特徴量の増加は事故件数の減少に伴う相対的なものである場合がある。また、特徴量が減少している場合、実際の件数では、見かけよりも減少していることに注意されたい。

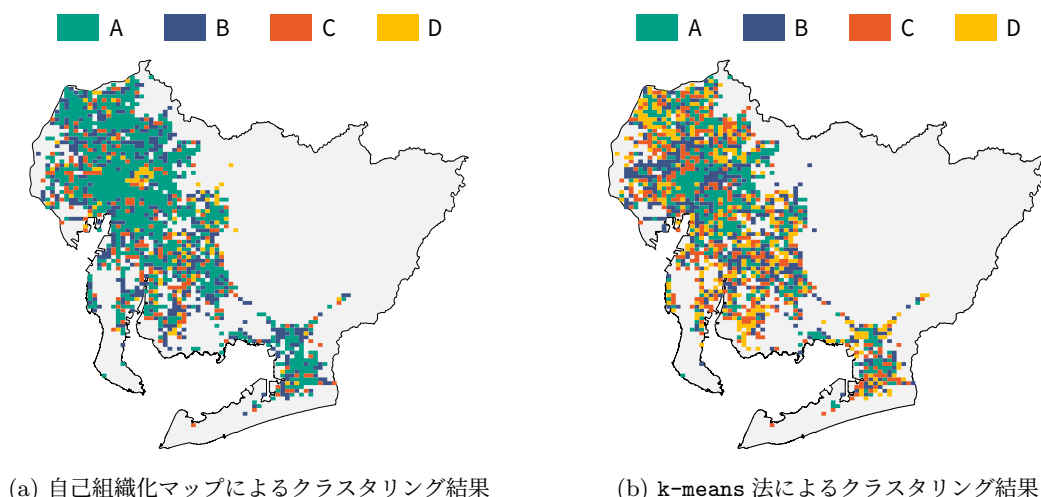


図 4.35 各クラスタリング手法におけるクラスタリング結果の比較




図 4.36 各クラスタの事故件数の変化

以降、各クラスタの特徴量分布に基づく考察を示す。クラスタ A はすべての特徴量の平均値が 0 に近い、標準的な事故傾向を示す「標準地域」である。このクラスタには最も多くの小地域が属し、互いの特徴がクラスタの中で相殺しているものと考えられる。このことから、クラスタ A は他のクラスタに分離されるほどの特徴がなく、平均的な事故傾向を示すものと考えられる。また、事故件数が減少していることを考慮すると、本研究で対象としたものにおいては、特徴に偏りなく、件数が減少した地域群であるといえる。

クラスタ B は運転者の注意が低下している「注意低下型地域」である。前方不確認による事故が約 5.5 ポイント減少した一方で、漫然運転による事故が約 9.0 ポイントも増加している。事故地点を道路地図から確認したところ、その多くは幅員の広い道路に分布していた。このことから、走行自体は安定した道路環境であるものの、周囲の景観の経年変化などにより、運転者の注意が散漫になりやすい環境となっている可能性が考えられる。

このような安全運転義務違反に起因する事故は、運転者の法令違反のうち、約 4 割を占める。また、漫然運転をはじめ、故意によるものでない場合が多い。そのため、これらの対策は難しいものとされる。一方で、前方不確認による事故が減少していることから、運転者の注意喚起を促すような交通安全施策が効果を上げ

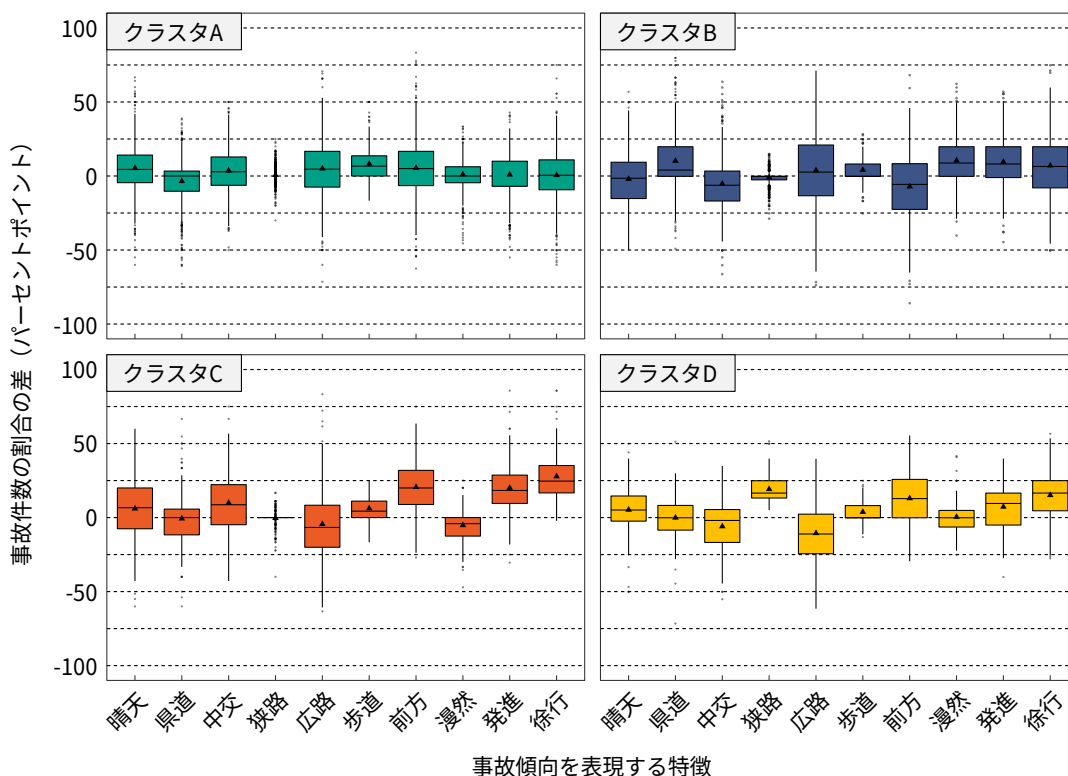


図 4.37 各クラスタの特徴量分布の比較

ている可能性が考えられる。この地域の調査から、効果的な対策を抽出できる可能性があると考えられる。

クラスタ C は車両発進時の事故傾向が強い「発進時確認型不足地域」である。「徐行」は運転者が危険から回避行動を取った速度が 10 km/h 以下であることを表すが、この事故が約 24.6 ポイントも増加している。また、前方不確認による事故が約 20.0 ポイント、車両発進時の事故が約 18.3 ポイント増加している。これらのことから、この地域群では、車両発進時に前方の車両や構造物との衝突を増加させる何らかの要因があると考えられる。

この地域について地図から調査をおこなったが、車両発進時の事故を誘引するような特定の要因は見受けられなかった。一方、小地域の断面交通量を調査したところ、これらの地域では、周辺地域と比べて交通量が少ないことが確認された。このことから、駐車に伴う発進事故の増加が考えられる。また、断面交通量が少ない場合には、単純に交通量が少ないだけでなく、渋滞が発生しやすい道路であることもある。渋滞流中においても、発進時の事故が増加する可能性があり、今後、旅行速度などから、これらを裏付ける調査が必要であると考えられる。

クラスタ D は事故地点が狭い道路へと移り変わった「^{きょうあい}狭隘道路型地域」である。この地域では、広い道路での事故が約 11.0 ポイント減少した一方で、狭い道路での事故が約 16.7 ポイント増加している。これらのことから、事故地点が広い道路から狭い道路へと移り変わった地理的要因があるものと考えられる。

クラスタ D に属する小地域は、その多くが長久手市周辺に分布している。長久手市は平均年齢が若く、人口が増加している地域であり、対象とした 2009 年から 2019 年にかけては開発が盛んに進められた。その結果、新たに住宅道路や学区が新たに整備され、事故地点における道路幅員が相対的に狭いものに変化した可能性が考えられる。近年、住宅道路や通学路を対象とした規制である「ゾーン 30」の導入が進められており、長久手市でもその取り組みがみられる [84]。こうした施策の展開は本分析結果とも整合するものといえる。

クラスタ数と学習回数については、解釈性を考慮して決定した。クラスタ数の検討として、自己組織化マップのクラスタリング結果に対し、クラスタの凝集性と分離性からクラスタの妥当性を評価する指標である DBI (Davis-Bouldin Index) を用いて、良い値を探索した。この DBI では、値が小さいほど、クラスタの凝集性が高く、分離性が良いことを表す [85]。しかし、その結果、クラスタ数を増やすほど、DBI の値が小さくなる傾向が見られた。クラスタ数と DBI の関係を図 4.38 に示す。




図 4.38 クラスタ数と DBI の関係

クラスタリングでは、クラスタ数を増やすほど、DBI の値が小さくなる傾向があるが、データにクラスタ境界がある場合には、一定のクラスタ数を堺に DBI の値が増加し、グラフに谷が形成される。本研究の結果では、図 4.38 に示したとおり、DBI は単調減少を示しており、この後も DBI の値が増加することはなかった。つまり、このデータには明確なクラスタは存在せず、DBI では判断できない曖昧なものであることを意味する。そこで、本研究では各クラスタの特徴を比較し、解釈性の高いクラスタ数を選択することとした。

学習回数については、100 エポックごとに学習結果を確認し、クラスタの特徴が安定するまで学習を進めることとした。その結果、3,000 エポックまで学習をおこなったが、学習は収束に向かうことがなく、クラスタの特徴も変化し続けた。一方で、ノイズに該当する小地域が属するクラスタを変え続けているだけで、それぞれのクラスタを特徴付ける一部の小地域はクラスタが変化していないことが確認された。これらのことから、本研究の対象データにおいては、学習回数と解釈性の高さが比例しないことが明らかとなった。

分かりやすい例として、図 4.39 は左が 300 エポックまで、右が 600 エポックまで学習した結果である。地図中の黄色で示した領域は、クラスタ D に属している地域である。学習の進行につれて、各データはクラスタとの類似度に応じて、属するクラスタを変える。そのため、300 エポックと 600 エポックの間では、クラスタ D の地域が変わっている。一方で、変化していない地域も確認できる。

これらのクラスタが変化していない地域を調査したところ、クラスタ D の特徴として強く表れていた、狭い道路での事故件数の増加量が大きい地域であることが分かった。図 4.40 は、左がクラスタの変化していない小地域群で、右が狭い道路での事故件数の変化量を示している。これらを比較すると、クラスタの変化していない小地域群は基本的に狭い道路での事故件数が大きく増加した地域であることが分かる。このように、一定のデータは安定してクラスタに属し続けていたが、クラスタ境界付近の特徴が曖昧なデータはクラスタを変え続けていた。

本研究では、自己組織化マップによるクラスタリング手法が、交通事故の空間的な傾向を捉えるのに適していることを確認した。一方で、本研究で対象とした特徴では、クラスタ境界付近のデータがいくらか存在し、それらは学習を進めても一定のクラスタに安定しないことが明らかとなった。これらのことから、クラスタ境界付近の曖昧なデータを扱う手法が必要であると考えられる。

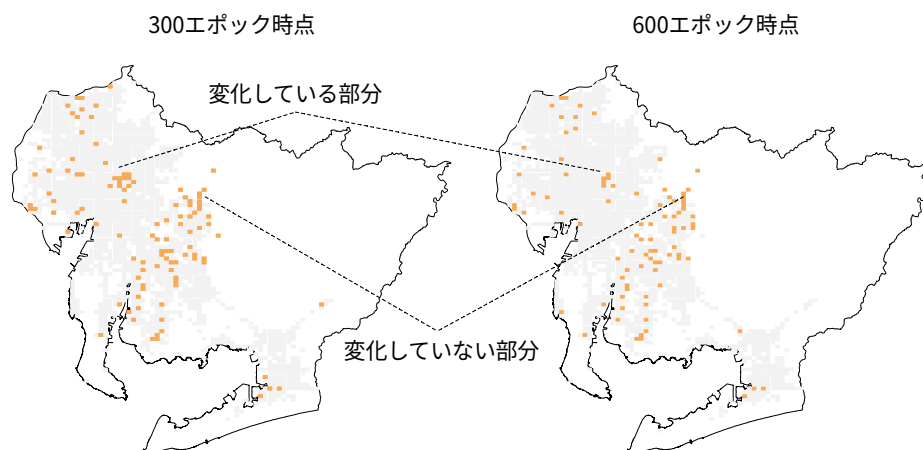


図 4.39 300 エポック, 600 エポックにおける狭隘道路型地域の比較




図 4.40 クラスタ D における変化していない地域と狭い道路での事故件数の変化量

4.5.3 空間的傾向に基づく交通環境と当事者の行動との関係分析

交通事故は運転者あるいは歩行者の行動に基づいて発生する。この行動は当事者の心理的な内部状態により決められるため、どのような事故が発生するかは当事者の状態に依存すると考えられる。また、分析のために、この当事者の状態を直接的に把握することは困難である。一方で、「曲がりづらいカーブ」「見通しの悪い交差点」のように、当事者の内部状態は交通環境から影響されており、交通環境は間接的に事故の発生を誘引するものと考えられる。

そこで本研究では、交通事故の人的要因に着目し、当事者の行動が交通環境から影響されているかどうかを事故地点の空間的傾向から明らかにすることを目的とする。交通事故データには、「人的要因」という項目で「安全確認が不十分だった」「考え事等の漫然運転」のように、事故発生に関わる当事者の行動の一部が記録されている。本研究では、このデータと事故地点から、特定の人的要因による事故が空間的に偏っているかどうかを分析する。

特定の人的要因による事故地点の偏りから、交通環境との関係をどのように分析するかを説明する。図 4.41 はある地域における脇見と前方不注意の 2 種類の事故地点の分布を示している。左の脇見による事

事故地点は特定の交差点付近に集中しており、それらの交差点では脇見を誘引するような何らかの環境的要素が存在している可能性が考えられる。一方で、右の前方不注意による事故地点は広範囲に偏りなく分布しており、どのような場所でも発生していることが考えられる。本研究では、このようにして各人的要因に空間的な偏りがあるかどうかを判断し、そこから交通環境との関係を検討する。

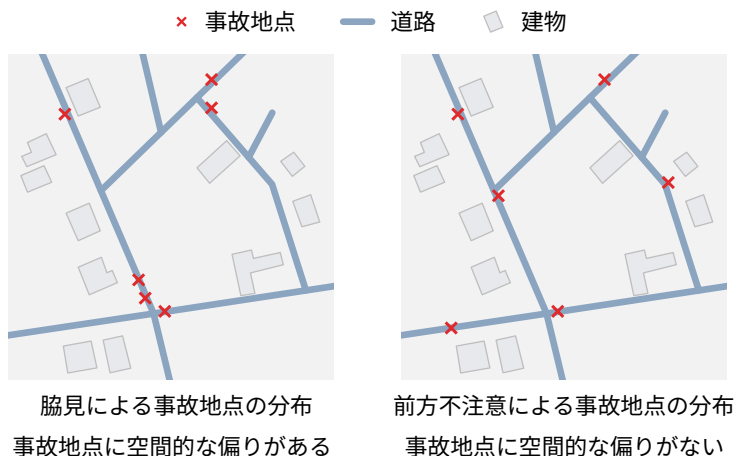


図 4.41 人的要因に空間的な偏りのある事故とそうでない事故の例

分析対象とする交通事故の人的要因

本研究では、愛知県内の各行政区域、16区37市14町2村、計69地区で発生した交通事故について、それらの第1当事者の人的要因に基づいて分析をおこなう。対象年は2007年から2021年に発生した事故であり、約53万件の事故データを用いる。

人的要因はあらかじめ定められた分類に基づき、事故データに記録されているが、その種類は非常に多い。対象データにおいては、101種類存在することを確認した。また、該当データが著しく少ない、特殊な人的要因も存在する。そのため、これらを対象とした分析では、結果の信頼性を確保することが難しい。

そこで本研究では、表4.15に示す第1当事者から記録された人的要因の割合より、データ全体の9割を占める、上位11種類の人的要因を対象とする。なお、人的要因の記述について、その先頭に「その他」とあるものは、その人的要因を含む大区分において主要な事例でないことを意味する。例えば、表中の「その他の脇見」は同表にある「風景、地物等」「他の車、歩行者」以外への脇見を指す。また、この「脇見」のように人的要因は当事者種別（車両や自転車など）やその行動（不注視、脇見など）から、似通ったものをまとめる大区分が定められているが、本研究では、これらをまとめず、それぞれを別個の人的要因として扱う。これは交通環境と人的要因との関係を考えるとき、同じ「脇見」であっても、当事者種別やその対象が異なる場合には、関わり方が異なる可能性があるためである。

事故地点の空間的な偏りの数量化

本研究では、事故地点の空間的な偏りを数量的に分析するため、モランの測度 I を用いてこれを評価する。空間的自己相関を測る指標であるモランの測度 I は、その性質から事象が対象地域において、どの程度集中しているかを評価できる。ある人的要因による事故の件数を小地域の属性値とし、モランの測度 I の値から、対象地域において事故地点がどの程度凝集しているかを測る。よって、この値の高い地域では、その地域の交通環境が運転者や歩行者の事故につながる特定の行動を引き起こしている可能性が考えられる。

表 4.15 第1当事者の記録における人的要因の件数と割合

人的要因（当事者種別）	件数 [件]	割合 [%]
安全確認が不十分であった（車両等）	245,130	46.5
その他／考え事等の漫然運転（車両等）	82,310	15.6
安全確認をしなかった（車両等）	38,197	7.25
その他の脇見（車両等）	30,238	5.74
その他特に具体的危険性がないとして注視を怠った（車両等）	23,410	4.44
風景／地物等に脇見（車両等）	20,461	3.88
他の車／歩行者に脇見（車両等）	14,011	2.66
ブレーキの踏みが弱い／踏み遅れ（車両等）	12,828	2.43
安全確認が不十分であった（自転車）	11,626	2.21
交通規制に対する認識を誤った（車両等）	11,453	2.17
物を落とした／物を取ろうとした（車両等）	9,117	1.73
上記以外の人的要因	50,562	9.60

空間的自己相関を用いた分析では、対象地域を分割した小地域を設定する必要がある。よく用いられる、グリッド状への分割では道路のない空間が生じてしまう。道路のない空間が存在すると、道路の有無に依存して、事故地点に偏りが生じ、本研究が目的とする事故地点の偏りを正しく評価できない。同様に道路の有無ができるような分割方法では、この問題が生じてしまう。

そこで本研究では、対象の空間モデルを道路ネットワークとして道路に沿った分割をおこなう。道路ネットワークを対象とすることで、道路のない空間が存在せず、事故地点の偏りを正しく評価できると考えられる。道路ネットワークのリンクを一定の長さのセグメントに分割し、それらのセグメントを小地域に設定する。また、各セグメントの付近で発生した事故の件数を人的要因ごとに属性値として持たせる。リンクを等しい長さに分割することで、空間的に集計される事故件数がセグメントの長さの違いに依存するのを避けられる。

ただし、リンクを一方から同じ長さで分割していくと、リンクの長さによっては端数の部分が生じる。この部分は他のセグメントより短く、割り当てられる事故件数が少なくなってしまう。そのため、真に等しい条件の下、事故件数を空間集計することは難しい。本研究では、この問題についてセグメントの長さがある程度短く設定することで、長さによる偏りを小さく抑えるものとする。

セグメントの属性値の計算では、各交通事故のデータをその発生地点から直線距離が最も近いセグメントへ割り当てる。それから、割り当てられた交通事故を人的要因ごとに数え上げる。この方法から、ある人的要因による交通事故が道路ネットワーク上のどこで、多く発生しているかを表す空間分布を求める。しかし、このとき例外的に道路以外の地点で発生した事故がある場合や、道路情報が欠損している地域が存在する場合には、意図しない離れたセグメントへ事故が割り当てられてしまう。

本研究では、この問題の発生を抑えるために、セグメントまでの距離が一定以上離れている事故を属性値の計算対象から外すものとする。ここでは、使用するデータの調査から、対象の交通事故が明らかに道路上で発生していないことを示す距離として事故地点とセグメントとの間の距離が20mを超える14,564件を除外する。これはデータ全体の約2.7%に相当する。なお、本研究では道路上に沿った環境との関係をみていること、またそれらの件数が少なく、分析が難しいことから、路外で発生した交通事故を分析対象から外しているが、これらは道路以外の環境との関係をみるなど、他の方法による分析が必要であると考えられる。

モランの測度 I では、小地域間の空間的な近接関係を表す重み係数を設定する必要がある。本研究では、この重み係数を経路距離に応じたものとする。ここで、この重み係数の計算コストはネットワークの規模に応じて、指数関数的に大きくなる。そのため、重み係数の設計は単純なものである方が望ましい。そこで本研究では、小地域 i, j 間の重み係数 w_{ij} を式 (4.12) に示す経路距離に応じた二次関数として定義する。

$$w_{ij} = \begin{cases} 1 - \left(\frac{d(s_i, s_j)}{h}\right)^2 & (i \neq j \text{ かつ } d(s_i, s_j) \leq h \text{ のとき}) \\ 0 & (\text{それ以外のとき}) \end{cases} \quad (4.12)$$

ここで、 s_i, s_j はそれぞれ小地域 i, j のセグメントを表し、 $d(s_i, s_j)$ はそれらの中心点間の経路距離を表す。したがって、重み係数 w_{ij} は任意のセグメント s_i を中心として、そこから経路距離 h までのネットワークに対して、中心点からの経路距離に応じて、小さくなるような値を割り当てる。また、この重み係数 w_{ij} は 0 以上 1 以下の値をとる。

仮説検定による空間的な偏りの検証

本研究では、事故地点の空間的な偏りをみるために、モランの測度 I を求める。しかし、この値のみで空間的な偏りがあるかどうかを判断することは難しい。これは事故件数が対象とするセグメントの数と比較して非常に少なく、対象地域においてその地点がいくつかの箇所へ凝集していたとしても、 I の値は小さいものとなることが想定されるためである。

そこで本研究では、対象とする地域、人的要因について「交通事故は道路ネットワーク上のランダムな位置に発生する」という帰無仮説を置き、これを棄却することで事故地点に空間的な偏りがあることを主張する。そのために、各地域、人的要因について実際と同数の事故地点を道路ネットワーク上のランダムな位置に配置し、疑似的な事故地点の空間分布を得る。そして、実際の交通事故に対して求めた測度 I と、この疑似的な空間分布に対して求めた測度 I' の比較から、測度 I が高いかどうかを判断する。

また、このとき求める測度 I' は偶然高いあるいは低い値となる可能性がある。そのため、この手順を繰り返し、複数の疑似的な空間分布に対して測度 I' を求める。そして、この得られた測度 I' の標本分布に対して、実際の交通事故における I が有意に高いかどうかを検定する。

事故地点の空間分布に対する分析結果

本研究は愛知県全域の道路ネットワークを分析対象としているため、計算規模が大きい。そこで、ネットワークを対象とした計算の実装に **pgRouting** ビジュアルライティング を採用した。pgRouting は PostgreSQL データベースの拡張の一つで、ネットワークを対象とした経路探索や距離計算を高速に実行するための機能を提供する [86]。また、地理空間データを扱うための PostGIS と組み合わせて使用することで、道路ネットワークを対象とした計算が実現できる。本研究では、PostgreSQL 12, PostGIS 3.0, および pgRouting 3.0.1 を使用した。また、ネットワークを構築するための道路データには、OpenStreetMap のデータを使用した。

セグメントの長さは 10 m, 重み係数におけるバンド幅は 100 m に設定した。この設定は同様にして道路ネットワーク上での交通事故の影響を考慮して分析している Xie・Yan の研究 (2013) の条件を参考にしたものである [65]。また、このセグメントの長さは交通事故の影響を考える上では、十分に短い。よって、リンクを分割したときに生じる端数の影響は小さく抑えられるものと考えられる。

69 の行政区域, 11 種類の人的要因の組み合わせ, 計 759 の条件の下, 疑似的な分布の測度 I' の標本分布に対する検定をおこなった結果, そのほとんどである 717 の条件で有意に高い測度 I が得られた。ここで, 疑似的な測度 I' の採取回数は 20 回, 有意水準は 1% としている。この結果から, 交通事故を発生させた人的要因, すなわち当事者の行動は交通環境と関係があることが示された。また「ブレーキの踏みが弱い/踏み遅れ (車両等)」「物を落とした/物を取ろうとした (車両等)」のように, 交通環境との関係が想定しにく

いものについても、空間分布に有意な偏りがあることが分かった。これらの結果はこのような人的要因にも、潜在的には交通環境との繋がりがあることを示唆している。

帰無仮説が棄却されなかった条件は、設楽町、東栄町などの事故件数の少ない行政区域や、比較的件数の少ない人的要因である「安全確認が不十分であった（自転車）」などであったに集中していた。これらの結果は当該条件において、データが十分になく、帰無仮説を棄却するだけの検出力がなかったものと考えられる。したがって、本研究の結果からは交通事故の人的要因は交通環境と関係があると結論づけられる。

モランの測度 I が有意に高い条件における事故地点の分布の一例として、名古屋市中区における「風景／地物等に脇見（車両等）」による事故と、「交通規制に対する認識を誤った（車両等）」による事故の分布を図 4.42 に示す。

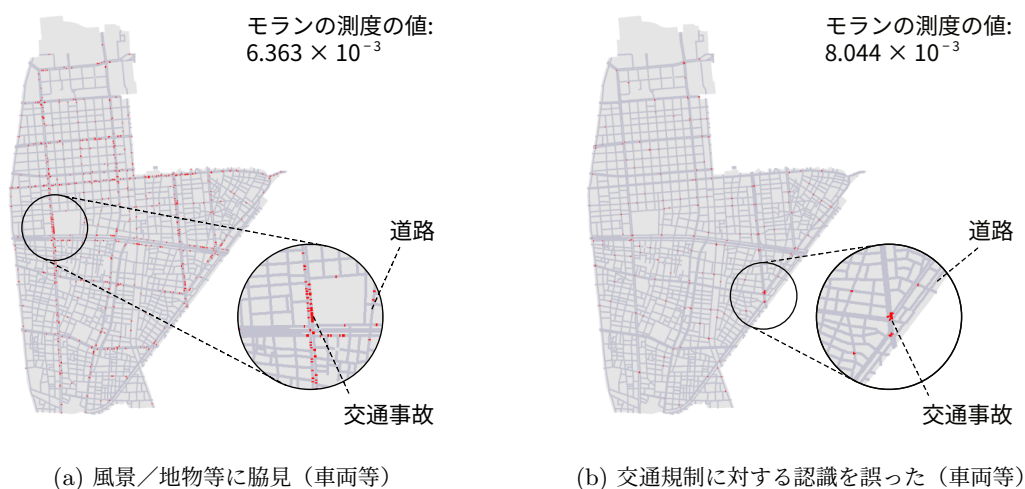


図 4.42 名古屋市中区において空間的な分布に有意な偏りがみられた人的要因による事故地点の分布

これらの人的要因による事故は、共通して住宅道路で発生していない。また、それぞれ異なる場所に集中している。図 4.42(図 4.42a) に示した、「風景／地物等に脇見（車両等）」による事故は幹線道路に沿う形で地点が集中している。これらはこの道路沿いの建物、広場等の景観に脇見が誘引されたことが考えられる。一方で、図 4.42(図 4.42b) に示した、「交通規制に対する認識を誤った（車両等）」による事故は 1 つの交差点付近に集中している。これはこの交差点の道路構造、標識等による規制が分かりにくく、運転者の認識を誤らせた可能性が考えられる。

本研究では、交通事故の人的要因と交通環境との間に関係があることを示す結果が得られた。また、空間的自己相関があることが認められた地域では、ある程度事故地点が凝集しており、その傾向を空間分布から把握できることを確認した。本研究では、人的要因と交通環境との因果関係までは明らかにできていないが、今後、これらの結果をもとに事故地点の凝集している場所の交通環境を調査することで、事故発生を誘引する交通環境の要因を特定できる可能性があると考えられる。

4.5.4 正面衝突事故の多発箇所とその交通環境の分析

正面衝突事故は当事者が死亡するリスクの最も高い事故類型である。この典型的な例としては、道路のセンターラインを越えて、対向車と衝突する場合がある。このとき、衝突時の相対速度が高くなるため、その強い衝撃から、当事者が重傷あるいは死亡することが多い。正面衝突事故の年間発生件数は構成比において 3% ほどで、他の追突事故や出会い頭事故などの事故類型より少ないものである。しかし、死亡事故の中で

は30%以上を占めており、最も危険性が高いとされる。国内の事故件数は全体に減少傾向にあるものの、正面衝突事故に関するこの傾向は5年以上変化していない。このような背景から、正面衝突事故による事故被害は安全対策の検討において、対策すべき対象として重要視されている [28]。

一方、道路幾何構造と運転との関係についての研究から、道路曲率が運転者の認知や車両の挙動に影響することが確認されている。Land・Tatler はレーシングドライバーを対象に、コースの湾曲した区間で、どのような視覚情報を獲得しているかを調査した [87]。そのために、レーシングドライバーの頭部および眼球の運動をコース上の複数の区間で計測している。各区間で得たデータを比較した結果、車両の垂直軸の回転速度（ヨー・レート）と運転者の頭の向きに強い関係があることを発見した。また、道路曲率の強いカーブでは、レーシングドライバーの注視点にばらつきが有意に大きいことを発見した。

Land・Tatler の研究結果はレーシングドライバーを対象としたものであり、一般の運転者にもこの特性が共通するかは明らかでない。尾杉らはこの特性が一般の運転者にも共通することを明らかにした [88]。尾杉らは運転者の認知特性を解明するために、FB-Delay PilotNet という運転者の速度制御モデルを提案した。このモデルは運転者の知覚から操作までの遅れを考慮した CNN ベースのモデルであり、走行中の運転者の視覚情報（画像）と車両操作との関係を学習する。尾杉らは一般の運転者を対象に、ドライビングシミュレータを用いてこのモデルを学習させた。その結果、Land・Tatler の研究結果と類似する結果がみられたことを報告している。したがって、道路曲率の強さが運転者の注視点に影響することは、レーシングドライバーに限らず、一般の運転者にも共通している。

また、実際の交通事故データを用いた分析として、赤羽らは高速道路で交通事故が多発している S 字状の区間において、道路曲率の変化パターンがその一因である可能性を示した [89]。赤羽らは実際に対象区間を複数の被検者に走行してもらい、その際の車両挙動を計測した。走行時のカメラ映像、ステアリング操作角、車両加速度などのセンシングデータを分析した結果、曲率が急激に増大する区間では、ステアリング操作角に呼応せずに、横方向の加速度が強まっていることを確認した。この結果から、対象区間では走行車が横すべりを起こしており、カーブに対して大回りに走行していることが想定される。このようにして、事故の発生へ繋がったものと考察されている。

本研究では、愛知県の交通事故データを対象とした事前調査から、正面衝突事故の多発箇所において、次の2つの結果を得た [90]。

1. 地方部では、湾曲した道路に沿って正面衝突事故が多く発生している。
2. 都市部では、正面衝突事故の地点が地図上の一点に集中している。

本研究では、それぞれの傾向を全国的に調査することで、正面衝突事故の発生と交通環境との関係への理解を深めることを目的とする。

1 の湾曲した道路に沿う傾向は、従来の研究結果を踏まえると、道路曲率が影響している可能性が考えられる。しかし、事前調査では、事故の発生に道路曲率が影響しているかまでは明らかでない。そこで本研究では、これを明らかとするために、道路幾何構造と湾曲した道路における正面衝突事故との関係を分析する。

一方、2 の一点に集中する傾向は、その地点に何らかの道路幾何構造の特徴が存在している可能性が考えられる。しかし、この傾向は従来の研究にもみられたものでなく、愛知県の交通環境に依存したものである可能性がある。そこで本研究では、この傾向が全国的に成り立つかを調査する。

愛知県を対象とした事前調査

事前調査では、愛知県の正面衝突事故について、広域的な傾向から局所的な傾向までを段階的に調査した。この調査では、愛知県警察より提供いただいた2008年から2020年までの交通事故データを対象としている。

まず、正面衝突事故が発生しやすい地域を確認するために、各市町村の正面衝突事故の割合を算出した。この結果を地図上に可視化したものを図 4.43 に示す。図 4.43 に示すように、愛知県の前線衝突事故は三河高原や三河湾に面した山間部および海岸部の地域で割合が高いことが確認された。これらの地域には、非市街地の部分が多い、人口が少ない、道路密度が低い、事故件数が少ないといった点が共通する。

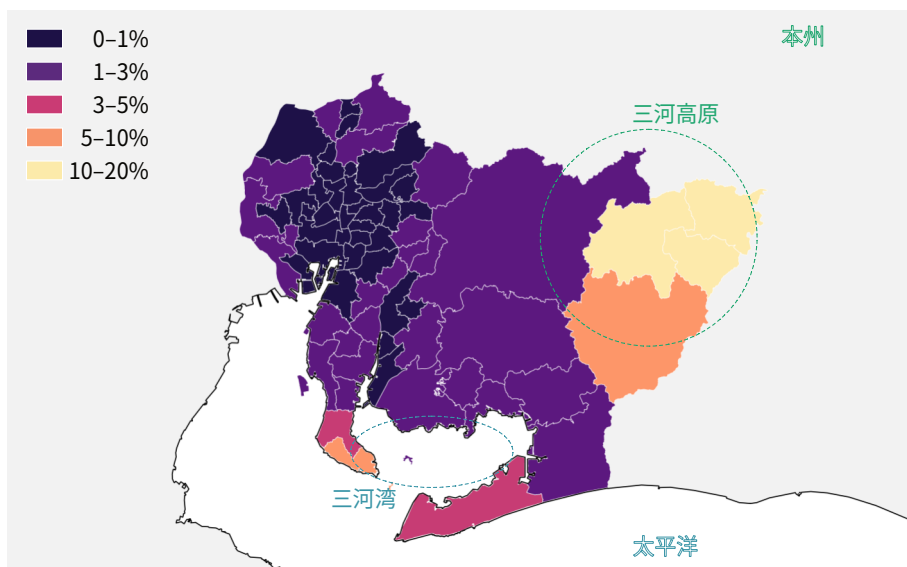


図 4.43 愛知県における正面衝突事故の割合の高い地域

愛知県全体での傾向が確認できたため、さらに狭域の傾向として、1つの市町村の中で正面衝突事故が発生しやすい箇所を調査した。市街地と山地の両方含む豊田市を対象に調査したところ、8件もの正面衝突事故が集中している箇所が確認された。豊田市における正面衝突事故のヒートマップを図 4.44 に示す。なお、このヒートマップでは、一辺が約 500m の 2分の1 地域メッシュで空間集計している。

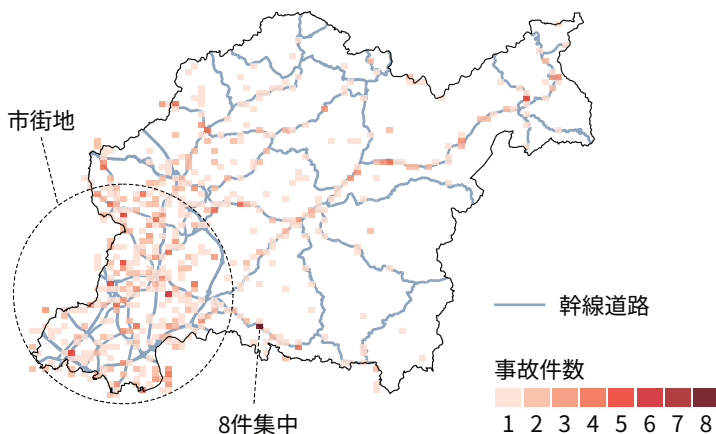


図 4.44 豊田市における正面衝突事故のヒートマップ

結果から、非市街地には住宅道路がないということもあるが、正面衝突事故の地点は主に幹線道路に沿って分布している。また、8件もの事故が集中していた地点は市街地の外れに位置していた。対象の地点の地図で確認したところ、山間部に位置する湾曲した道路であることが分かった。このことから、1つの市町村の中でも、山間部で発生しやすいことが確認された。

さらに、豊田市での傾向が他の地域にもみられるかを確認するため、各市町村で同様の空間集計をおこなった。そして、その中で最も正面衝突事故の件数が多い箇所を抽出した。これらの箇所を事故件数の多い順に図 4.45 に示す。なお、左上から3番目の地図は豊田市のものであり、図 4.44 で示した8件の事故が集中していた地点である。

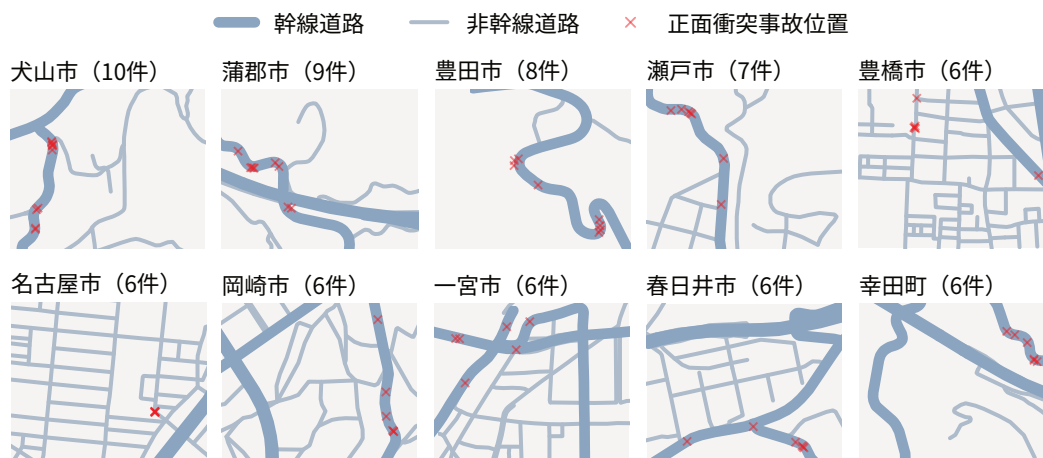


図 4.45 正面衝突事故の多発地点

結果から、犬山市、蒲郡市、瀬戸市などでは、豊田市のように事故地点が湾曲した道路に沿って発生していることが確認された。これらの地点はいずれも山間部や海岸部に位置しており、これまでの結果と合致する。また、山地の場合には、勾配が大きく速度が出やすい、見通しが悪いといったことも要因として考えられる。抽出された地点では、このような理由から、当事者がセンターラインを越えて対向車との衝突した可能性が考えられる。

これまでの結果は地方部における傾向であったが、一方、名古屋市や豊橋市などの都市部においても、正面衝突事故の多発箇所が検出された。これらの箇所では、正面衝突事故の位置が地図上の一点に集中していることが確認できる。都市部では、交通量が多く、それに伴い事故件数も多いため、正面衝突事故に限らず、事故の発生しやすい箇所が抽出されたという可能性もある。抽出された地点を地図から調査してみたものの、交通事故を誘引する特定の要因は確認できなかった。この要因については、他のデータと組み合わせた、さらなる調査が必要であると考えられる。

分析対象のデータ

事前調査で用いた愛知県の交通事故データには、正面衝突事故の件数が5,932件しかない。統計的な検証においては、データの多い方が望ましい。そこで本研究では、検証に向けて対象地域を全国へと拡大し、データ数の増加を図る。

本研究では、警察庁から公開されている全国の交通事故データを使用する。このデータは2019年から毎年公開されており、本研究では、2019年から2023年までに計上されたデータ、約160万件を使用する。全国の交通事故データは一般公開にあたり、いくらかの項目が匿名化されている。愛知県の交通事故データには、事故の種類を記した「事故類型」という項目があり、その内容が「正面衝突事故」であるか否かにより、正面衝突事故のデータを抽出することができた。一方、全国の交通事故データには、この項目がない。そのため、直接、正面衝突事故のデータを抽出することはできない。

そこで本研究では、「衝突部位」という項目の組み合わせから、正面衝突事故のデータを抽出する。衝突部

位は当事者の車両における衝突痕の位置を示す項目である。四輪車の場合には、図 4.46 に示す、8つの方向に応じた値が記録される。また、この項目は当事者ごとに記録されており、2台の車両が衝突した場合には、2つの衝突部位が記録されている。

センターラインを越え、対向車と衝突した場合では、左側通行であることを考慮すると、双方の車両の「1: 前方」あるいは「5: 前方右」を衝突部位として記録されることが想定される。このことから、本研究では第1当事者、第2当事者の衝突部位がいずれも「1: 前方」あるいは「5: 前方右」である事故、4パターンを正面衝突事故として抽出する。ここで、第1当事者とは、事故において最も過失の大きいとされる当事者を指し、第2当事者はそれに次ぐ当事者を指す。




図 4.46 衝突部位に記録される 8つの方向




図 4.47 正面衝突事故として抽出する組み合わせ

衝突直前に運転者が対向車線側に回避行動を取った場合「8: 前方左」を衝突させる可能性もある。しかし、前方左を衝突部位に含む組み合わせには、直進者同士の出会い頭事故なども含まれる。そのため、本研究では正面衝突事故に対象を限定するため、これらの含む組み合わせは例外的なものと考え、除外する。また、対象とする4パターンは衝突部位が運転者席と近く、前方左を含む場合よりも、運転者への強い衝撃が加わっていることが想定される。このことから、分析対象をより危険性の高いものに限定する効果もあると考えられる。

また、本研究では四輪車同士の正面衝突事故のみを対象とする。四輪車同士の事故は正面衝突事故の中で最も件数の多い、交通主体の組み合わせである。一方、交通事故データには、二輪車や歩行者との正面衝突事故も含まれている。しかし、四輪車同士の事故と、これらの交通主体を含む事故では、運動特性や交通規制の違いなどから、その状況が大きく異なることが想定される。そのため、本研究では信頼性のある結果を得るために、対象を四輪車同士の事故に限定する。

さらに本研究では、全国の交通事故データを画一的に処理するために、Rで利用可能なjpaccidentsというパッケージを開発した[?]. 全国の交通事故データは70以上の項目から構成されている。また、各年のデータの項目は少しずつ異なっており、いくらかの前処理を必要とする。jpaccidentsでは、交通事故データのダウンロード、形式の変換、条件に応じたデータ抽出などの機能を提供する。また、意味的な対応関係を記述したメタデータを用いて、各年のデータの項目の違いを吸収可能な設計とした。このjpaccidentsを用いた本研究の分析は再現性を確保するためにスクリプトとして保管し、GitHubで公開している。

約160万件ある交通事故データから、四輪車同士の事故を抽出した結果、約135万件のデータが得られた。そこから、正面衝突事故として定義した4パターンに該当するデータは、約16万件であった。この内訳を表4.16に示す。

件数の内訳から、前方同士の衝突が最も多い。また、衝突部位の組み合わせごとにその件数は大きく異なることが分かった。特に、第1当事者が前方右、第2当事者が前方であるパターンと、その逆のパターン

表 4.16 衝突部位の組み合わせごとの事故件数

衝突部位の組み合わせ		件数 [件]
第1当事者	第2当事者	
前方	前方	85,545
前方右	前方	49,610
前方右	前方右	19,736
前方	前方右	8,725
合計		163,616

では、件数には4倍以上の差がみられる。個別のデータを確認したところ、図4.48に示すような右折車両と直進車両による事故が含まれている可能性があることが分かった。このような事故は右直事故^{うちよく}と呼ばれ、交差点付近で発生することが多い。

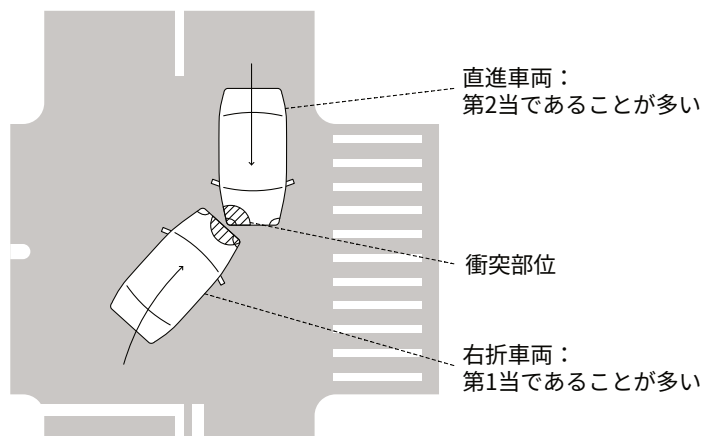


図 4.48 右折車両と直進車両による事故（右直事故）の例

右直事故では、図4.48に示すように抽出した組み合わせの部位で衝突する可能性がある。また、原則として直進車両が優先であることから、右直事故では右折車両が第1当事者になりやすい。そのため、右直事故における右折車両が前方右を衝突しやすいと仮定すると、件数の偏りを説明できる。

一方、交通事故統計では、右直事故は右折時の事故として分類されており、正面衝突事故とは区別されている。そのため、本研究で抽出した正面衝突事故のデータは、交通白書などで述べられる正面衝突事故とは部分的に合致しない可能性がある。しかし、交通事故データからはこれを判別できない。そのため、以降の分析では交差点上のデータは右直事故である可能性も考慮して考察するものとする。

湾曲した道路と正面衝突事故との関係分析

正面衝突事故が湾曲した道路で発生しやすいかを明らかとするために、正面衝突事故の発生地点の道路曲率に偏りがあるかどうかを調査する。正面衝突事故が湾曲した道路において発生しやすいならば、発生地点の道路曲率は平均的なものよりも大きいことが期待される。そこで本研究では、正面衝突事故とその他の事故について、それぞれが発生した道路を比較し、その道路曲率に差がみられるかどうかを検証する。

正面衝突事故には、交差点や直線区間で発生した事故もある。しかし、これらの道路では曲率を測ること

ができないため、本研究では分析対象から除く。正面衝突事故と道路曲率との関係を検証するために、交通事故データから、カーブ区間で発生した事故のみを抽出する。具体的には、道路形状に「カーブ・屈折」という値が記録されているデータを対象とする。そして、これらのデータを正面衝突事故とその他の事故に分類し、比較をおこなう。

本研究では、道路曲率を対象とするが、交通事故データにはその情報が含まれていない。そこで、本研究では交通事故データが持つ事故地点の情報と OpenStreetMap の道路データから、事故地点の道路曲率を幾何的に算出する方法を提案する。曲率とは、曲線状の一部を円の弧としてみなしたとき、その円の半径の逆数として定義される数値である。この値は大きいほど曲がり強く、小さいほど曲がり緩やかであることを示す。また、曲率の算出には、曲線を表現する式の二階微分が必要となる。しかし、地理空間データで用いられる道路は折線として表現されるため、微分を直接適用できない。そこで本研究では、式 (4.13) に示す、メンガーの曲率という数式から、道路データの曲率を定義する。

$$c(x, y, z) = \frac{1}{R} = \frac{4A}{|x - y||y - z||z - x|} \tag{4.13}$$

メンガーの曲率 (Menger's curvature) とは、与えられた 3 点 x, y, z を通る曲線の曲率を近似的に求める式である。ここで、 A はこれらの点から構成される三角形 xyz の面積を表す。また、 R は三角形 xyz の外接円の半径を表す。メンガーの曲率を用いることで、折線で表現された道路データに対しても、基点となる 3 点を与えられれば、曲率を算出できる。

本研究では、道路上の図 4.49 に示す、3 点をメンガーの曲率計算における x, y, z とする。点 x は事故地点から最も近い道路上の点である。地理空間データでは、道路が折線、事故地点は点で表現されるため、厳密に道路上に事故地点が乗ることは稀である。そのため、事故地点から最も近い点を道路上の事故地点とし、これを求める曲率の中心点 x とする。また、点 y, z はそれぞれ点 x から前方、後方に向かって、一定距離だけ進んだ地点である。本研究では、実際の道路データの調査からこの距離を 50 m とする。

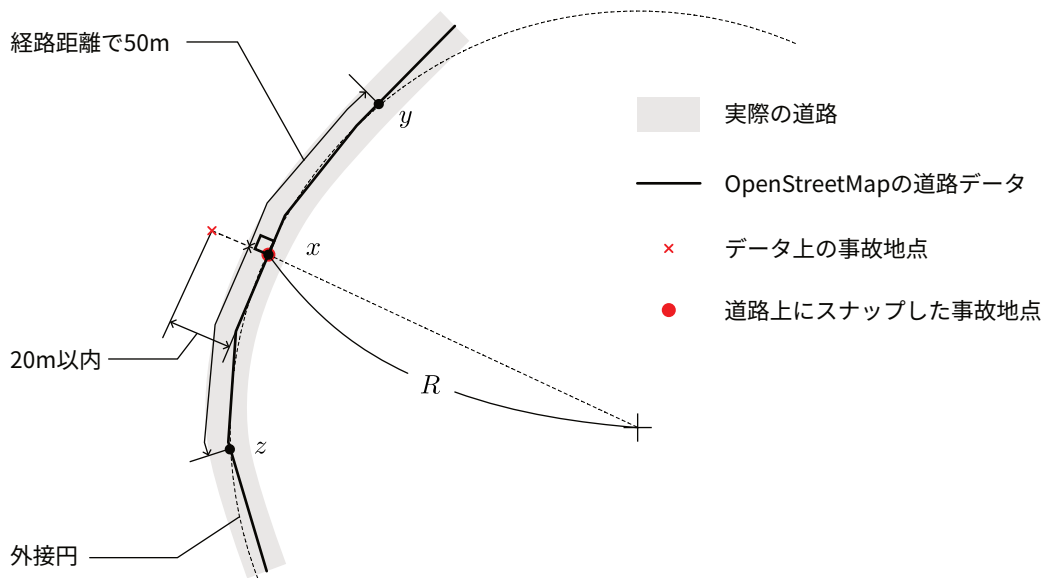


図 4.49 道路曲率の算出に用いる点

なお、点 x を求める際に、事故地点から道路までの距離が著しく遠い場合には、道路データの欠損や道路以外の場所での事故が想定される。そのため、本研究では、20 m 以内に道路が存在しない事故は分析できな

いものとし、対象から除外する。また、点 x , y , z が一直線上に存在する場合には、曲率が定義できない。この場合も対象から除外することとする。

正面衝突事故の発生した道路の曲率が大きいかどうかの検証には、仮説検定を用いる。正面衝突事故とその他の事故の2群にデータを分け、これらの道路の曲率について、有意に差がみられるかを検証する。ここでは「事故が発生するすべての道路において、その曲率は事故の種類によらず同じ確率分布に従う」ことを帰無仮説として検定する。検定から、この仮説が棄却された場合、正面衝突事故が発生する道路は有意に曲率が大きいといえる。対象とする道路曲率は0より大きい実数であり、また正規分布に従わない。このことから、検定には、ノンパラメトリックな検定手法であるマン・ホイットニーのU検定を用いる。

ここまで述べたとおり、本研究では正面衝突事故と道路曲率との関係进行分析する。しかし、事故が発生する要因は多岐に渡り、道路曲率のみを分析した場合、その重要度を十分に評価できず、事故発生への影響を適切に説明できない可能性がある。

そこで本研究では、交通事故データに含まれる、道路曲率以外の情報も含めた決定木分析から、各要因の重要度の評価をおこなう。これにより、道路曲率が正面衝突事故の発生においてどの程度重要であるか、またどのような条件の下で正面衝突事故が発生しやすいかを明らかにする。この分析の対象には、交通事故データの項目に道路曲率を加えた、表4.17に示す10項目を特徴量として使用する。本研究では、これらの項目から正面衝突事故とその他の事故を分類する決定木を作成する。そして、この決定木から正面衝突事故の発生における各要因の重要度と、正面衝突事故の発生リスクを高める条件を抽出する。この決定木アルゴリズムには、ジニ不順度に基づいてデータを分類するCARTを使用する。

表4.17 決定木分析に使用する項目とデータの例

項目	データの例
道路曲率	(0より大きい実数値)
時間帯	日の出前, 日の出後, 日中, 日の入り前, 日の入り後, 夜間
天候	晴, 曇, 雨, 霧, 雪
地域種別	市街地, 非市街地
中央分離	中央分離帯, 高輝度表示, 道路鋸, ワイヤロープ, ペイント, なし
歩車道区分	ガードレール, 縁石, 路側帯, なし
曜日	日, 月, 火, 水, 木, 金, 土
祝日区分	祝日, 祝日の前日
年齢区分*	0-24歳, 25-34歳, 35-44歳, 45-54歳, 55-64歳, 65-74歳, 75歳以上
車両種別*	乗用車, 貨物車

* 年齢, 車両種別は第1当事者のものを使用

交通事故データから、湾曲した道路で発生した事故を抽出した結果、32,036件のデータが得られた。そのうち、事故地点から道路までの距離が遠く、道路と対応付けられなかったもの、事故地点が直線道路に存在していると判断されたものを除外した結果、31,237件となった。正面衝突事故と道路曲率との関係分析では、これらのデータを使用する。

これらのデータを先述した正面衝突事故のデータに含まれるものと、そうでないものに分けた。その結果、正面衝突事故のデータが11,688件、正面衝突事故以外のデータが19,559件となった。これらのデータから、それぞれが発生した道路の曲率を比較する。図4.50はそれぞれの道路曲率の分布を確率密度関数で表したものである。なお、グラフの差をみせるために、横軸は平方根目盛としていることに注意されたい。




図 4.50 正面衝突事故，正面衝突事故以外のそれぞれが発生した道路曲率の確率密度関数の比較

分布はいずれも 0 付近に集中しているが，これは道路の曲率半径が一般に大きく，曲率そのものが小さい値をとるという道路構造の特性を反映したものである．道路構造基準を定める「道路構造令」によると，屈曲部の曲線半径はその道路の制限速度に応じ，段階的に 15-70 m 以上とするように規定されている．この規定に従うと，道路曲率は 1.41×10^{-3} - 6.67×10^{-2} (1/m) 以上と計算できる．図 4.50 の分布とこれらの値から，メンガーの曲率を用いた道路曲率の値が妥当であることが確認できる．

分布の比較から，正面衝突事故が発生した道路の曲率は，その他の事故が発生した道路よりも全体に大きい傾向にある．これらの 2 群に差があるかどうかを有意水準 $\alpha = 1\%$ で検定した．その結果，正面衝突事故が発生した道路の曲率はその他の事故が発生した道路よりも，有意に大きいことが示された． p 値は 2.2×10^{-16} と極めて小さく，有意性が高いことを示した．また，サンプルサイズを考慮して，効果量を算出したところ， $r = 0.766$ という結果を得た．一般に効果量は 0.5 以上であれば，大きいとされることから，この結果は十分に大きな差があることを示している．

正面衝突事故とその他の事故とを分ける条件を明らかとするために，決定木分析を実施した．作成した決定木の一部，根に近い部分を図 4.51 に示す．決定木の結果から，正面衝突事故の発生には，中央分離帯の有無，市街地であるかどうかが強関係していることが分かった．さらに，道路曲率に関しては，中央分離帯がなく非市街地である場合に，道路曲率が 1.04×10^{-2} 以上という交通環境で，正面衝突事故の割合が大きくなることが示された．

中央分離帯がある場合，物理的に対向車線への進入が防止されるため，その有無が正面衝突事故に影響するのは妥当であると考えられる．米国の研究結果であるが，市街地，非市街地の両方を対象とした調査において，中央分離帯の設置が正面衝突事故の被害低減へ有効であることが報告されている．本研究の結果はこの内容とも整合する．また，非市街地の場合，正面衝突事故の割合が高まるという結果も，愛知県における事前調査において山間部や海岸部で正面衝突事故が多発していたことと一致する．この結果は非市街地に運転が難しく，正面衝突事故に繋がりがやすい道路環境が存在していることを示唆している．

道路曲率は中央分離帯の有無，市街地であるかどうかに次ぐ，分類条件として示されている．結果から，道路曲率が 1.04×10^{-2} 以上の場合，正面衝突事故の割合が 45.7% から 53.7% に高まることが示された．しかし，この数値からでは，どのような道路であるかを想像することが難しい．そこで，正面衝突事故の発生した道路から，この値に最も近い道路曲率を持つ区間を検索し，これを 3 次元的に可視化した．この道路を図 4.52 に示す．

図 4.52 に示した分類境界に近い道路は，上面図からでは，それほど曲がり強いようには見えない．しか

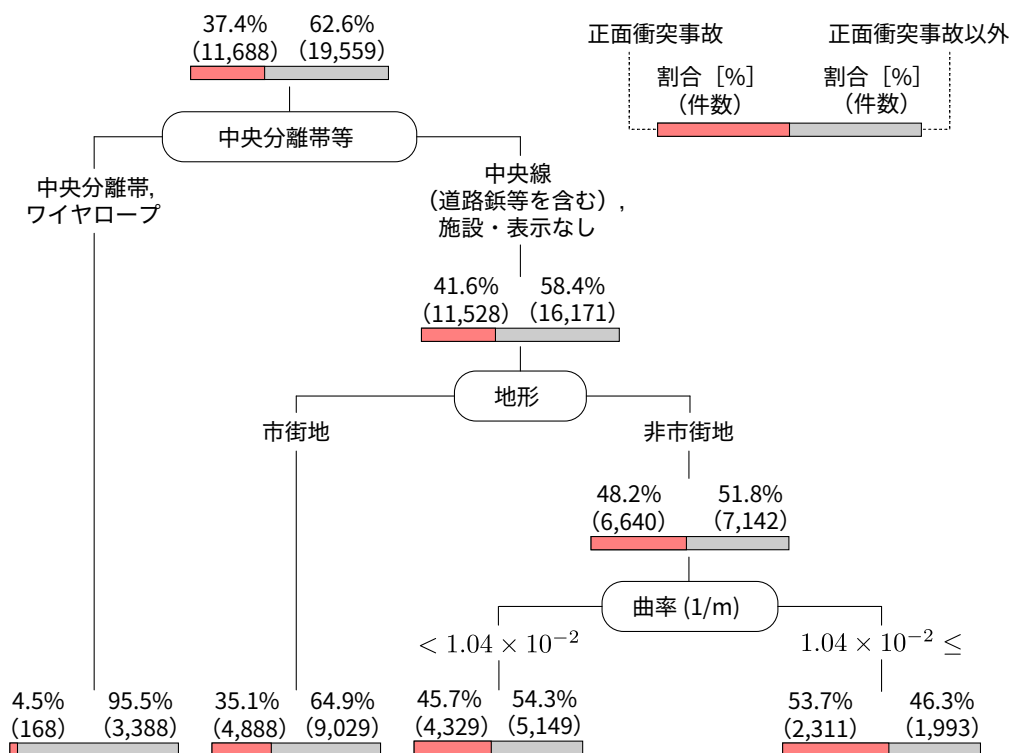


図 4.51 正面衝突事故と正面衝突事故以外を分類する決定木の一部

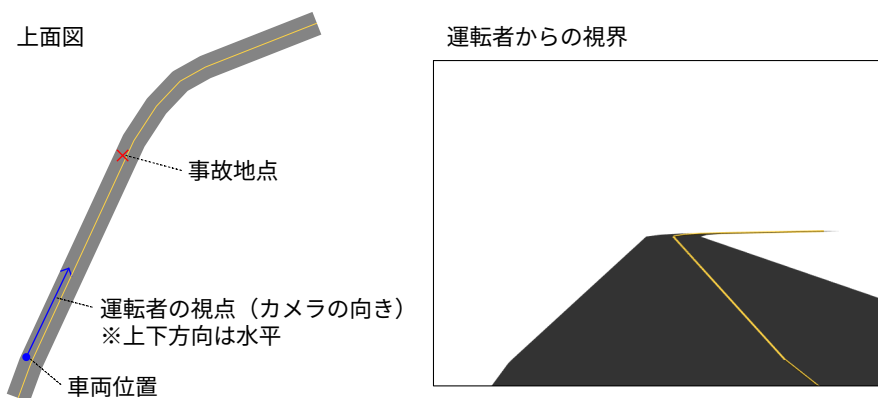


図 4.52 道路曲率が 1.04×10^{-2} に近い道路

し、運転者の視点から見ると、カーブから先の道路の視認性が悪いことが分かる。また、この図では曲率を表現するために、道路のみを表現したが、実際の交通環境では、周囲の木々、建物、走行車両などの物体、勾配、天候なども視界に作用する。そのため、運転者の視界はさらに制限されていることが考えられる。

道路曲率がどの程度重要な要因であるか、また他に重要な要因はないかを評価するために、特徴量重要度を算出した。本研究の決定木モデルにおける特徴量重要度 (feature importance) とは、その特徴を用いて分類されたデータ数とジニ不順度の改善度から算出したものである。各特徴の重要度とその割合を重要度の高い順に表 4.18 に示す。

この結果から、道路曲率は使用した 10 個の特徴の中で、3 番目に重要な要素であることが示された。また、中央分離、地域種別、道路曲率、歩車道区分の 4 つの特徴で、決定木全体の 95% 以上を説明できるこ

表 4.18 決定木に用いた特徴の重要度

特徴名	特徴量重要度	全体の重要度に対する割合 [%]
中央分離	901.3	70.77
地域種別	236.1	18.54
道路曲率	45.7	3.59
歩車道区分	37.0	2.91
天候	14.3	1.13
時間帯	12.3	0.96
車両種別	11.3	0.89
曜日	9.9	0.78
年齢区分	5.6	0.44
祝日区分*	—	—

* 決定木における分類条件に使用されなかった特徴（複雑度は 0.015）

とが分かった。これは他の特徴が決定木のデータ分割に与える影響がこれらと比べ、小さいことを示している。なお、作成した決定木は正面衝突事故とその他の事故を完全に分類するものでない。また、本研究で使用した項目は、道路曲率と交通事故データに含まれるもののみである。本研究で重要であることが確認された要素に加えて、道路の勾配や周囲の建物情報など、正面衝突事故を誘引する可能性のある要素を追加することで、より正確に正面衝突事故の要因を明らかにできると考えられる。

正面衝突事故が集中して発生する箇所の調査

都市部の正面衝突事故が地図上の一点に集中して発生する傾向が、全国的に成り立つかを調査する。そのために、交通事故データから正面衝突事故の地点が集中している箇所を検出する。また、それらがどのような場所であるかを、地図上に可視化し、その位置関係や周辺の交通環境を調査する。

本研究では、集中箇所を検出する方法として **DBSCAN** というクラスタリング手法を採用する。DBSCAN (density-based spatial clustering of applications with noise) とは、密度ベースのクラスタリング手法の一つである。この方法では、データ点（事象の発生地点）からの距離 Eps と、クラスタに必要なデータ点の最小数 $MinPts$ から、クラスタを検出する。

例えば、図 4.53(a) に示すように事故地点が位置していたとする。このとき、 $Eps = 10\text{ m}$ 、 $MinPts = 3$ 件と設定した場合、DBSCAN では、それぞれの事故地点から半径 10 m の範囲内を考える。そこに含まれる自身も含めた事故件数が 3 件以上の事故地点を「コア点」とする。それから、同様にしてコア点から 10 m 以内に存在する事故地点群を一つのクラスタとして検出する手法である。この例では、図 4.53(b) に示した、4 件の事故が一つのクラスタとして検出される。また、DBSCAN では k -means 法などのすべてのデータをクラスタに分類する手法とは異なり、クラスタに含まれないデータはノイズとして扱う。

DBSCAN はその特徴として、与えたパラメータである Eps 、 $MinPts$ から、検出されたクラスタの解釈がしやすいことが利点に挙げられる。図 4.53 の例では「事故地点の周り 10 m 以内に 3 件以上の事故が発生している箇所」としてクラスタを解釈できる。また DBSCAN には、鎖状のクラスタも検出できるという利点もある。本研究では、事故地点が地図上の一点に集中する傾向があるかどうかを調査するため、このようなクラスタの形状的特徴は重要である。交通事故の場合には、事故地点が道路に沿って分布していることがあるが、このような場合に k -means 法では、それらが複数のクラスタとして検出されてしまう。DBSCAN




図 4.53 DBSCAN によるクラスター検出の例

では、このような道路に沿った事故地点も、コア点の連結から1つのクラスターとして検出できる。

事前調査では、愛知県を2分の1地域メッシュで空間集計し、正面衝突事故の多発地点を抽出した。しかし、メッシュによる空間集計では、多発箇所を分断するように格子が配置された場合など、格子の基準となる位置に依存して、集中箇所を見落としてしまうことがある。DBSCANにおけるコア点の連結はこのような問題も解決している。

DBSCANのパラメータの設定値については、どのような値が適しているかは明らかでない。そのため、本研究では複数の設定値に基づく結果を比較し、これを判断するものとする。

正面衝突事故が集中して発生した場所を特定するために、DBSCANの異なるパラメータをいくつか試し、それぞれの結果を比較した。この結果として、パラメータごとに検出されたクラスターの個数を表4.19に示す。

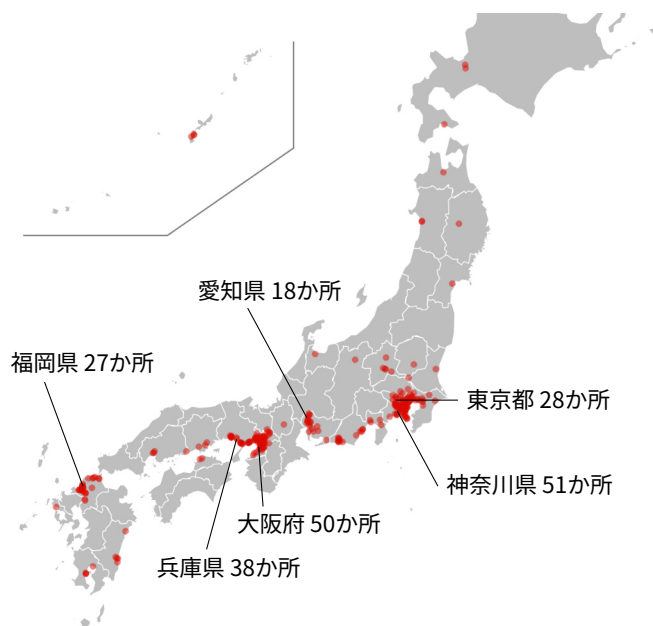
表 4.19 パラメータごとに検出されたクラスターの個数

Eps [m]	MinPts [件]			
	3	4	5	6
50	3,825	1,153	389	160
30	2,678	706	222	82
10	1,276	292	73	22

クラスター内の事故地点間の距離を表す Eps は小さくするほど、データ群がクラスターになるための条件が厳しくなるため、検出されるクラスターの個数は減少する。一方、小さな Eps で検出されたクラスターは高い凝集性を持つことを示す。表 4.19 の結果から、正面衝突事故の地点は Eps を 10 m まで小さくしても、MinPts の値が小さい場合には、多くのクラスターが検出された。10 m という距離は道路環境においては非常に近い距離である。そのため、正面衝突事故が地図上の一点に集中しやすい傾向は正しいものと考えられる。

地図への可視化から、検出されたクラスターが都市部へ集中する傾向が確認された。表 4.19 の下線で示した、Eps = 10 m, MinPts = 4 件の場合のクラスターを可視化したものを図 4.54 に示す。クラスターの位置は東京、大阪をはじめとする人口の多い都市部に集中していることが確認できる。

さらに、検出された箇所のなかで事故件数の特に多いものをいくつか抽出し、その周辺の交通環境を調査した。そのうちの2つの例を図 4.55 に示す。左側は大阪市（大阪府）のもので最も多い12件の事故が集中していた。Google のストリートビューから、この場所は高架下のトンネル状の道路であり、視界が制限され



(日本地図は国土数値情報の行政区画データより作成)

図 4.54 DBSCAN により検出された正面衝突事故の集中箇所 (Eps = 10 m, MinPts = 4 件)

ていることが確認された。右側は次に事故件数の多い 8 件のクラスタの一例として、横須賀市（神奈川県）のものである。この場所は高速道路の出入り口付近であり、交差点規模が比較的大きいことが確認された。

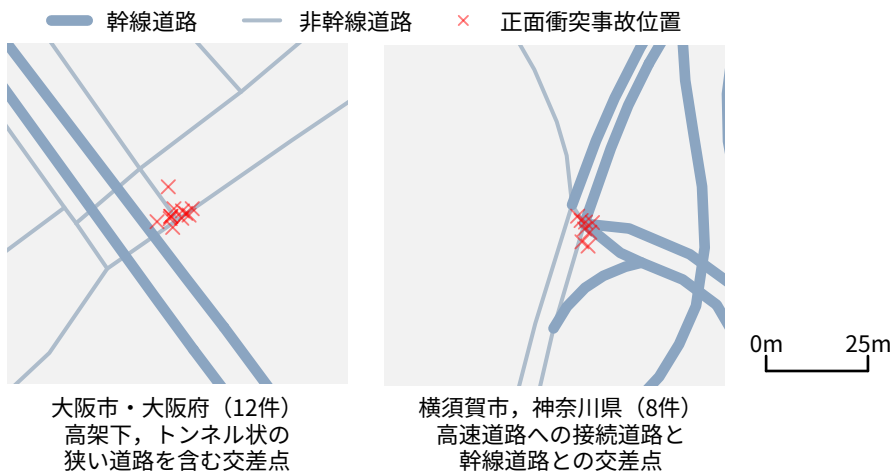


図 4.55 特に正面衝突事故が集中している場所の例

このようにクラスタとして検出された場所の多くは、見通しの悪さや交差点の規模が大きいことなど、従来研究でも事故リスクを高める要因として指摘されている交通環境を含んでいることが分かった [49]。また、検出された正面衝突事故のほとんどが交差点におけるもので、死亡事故が少ないことが判明した。したがって、これらは典型的なセンターラインを越えて対向車と衝突するといった事例ではない。これらのことから、地図上の一点に集中するものとして、検出された場所は正面衝突事故に限らず、一般に交通事故が発生しやすい場所であると考えられる。

一方、DBSCAN では鎖状のクラスタも検出できるという特徴がある。パラメータの調整次第では、湾曲した道路に沿う事故群も検出できる可能性がある。しかし、本研究で検出されたクラスタの多くは一か所に集中しているものであった。そこで対象データをカーブ区間に発生したものに限定したところ、Eps = 10m においては、クラスタがほとんど検出されないことが分かった。条件を緩め、MinPts = 2 件としたとして検出した結果を図 4.56 に示す。

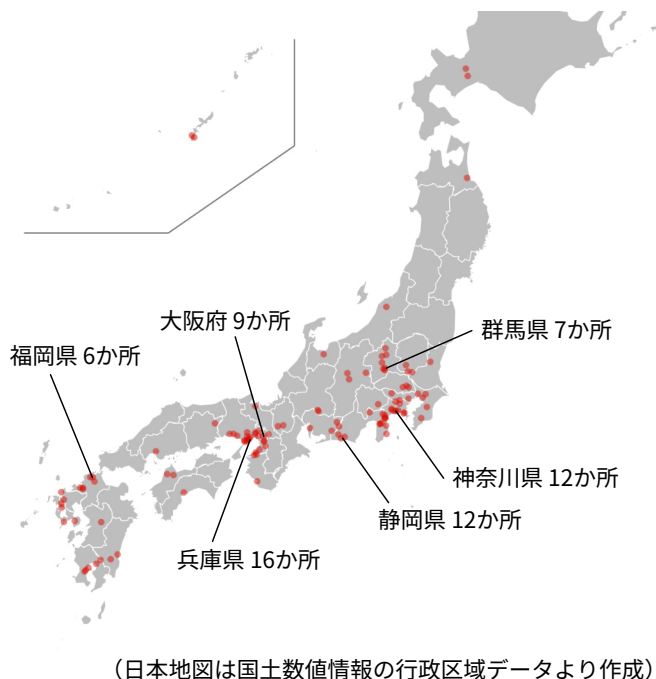


図 4.56 DBSCAN により検出されたカーブ区間上の正面衝突事故の集中箇所 (Eps = 10m, MinPts = 2 件)

この結果から、すべての正面衝突事故を対象にした場合には検出されなかった、静岡県や群馬県の山間部の道路にもクラスタが検出された。しかし、検出されたクラスタはいずれも内包している事故件数が 3 件以下であり、3 件のものが 7 個、他はすべて 2 件ということが確認された。これらから、検出されたクラスタは正面衝突事故のリスクの高い交通環境があるわけではなく、偶発的に近くで発生した可能性を否定できない。一方、愛知県を対象にした分析では、13 年分のデータを使用したのが、本分析の使用データは 2019 年から 2023 年までと 5 年分しかない。そのため、5 年以内に正面衝突事故が同じカーブ区間で 3 件以上の発生することが稀であり、より長期的なデータを使用することで、この傾向が得られるという可能性もある。この点については、継続的なデータの収集、限られたデータから知見を得るための新たな手法の検討など、今後の課題としたい。

以上のとおり、愛知県で確認された 2 つの傾向について調査し、正面衝突事故の多発箇所に関する知見を明らかとした。湾曲した道路を対象にした決定木分析では、道路曲率が正面衝突事故の発生において重要な要因であることを示した。また、正面衝突事故が集中する箇所に対する分析からは、正面衝突事故の地点が地図上の一点に集中する傾向が全国的に成り立つことを確認した。

一方、本研究は分析対象を正面衝突事故に限定したため、発生リスクを高める条件を詳細に把握できた反面、データ数が減少し、得られる知見の幅が制限された可能性は否定できない。その影響の一例として、愛知県の豊富なデータでは確認できた「湾曲した道路に正面衝突事故が集中する」という傾向が、全国の限ら

れた年数のデータでは確認できなかった。こうした課題に対処するためには、今後もデータの継続的な収集を進め、より長期的な記録を用いた分析をおこなうとともに、限られたデータから最大限の知見を得るための新たな手法の検討も重要であると考えられる。

4.6 交通事故要因分析に関する考察

本研究では、マルチエージェントシミュレーションによる交通事故の再現に向けた知見を得るため、日本の交通事故要因の空間分析を実施した。交通事故の時空間的なホットスポットの検出では、従来手法を組み合わせ、時間と空間の両方を考慮したホットスポットの検出し、その手法が従来のものよりも高い精度を持つことを示した。また、環境要因との関係分析では、交通事故と環境要因との間の複雑な関係を捉えるのに、空間分析と自己組織化マップを組み合わせた手法が有効であることを示した。さらに、交通環境が運転者の行動と有意に関係することや、正面衝突事故のリスクを高める道路曲率の条件などを明らかとした。

交通事故をモデル化するためには、交通事故の発生要因がどのように交通主体に作用し、事故発生に至るかを理解することが重要である。その点において、本研究の取り組みでは、日本全国を対象とした分析から、事故多発地点周辺の交通環境の調査までを実現した。これは従来研究で課題とされてきた、マクロ的・ミクロ的な視点の両方からの分析を実現しているといえ、事故要因の理解に貢献するものであると考えられる。各分析の結果は重なる部分も存在する一方で、各分析の視点からでしか得られない知見も存在している。今後、これらを統括していくことで、要因の振る舞いが明確化し、交通事故のモデル化が実現すると考えられる。

本研究ではこのようにさまざまな知見が獲得できた一方で、交通事故の性質から得られるデータの限界が顕著な課題として表れた。交通事故は地理空間に対して非常に稀な事象であり、また地域によりその性質が異なることから、統計的に十分なデータの収集が困難である。そのため、得られた知見のいくらかは、このデータの性質から信頼性が限定される結果となった。これを克服するためには、長期的なデータや関連するさまざまな種類のデータを収集し、管理することが必要である。本研究で開発した交通事故分析のためのデータベースおよび分析システムは、これを可能としており、今後の継続的なデータ収集と分析に役立つものと考えられる。

一方で、十分なデータを収集するには多くの時間を要する。また、事故対策や社会情勢の変化に伴い、交通環境の性質は時間的に変化する。そのため、今あるデータが将来に渡って有効であるとは限らない。今後、これらの課題へ根本的に対処するためには、その時に利用可能なデータから目的に対して十分な知見を引き出すための新たな手法が必要であると考えられる。

第5章

結論

5.1 本研究の取り組みのまとめ

本研究では、マルチエージェントシミュレーションによる問題解決における課題を明らかとするために、地震災害における市民の救助と、交通事故の要因解明という2種類の問題を対象に問題解決を試みた。救助戦略の設計では、既存のマルチエージェントシミュレーションの一つであるロボカップレスキューシミュレーションを用いて、さまざまな災害状況における市民救助に有効な戦略を設計した。また、開発した戦略を評価、改善するための方法を検討した。一方、交通事故要因の究明では、交通事故を再現するためのマルチエージェントシミュレーションが存在しない。そのため、これを実現すべく、実際の交通事故データをもとに、交通事故の要因を分析した。また、交通事故の要因を明らかにするための、多角的な分析手法を提案し、その有効性を評価した。

ロボカップレスキューシミュレーションにおける救助戦略の設計では、提案した分散協調戦略に基づくエージェントチームが標準的な戦略を持つものよりも優れた性能を持つことを示した。しかし、一部の災害シナリオでは、本研究の戦略が十分に機能していないことが判明した。また、これらのシナリオは設計時の想定を超えたものであることが分かった。このことから、個別の災害状況を想定して、それらに対応する戦略の設計には限界があり、未知の環境へ柔軟に適応する頑健な戦略を設計する手法が必要であることが明らかとなった。

交通事故要因の分析では、ホットスポットの検出手法を提案し、この手法による検出精度が従来手法よりも優れることを示した。また、事故傾向の変化が類似する地域をクラスタリングすることで、事故被害低減のための知見獲得が期待される地域群を特定できることを示した。さらに、運転者の行動と事故地点との間に空間的な依存関係があることや、正面衝突事故の発生リスクを高める道路曲率の閾値を明らかとした。このようにマクロ・ミクロ両分析から、多くの知見を明らかとしたが、それぞれの分析結果の信頼性は、使用するデータの数に依存する。そのため、限られたデータから問題の本質を捉え、モデル化に有効な知見を引き出す手法が必要であることが明らかとなった。

5.2 マルチエージェントシミュレーションによる問題解決における課題

本研究では、地震災害における市民の救助、交通事故の要因解明という問題解決を通じ、マルチエージェントシミュレーションによる問題解決における次の課題が明らかとした。これらの課題は本研究が対象とした災害救助、交通事故以外の問題においても共通するものであると考えられる。

問題の核の抽出（戦略設計）

個々の災害状況を想定し、そのすべてに対応するように協調戦略を設計する方法では、そこで想定されなかった未知の環境に適応できない。これらの環境は図 5.1 に示すように、環境の全体集合（問題全体）からその一部をサンプリングしたものに過ぎないためである。




図 5.1 戦略設計プロセスにおける課題

そのため、戦略設計時に想定した環境の集合に対する戦略設計は、この環境群が持つ性質に適応は対応できても、それが問題全体に対する本質的な解決となっているとは限らない。これを克服するには、戦略に環境を問わず、対象問題の解決へ本質的に有効な能力を持たせる必要がある。またそのために、問題の核となる要素を抽出し、これに基づき構築した戦略の有効性を評価できるようにする必要がある。この実現には、さまざまな環境と戦略との組み合わせの中から、シミュレーションを通じて、環境と戦略との性質間の関係を明確化が不可欠である。

モデル境界の形成（モデル化）

現実世界から獲得できるデータには、その数、質、網羅性に限りがある。本研究で示したように、モデル化では、これらのデータを駆使して、図 5.2 に示すように、マクロ、ミクロ双方の観点からの知見獲得のための分析が必要である。

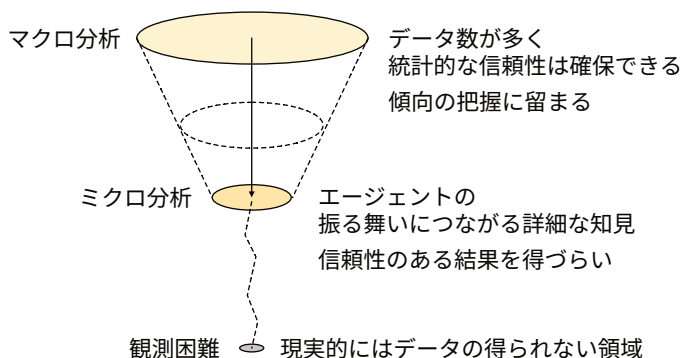


図 5.2 モデル化プロセスにおける課題

それぞれで獲得できる知見の粒度は異なり、その粒度に応じたエージェントや環境のモデル化が実現できる。しかし、マイクロ分析では、データ数が限られることから知見の信頼性は十分でないという問題がある。さらには、交通事故のように発生確率の低い疎なデータや、情報収集のためのセンシング技術や導入コストの制約、内的要因など、そもそも現実的に観測が困難な領域も存在する。これらの問題に対し、モデル化の対象の直接的なデータのみならず、関連する幅広いデータやその関係を集約していくことは、その隙間を埋められる可能性がある。このように限られた実証データに対し、その種類や属性から情報をカバーし、妥当性の高いモデルを構築していくことが、これらの問題を打開する鍵である。

これらの課題はそれぞれマルチエージェントシミュレーションを用いた問題解決における戦略設計、モデル化のプロセスに対応したものであるが、それぞれのプロセスにのみ影響するといった独立したものではない。モデル化、戦略設計、またこれらの評価という3つのプロセスは相互に依存している。例えば、戦略設計で重要となる性質はモデル化に必要なデータの種類の種類やその精度を規定する。また、モデルの妥当性はシミュレーションから得られる結果の信頼性に影響し、ひいては戦略の正当性にもつながるものである。

そのため、マルチエージェントシミュレーションの問題解決では、これらの連関性を考慮した、総合的なアプローチが重要である。つまり、相互に影響し合うプロセス全体を俯瞰し、整合性を保ちながら、各プロセスの課題に取り組むことが求められる。

5.3 今後の展望

本研究では、より良い戦略設計に向けた問題の核となる要素の抽出、およびデータ収集上の制約を克服したモデル境界の形成という2つの課題を明らかとした。これらの課題の解決に向けては、シミュレーション技術の高度化、深層学習や生成AIなどの先端技術が今後その基盤となることが予想される。

対象問題に有効な戦略設計を実現するには、さまざまな環境と戦略の組み合わせをシミュレーションを通じて分析する必要がある。しかし、環境と戦略との間の関係は単純なものではなく、この分析では高度な表現能力を持つモデルが求められる。本研究においても、ロボカップレスキューシミュレーションでは統計モデルを用いた分析から、その関係性が非線形かつ複雑であることを示した。この複雑な関係を捉えるために、深層学習モデルの活用が有効であると考えられる。深層学習モデルは多層のニューラルネットワークから、従来の統計モデルで捉えきれない関係性を学習し、その関係を高い精度で表現できる。また、シミュレーションの画像情報やエージェントの時系列的な行動データなど、多様な形式のデータを同時に扱える。このような入力データの精緻化も、この関係性を見出す上で、効果があると考えられる。

データ収集上の制約を克服したモデル境界の形成に向けては、さまざまな情報を組み合わせて、モデルの妥当性を高める必要がある。本研究で提案した、カーネル密度推定によりデータから分布を推定し、その分布のもとでデータを生成するという手法では、多様なデータを生成できる一方、生成されるデータの品質は入力となったデータに依存する。これに対し、国土交通省のデジタルトランスフォーメーションの推進などと共に、今後増えていくオープンデータの活用は有効であると考えられる。また、近年の生成AI技術はインターネット上の膨大なデータをもとに、より高品質なデータを生成できる。ただし、生成AI技術を用いる場合でも、その信頼性や情報の偏りには注意を向ける必要があると考えられる。現実のデータから得られた確かな知見と、生成AI技術による現実味を持った多様なデータとを組み合わせることで、マルチエージェントシミュレーションのモデルの妥当性を高められることが期待される。

本研究で挙げた課題はマルチエージェントシミュレーションによる問題解決において、まだその一部に過ぎない。しかし、このような課題の明確化はこれまでになく、マルチエージェントシステムを対象とする研究の発展に寄与するものと考えられる。また、今後も継続的にマルチエージェントシミュレーションの適用事例は増えていくことが予想され、本研究の成果はこれに役立つものであると考えられる。

マルチエージェントシミュレーションを含む、人工知能技術およびその応用は今後もさまざまな場面で求められ、ますます発展することが期待される。人間の知性をコンピュータ技術で表現しようとする、これらの技術は本研究において基礎的な役割を果たすとともに、今後明らかとなる課題の解決においても重要なものとなることが予想される。今後新しく生み出される先端技術も含め、広い視野で包括的に研究を進め、究極的には社会のあらゆる問題解決への一つの選択肢として、多くの人々がマルチエージェントシミュレーションによる解決を図れるよう、体系的な枠組みを実現したい。

謝辞

本研究をまとめるにあたり、これまで多くの方々大変お世話になった。ここに感謝の意を表す。

まず、本研究の指導教員として研究の着想段階から博士論文の完成に至るまで、丁寧かつ熱心なご指導を賜った、愛知工業大学情報科学部 教授 伊藤暢浩先生に心より感謝申し上げます。マルチエージェントシステムの基礎からロボカップレスキューシミュレーションに関する実践的知見に至るまで、多角的な観点からご助言をいただいた。先生からいただいた示唆は本研究の方向性を定め、研究を深める上で重要な指針となった。

愛知工業大学情報科学部 教授 菱田隆彰先生、愛知工業大学情報科学部 准教授 内種岳詞先生には、修士課程から継続して副査として本研究に関わっていただいた。研究をまとめていく上での要点や本質的な課題についての的確なご指摘を賜り、本研究の完成に大いに貢献いただいた。厚く御礼申し上げます。

本研究の進行にあたっては、愛知大学経営学部 教授 岩田員典先生、相山女学園大学情報社会学部 教授 向直人先生に、多くの議論の機会をいただいた。専門分野の異なる立場からのご指摘は研究内容を客観的に見直すきっかけとなり、本研究の質を高める上で大きな助けとなった。

地理空間情報を扱う分析に関しては、愛知大学地域政策学部 教授 蔣湧先生より、分析手法に関する多くのアイデアや既存研究のご紹介をいただいた。地理空間分析の専門的視点からのご指摘は、人工知能を主軸とする本研究に新しい視野をもたらし、研究の枠組みを広げる上で重要な役割を果たした。

研究成果に関して、金城学院大学 中村正治先生、南山大学大学院 澤木勝茂先生、愛知工業大学 中川覃夫先生、東京都立産業技術大学院大学 石井直宏先生には、書籍執筆の機会を与えていただいた。また、愛知大学経営学部 教授 木村充位先生には、交通事故データの信頼性に関する論文執筆の機会をいただいた。これらの経験は、本研究を客観的に整理し、社会的文脈の中で位置付ける上で貴重な機会となった。

防災に関する研究を進めるにあたり、福知山公立大学情報学部 教授 畠中利治先生、ならびに同大学地域防災研究センター 教授 水口学先生には、消防署における実務的観点からの助言をいただいた。加えて、実際に消防署の方々と意見交換する機会を設けていただいたことは、本研究におけるモデル化の妥当性を検討する上で重要な示唆を与えるとともに、実務において求められる水準や制約条件を理解する貴重な機会となった。また、株式会社アイ・ツー 代表 松崎秀規氏には、能登半島における震災の復興状況に触れる機会を提供いただいた。実際に被災地の状況や、住まいを失い困難な状況に置かれている方々の現状を目の当たりにすることで、本研究の成果が向かう先や、社会にどのように還元されるべきかを強く意識する契機となった。

ロボカップレスキューシミュレーションを対象とした研究においては「AIT-Rescue2024」のメンバーとして、前田綾也氏、上原温揮氏、藤澤丈氏、松永一希氏、鈴木涼介氏、藤井駿太郎氏、加藤幸太氏に、多くの議論と協力をいただいた。また、これに加え、島田優希氏にはシミュレーションを繰り返し実行するための計算環境および計算機インフラに関して、助言と協力をいただいた。

さらに、膨大な数の地図データの作成、救助戦略と活動との関係について熱心に議論いただいた上田陽明氏、シミュレーション可視化システム構築を通じて多くの支援をいただいた山本竜甲氏、さまざまなシナリオにおけるデータ収集に協力いただいた新美舜也氏に感謝申し上げます。

交通事故分析に関する研究については、立ち上げ段階から熱心に議論いただいた加藤翔馬氏、統計理論を

中心に刺激的な議論と的確な意見を賜り、リスク推定モデルの構築に大いに貢献いただいた國吉佑輔氏，ならびにモデル改善に協力いただいた小野木夏樹氏に深く感謝する。

さらに，交通事故分析の実験環境構築やモデル実装に協力いただいた波多野良氏，分析手法や論文執筆に関して助言をいただいた清水和彦氏，岡本愛氏に感謝申し上げます。

日頃より研究について活発な議論をいただいた，小島大征氏，酒井淑成氏，長谷川滉氏，鈴木宏哉氏，中尾望氏，伴昌樹氏をはじめとする伊藤暢浩研究室の皆様のご存在は，研究生生活を支える大きな力となった。

交通事故データを提供いただいた愛知県警察本部，交通量データを提供いただいた日本道路交通情報センターに感謝申し上げます。

また，ロボカップレスキューシミュレーションの環境および運営に関して，ロボカップコミュニティの皆様，特に，サン＝テティエンヌ国立高等鉱業学校 ルイス先生より多くの技術的支援をいただいた。加えて，本研究に関わる実装では，R 言語コミュニティの皆様，特に徳島大学デザイン型 AI 教育研究センター 助教 瓜生真也先生，伊東生態統計研究室 伊東宏樹氏には，開発に関する多くの示唆を賜った。

最後に，長きにわたり研究生生活を支えてくれた家族に心より感謝する。

参考文献

- [1] Brenno Moura Castro, Marcelo De Miranda Reis, and Ronaldo Moreira Salles. Multi-agent simulation model updating and forecasting for the evaluation of COVID-19 transmission. *Scientific Reports*, Vol. 12, No. 1, pp. 1–18, December 2022. (3, 7 ページで参照)
- [2] 野田 五十樹. マルチエージェント社会シミュレーションとリアリティ. *人工知能*, Vol. 39, No. 3, pp. 306–313, 2024. (3 ページで参照)
- [3] Stuart Russel and Peter Norvig. *Artificial Intelligence: A Modern Approach*. Pearson, 4th edition edition, 2021. (6, 8, 38 ページで参照)
- [4] Marvin Minsky. *心の社会*. 産業図書, 1990. (6 ページで参照)
- [5] 高玉 圭樹. マルチエージェント学習: 相互作用の謎に迫る. コロナ社, 2003. (8 ページで参照)
- [6] RoboCupRescue Simulation. Agent Simulation. <https://rescuesim.robocup.org/competitions/agent-simulation-competition/>. Accessed on 2025-06-19. (12, 30 ページで参照)
- [7] 国土交通省. 道路啓開とは. <https://www.mlit.go.jp/road/bosai/measures/index4.html>. Accessed on 2025-09-05. (16 ページで参照)
- [8] Cameron Skinner and Sarvapali Ramchurn. The RoboCup rescue simulation platform. In *Proceedings of the 9th International Conference on Autonomous Agents and Multiagent Systems: Volume 1 - Volume 1*, pp. 1647–1648. International Foundation for Autonomous Agents and Multiagent Systems, 2010. (21 ページで参照)
- [9] ringo-ringo-ringo. ringo-viewer (GitHub). <https://github.com/ringo-ringo-ringo/ringo-viewer>. Accessed on 2025-09-07. (22 ページで参照)
- [10] Rodney Allen Brooks. A robust layered control system for a mobile robot. *IEEE Journal on Robotics and Automation*, Vol. 2, No. 1, pp. 14–23, 1986. (23 ページで参照)
- [11] Shunki Takami, Kazuo Takayanagi, Shivashish Jaishy, Nobuhiro Ito, and Kazunori Iwata. Design of Agent Development Framework for RoboCupRescue Simulation. In Roger Lee, editor, *Computational Science/Intelligence and Applied Informatics*, pp. 185–199. Springer International Publishing, July 2018. (24 ページで参照)
- [12] RoboCup Rescue Simulation Organizers. Agent Simulation Competition Rules: RoboCup 2022 (Version 2.0), January 2022. (24, 56 ページで参照)
- [13] RoboCupRescue Simulation. RSL21ScoreFunction (roborescue/rcrs-server). <https://github.com/roborescue/rcrs-server/blob/master/modules/standard/src/rescuecore2/standard/score/RSL21ScoreFunction.java>. Accessed on 2025-08-19. (30 ページで参照)
- [14] Keisuke Ando, Ryoya Maeda, Haruki Uehara, Joe Fujisawa, Itsuki Matsunaga, Ryosuke Suzuki, Kota Kato, Yuki Shimada, Shuntarou Fujii, Takeshi Uchitane, Kazunori Iwata, and Nobuhiro Ito.

- Designing a rescue strategy emphasizing distributed control in RoboCupRescue simulation. In Edna Barros, Josiah P. Hanna, Hiroyuki Okada, and Elena Torta, editors, *RoboCup 2024: Robot World Cup XXVII*, pp. 436–447, Cham, April 2025. Springer Nature Switzerland. (31 ページで参照)
- [15] David Arthur and Sergei Vassilvitskii. *k-means++*: The Advantages of Careful Seeding. In *Proceedings of the Eighteenth Annual ACM-SIAM Symposium on Discrete Algorithms*, Soda '07, pp. 1027–1035. Society for Industrial and Applied Mathematics, 2007. (43, 44 ページで参照)
- [16] James MacQueen. Some methods for classification and analysis of multivariate observations. In *Proceedings of the 5th Berkeley Symposium on Mathematical Statistics and Probability*, Vol. 1, pp. 281–297, 1967. (43 ページで参照)
- [17] Harold William Kuhn. The Hungarian method for the assignment problem. *Naval Research Logistics Quarterly*, Vol. 2, pp. 83–97, 1955. (44 ページで参照)
- [18] Leonard Kleinrock. Birth-Death Queueing Systems in Equilibrium. In *Queueing Systems*, No. Volume I, pp. 89–114. John Wiley & Sons, 1975. (51 ページで参照)
- [19] RoboCupRescue Simulation. *adf-sample-agent-java* (GitHub). <https://github.com/roborescue/adf-sample-agent-java>. Accessed on 2025-09-26. (52 ページで参照)
- [20] AIT-Rescue. *ait-rescue* (GitHub). <https://github.com/NONONOexe/ait-rescue>. Accessed on 2025-09-26. (52 ページで参照)
- [21] Keisuke Ando, Takeshi Uchitane, Kazunori Iwata, Nobuhiro Ito, Yong Jiang, and Naohiro Ishii. Social Simulations Using Multi-agent Systems. In *Probability and Statistical Models in Operations Research, Computer and Management Sciences: Including Applications to Reliability Models*, pp. 117–133. Springer Nature Switzerland, 2024. (56 ページで参照)
- [22] 伊藤 暢浩, 岩田 員典, 額 寛明. 偏相関分析による地図の特徴指標とマルチエージェントシステム評価値の分析. *知能と情報*, Vol. 26, No. 3, pp. 658–668, 2014. (57 ページで参照)
- [23] Kazunori Iwata, Nobuhiro Ito, Hiroaki Koketsu, and Naohiro Ishii. Analyzing Map Features and Building Information for Disaster Response Using Agent-Based Simulations. *Knowledge-Based and Intelligent Information and Engineering Systems*, Vol. 6883, pp. 616–626, 2011. (57 ページで参照)
- [24] Keisuke Ando, Haruaki Ueda, Takeshi Uchitane, Kazunori Iwata, and Nobuhiro Ito. Applying covariance structure analysis to reveal relationships between agent capability and map characteristics in robocup rescue simulation. <https://cdn.robocup.org/rsim/public/workshops/2021-waisdm/andoEtA12021-waisdm.pdf>, 2021. 2021 Workshop on Artificial Intelligence and Simulation for Natural Disaster Management Accessed on 2025-10-06. (58 ページで参照)
- [25] 金月 寛彰, 服部 宏充. マルチエージェントシミュレーションによるタクシー営業戦略の改善シナリオの提案. *人工知能学会論文誌*, Vol. 34, No. 3, pp. 1–9, 2019. (62 ページで参照)
- [26] WHO and the UN regional commissions. Global Plan for the Decade of Action for Road Safety 2021–2030. <https://www.who.int/publications/m/item/global-plan-for-the-decade-of-action-for-road-safety-2021-2030>, October 2021. Accessed on 2025-08-14. (63 ページで参照)
- [27] 内閣府, 中央交通安全対策会議. 交通安全基本計画—交通事故のない社会を目指して. https://www8.cao.go.jp/koutu/kihon/keikaku11/pdf/kihon_keikaku.pdf, March 2021. Accessed on 2025-10-09. (63, 64 ページで参照)

- [28] 内閣府. 令和7年交通安全白書. https://www8.cao.go.jp/koutu/taisaku/r07kou_haku/zenbun/index.html, June 2025. Accessed on 2025-10-09. (63, 125 ページで参照)
- [29] 国土交通省, 交通政策審議会陸上交通分科会自動車部会. 交通事故のない社会を目指した今後の車両安全のあり方について. https://www.mlit.go.jp/en/jidosha/vehiclesafety/report_the_future_of_vehicle_safety_jp.pdf, June 2021. Accessed on 2025-10-09. (64 ページで参照)
- [30] 警察庁. 平成29年版警察白書—特集 交通安全対策の歩みと展望. https://www.npa.go.jp/hakusyo/h29/pdf/pdf/03_tokusyu.pdf, 2017. Accessed on 2025-10-09. (64 ページで参照)
- [31] 朝日新聞. 交通事故死者数、8年ぶりに増加 2年連続で大阪が最多、最少は佐賀. <https://www.asahi.com/articles/ASS146JG1S14UTIL00F.html?msockid=1428b5d5a9396c403607a02da8586d55>, January 2024. Accessed on 2025-10-09. (64 ページで参照)
- [32] 警察庁. 自転車用ヘルメットの着用. <https://www.keishicho.metro.tokyo.lg.jp/kotsu/jikoboshi/bicycle/menu/helmet.html>, February 2025. Accessed on 2025-10-09. (64 ページで参照)
- [33] 警察庁. 特定小型原動機付自転車に関する交通ルール等について. https://www.keishicho.metro.tokyo.lg.jp/kotsu/jikoboshi/electric_mobility/electric_kickboard.html, June 2025. Accessed on 2025-10-09. (64 ページで参照)
- [34] 警察庁. 道路交通法の改正について (青切符についても含む). https://www.keishicho.metro.tokyo.lg.jp/kotsu/jikoboshi/bicycle/cycle_kaisei.html, September 2025. Accessed on 2025-10-09. (64 ページで参照)
- [35] 警察庁. ゾーン30とは? https://www.keishicho.metro.tokyo.lg.jp/kotsu/doro/zone30/about_zone30.html, March 2025. Accessed on 2025-10-09. (64 ページで参照)
- [36] 警察庁. 年報, 交通事故死者数について. <https://www.npa.go.jp/publications/statistics/koutsuu/toukeihyo.html>, 2025. Accessed on 2025-10-11. (65 ページで参照)
- [37] 愛知県警察本部交通部. 愛知の交通事故. <https://www.pref.aichi.jp/police/koutsu/jiko/koutsu-s/documents/aichikoutsujiko2024.pdf>, 2025. (Accessed on 2025-10-13). (65 ページで参照)
- [38] 警察庁, 交通企画課. 人口10万人当たりの交通事故発生状況 (e-stat, 2024年分). https://www.e-stat.go.jp/stat-search/files?stat_infid=000040249645, 2025. (Accessed on 2025-10-13). (65 ページで参照)
- [39] 国土交通省. 自動車保有台数 (e-stat, 2024年12月分). https://www.e-stat.go.jp/stat-search/files?stat_infid=000040252806, 2025. (Accessed on 2025-10-13). (65, 66 ページで参照)
- [40] 愛知県交通安全対策会議. 第11次愛知県交通安全計画—交通事故のない社会を目指して. <https://www.pref.aichi.jp/uploaded/attachment/393644.pdf>, 2021. (Accessed on 2025-10-13). (65, 66 ページで参照)
- [41] 警察庁交通局運転免許課. 運転免許統計. <https://www.npa.go.jp/publications/statistics/koutsuu/menkyo.html>, 2025. (Accessed on 2025-10-13). (67 ページで参照)
- [42] 山田 晴利, 柴崎 亮介, Teerayut, Horanont, 西田 泰, 下村 静喜, 塩田 誠, 知花 要. 事故発生位置情報を用いた事故分析総合システムの研究開発. 道路政策の質の向上に資する技術研究開発 成果報告レポート 25-3, 国土交通省, 新道路技術会議, 2016. (68, 71, 72, 75 ページで参照)
- [43] 山田 怜旺, 鈴木 弘司. 交通事故対策の多角的検討に資する事故データベースの構築と分析システムの提

- 案. 土木学会論文集 D3 (土木計画学), Vol. 78, pp. II.1-II.8, 2022. (68, 71, 72 ページで参照)
- [44] 加藤 翔馬, 伊藤 暢浩, 岩田 員典, 内種 岳詞, 向 直人. 交通事故データに基づく被害者減少に向けた一考察. 人工知能学会第二種研究会資料, Vol. 2019, No. SAI-035, pp. 09-16, 2019. (68, 71, 72, 73, 75 ページで参照)
- [45] 加藤 翔馬, 安藤 圭祐, 伊藤 暢浩, 岩田 員典, 内種 岳詞, 向 直人, 蔣 湧. 愛知県における事故件数と交通量の関係についての分析. 人工知能学会第二種研究会資料, Vol. 2020, No. SAI-039, pp. 06-13, 2020. (68, 69, 76 ページで参照)
- [46] 横関 俊也, 萩田 賢司. 千葉県の単路部における自転車事故からみた 10 年間で自転車通行方向の傾向変化. 土木学会論文集 D3 (土木計画学), Vol. 75, No. 6, pp. I.609-I.613, 2020. (68, 69, 71, 72 ページで参照)
- [47] 渡部 数樹, 中村 英樹. 道路交通環境に着目した交通事故発生要因に関する統計モデル分析. 土木学会論文集 D3 (土木計画学), Vol. 71, No. 5, pp. I.889-I.901, 2015. (69, 71, 72, 73 ページで参照)
- [48] 兵頭 知, 吉井 稔雄, 柴崎 宏武. 沿道状況に着目した幹線道路における追突事故発生リスクの地域差に関する分析. 土木学会論文集 D3 (土木計画学), Vol. 73, No. 5, pp. I.1201-I.1209, 2017. (69, 71, 72, 73 ページで参照)
- [49] 塩見 康博, 渡部 数樹, 中村 英樹, 赤羽 弘和. 交差点幾何構造を考慮した幹線道路信号交差点における交通事故リスク要因の分析. 土木学会論文集 D3 (土木計画学), Vol. 72, No. 4, pp. 368-379, 2016. (70, 71, 72, 73, 136 ページで参照)
- [50] 向 直人, 内種 岳詞, 岩田 員典, 伊藤 暢浩. 愛知県の交通事故データを利用した地図画像からの事故種別の分類. 第 18 回 ITS シンポジウム 2020, pp. 1-6, 2020. (70, 71, 72, 73 ページで参照)
- [51] 榊原 一紀, 浅井 智也, 中村 正樹, 本吉 達郎, 星川 圭介. 形式概念分析と機械学習による交通事故の分析と予測: 富山県の取り組みを例に. オペレーションズ・リサーチ: 経営の科学, Vol. 69, No. 5, pp. 247-253, 2024. (70, 71, 72 ページで参照)
- [52] 国土交通省. 全国道路・街路交通情勢調査 (道路交通センサス), 道路関係データ (交通量・旅行速度・渋滞 等). <https://www.mlit.go.jp/road/ir/ir-data/ir-data.html>, 2023. (Accessed on 2025-10-26). (74 ページで参照)
- [53] 国土交通省. 国土数値情報 ダウンロードサイト. <https://nlftp.mlit.go.jp/>, 2025. (Accessed on 2025-10-21). (74 ページで参照)
- [54] 日本デジタル道路地図協会. データの内容. <https://www.drm.jp/database/content/>, 2025. (Accessed on 2025-10-21). (74 ページで参照)
- [55] Keisuke Ando, Kazuhiko Shimizu, Nobuhiro Ito, Kazunori Iwata, Takeshi Uchitane, Naoto Mukai, and Yong Jiang. Design of Geospatial Database for Analysis of Road Traffic Accidents in Aichi Prefecture. In *2022 Joint 12th International Conference on Soft Computing and Intelligent Systems and 23rd International Symposium on Advanced Intelligent Systems (SCIS&ISIS)*, pp. 1-7, 2022. (74 ページで参照)
- [56] 地域メッシュ統計の特質・沿革. <https://www.stat.go.jp/data/mesh/pdf/gaiyo1.pdf>, 2019. (Accessed on 2025-11-09). (76, 111 ページで参照)
- [57] 北川 博之. データベースシステム. オーム社, 改訂 2 版, 2020. (76, 77 ページで参照)
- [58] Open Geospatial Consortium (OGC) and International Organization for Standardization (ISO). OpenGIS® implementation standard for geographic information - simple feature access. <https://www.ogc.org/standards/sfa/>, 2025. (77 ページで参照)

- [59] OpenStreetMap Foundation. OpenStreetMap. <https://www.openstreetmap.org/>, 2025. (78 ページで参照)
- [60] Shinya Uryu. jpmesh: Utilities for japanese mesh code, 2023. R package version 2.1.0.9000 (Accessed on 2025-10-27). (81 ページで参照)
- [61] Ando Keisuke, Uchitane Takeshi, Mukai Naoto, Iwata Kazunori, Ito Nobuhiro, and Jiang Yong. Nononoexe/rtadb: Database for analysis of road traffic accidents. <https://github.com/NONONOexe/rtadb>, 2023. (Accessed on 2025-10-27). (81 ページで参照)
- [62] Sam Lau, Joseph Gonzalez, and Deborah Nolan. *Learning Data Science: Data Wrangling, Exploration, Visualization, and Modeling with Python*. O’Reilly Media, 2023. (82 ページで参照)
- [63] Hadley Wickham, Mine Çetinkaya-Rundel, and Garrett Grolemund. *R for Data Science: Import, Tidy, Visualize, and Model Data*. O’Reilly Media, 2nd edition edition, 2023. (82 ページで参照)
- [64] Zhixiao Xie and Jun Yan. Kernel Density Estimation of traffic accidents in a network space. *Computers, Environment and Urban Systems*, Vol. 32, No. 5, pp. 396–406, 2008. (88 ページで参照)
- [65] Zhixiao Xie and Jun Yan. Detecting traffic accident clusters with network kernel density estimation and local spatial statistics: An integrated approach. *Journal of Transport Geography*, Vol. 31, pp. 64–71, 2013. (90, 102, 103, 123 ページで参照)
- [66] Benjamin Romano and Zhe Jiang. Visualizing Traffic Accident Hotspots Based on Spatial-Temporal Network Kernel Density Estimation. In *Proceedings of the 25th ACM SIGSPATIAL International Conference on in Geographic Information Systems*, 2017. (91 ページで参照)
- [67] Atsuyuki Okabe, Toshiaki Satoh, and Kokichi Sugihara. A kernel density estimation method for networks, its computational method and a GIS-based tool. *International Journal of Geographical Information Science*, Vol. 23, No. 1, pp. 7–32, 2009. (93, 99 ページで参照)
- [68] Jérémy Gelb and Philippe Apparicio. Temporal Network Kernel Density Estimation. *Geographical Analysis*, Vol. 56, No. 1, pp. 62–78, January 2024. (93, 95 ページで参照)
- [69] Keisuke Ando, Yusuke Kuniyoshi, Kazuhiko Shimizu, Takeshi Uchitane, Naoto Mukai, Kazunori Iwata, Nobuhiro Ito, and Yong Jiang. Spatio-temporal Network Analysis for Detecting Traffic Accident Clusters. In *2023 14th IIAI International Congress on Advanced Applied Informatics (IIAI-AAI)*, pp. 257–262, 2023. (94 ページで参照)
- [70] Keisuke Ando, Yusuke Kuniyoshi, Natsuki Onogi, Takeshi Uchitane, Naoto Mukai, Kazunori Iwata, Nobuhiro Ito, and Yong Jiang. Cluster Detection for Traffic Accidents on Spatiotemporal Networks. *Procedia Computer Science*, Vol. 246, pp. 371–380, 2024. (94 ページで参照)
- [71] Spencer Chainey, Lisa Tompson, and Sebastian Uhlig. The Utility of Hotspot Mapping for Predicting Spatial Patterns of Crime. *Security Journal*, Vol. 21, No. 1, pp. 4–28, 2008. (94, 107 ページで参照)
- [72] Luc Anselin. Local Indicators of Spatial Association—LISA. *Geographical Analysis*, Vol. 27, No. 2, pp. 93–115, April 1995. (96, 97 ページで参照)
- [73] Peter Diggle. A Kernel Method for Smoothing Point Process Data. *Journal of the Royal Statistical Society. Series C (Applied Statistics)*, Vol. 34, No. 2, pp. 138–147, 1985. (101 ページで参照)
- [74] Elke Moons, Tom Brijs, and Geert Wets. Improving Moran’s Index to Identify Hot Spots in Traffic Safety. In *Geocomputation and Urban Planning*, pp. 117–132. Springer, 2009. (102 ページで参照)

- [75] Ando (maintainer) Keisuke, Uchitane Takeshi, Mukai Naoto, Iwata Kazunori, Ito Nobuhiro, and Jiang Yong. pavement: Analyzing spatial events on roadways, 2025. R package version 0.2.1 (Accessed on 2025-11-08). (104 ページで参照)
- [76] 所 正文. 交通事故の発生要因と運転行動メカニズム. 国土舘大學政経論叢, No. 91, pp. 45–67, 1995. (109 ページで参照)
- [77] 安藤 圭祐, 國吉 佑輔, 清水 和彦, 岡本 愛, 伊藤 暢浩, 岩田 員典, 内種 岳詞, 向 直人, 蔣 湧. 愛知県の交通事故発生区域のクラスタ分析. 人工知能学会第二種研究会資料, Vol. 2021, No. SAI-42, pp. 1–7, 2021. (110 ページで参照)
- [78] 島田 亮. 新型コロナウイルス感染症の感染拡大に伴う移動制限下での交通事故の発生件数、負傷者数および死亡者数の変化. IATSS Review (国際交通安全学会), Vol. 46, No. 1, pp. 16–21, 2021. (111 ページで参照)
- [79] 帳 長平. 増補版 地理情報システムを用いた空間データ分析. 古今書院, 2009. (113 ページで参照)
- [80] T. コホネン. 自己組織化マップ. 丸善出版, 改訂版, 2012. (114, 115 ページで参照)
- [81] Vahid Gholami, Hossein Sahour, and Mohammad Ali Hadian Amri. Mapping soil erosion rates using self-organizing map (som) and geographic information system (gis) on hillslopes. *Earth Science Informatics*, Vol. 13, pp. 1175–1185, 2020. (114 ページで参照)
- [82] Richard D. Lawrence, G.S. Almasi, and Holly E. Rushmeier. A scalable parallel algorithm for self-organizing maps with applications to sparse data mining problems. *Data Mining and Knowledge Discovery*, Vol. 3, No. 2, pp. 171–195, 1999. (116 ページで参照)
- [83] Ron Wehrens and Johannes Kruisselbrink. kohonen: Supervised and unsupervised self-organising maps. <https://cran.r-project.org/web/packages/kohonen/index.html>. Accessed on 2025-11-10. (116 ページで参照)
- [84] 長久手市. ゾーン 30 実施区域のお知らせ. <https://www.city.nagakute.lg.jp/soshiki/kurashibunkabu/anshinanzenka/1/2/kotuanzen/kuruma/3212.html>, 2020. Accessed on 2025-11-12. (118 ページで参照)
- [85] David L. Davies and Donald W. Bouldin. A cluster separation measure. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. PAMI-1, No. 2, pp. 224–227, 1979. (119 ページで参照)
- [86] pgRouting Community. pgrouting. <https://pgrouting.org/>, 2025. Accessed on 2025-11-12. (123 ページで参照)
- [87] Michael F. Land and Benjamin W. Tatler. Steering with the head. *Current Biology*, Vol. 11, No. 15, pp. 1215–1220, 2001. (125 ページで参照)
- [88] 尾杉 竜正, 岡藤 勇希, 和田 隆広. 深層学習を用いた車両の速度制御に関するドライバの認知特性の解析. 自動車技術会論文集, Vol. 52, No. 2, pp. 355–362, 2021. (125 ページで参照)
- [89] 赤羽 弘和, 坂田 裕彦, 畔田 雅裕, 南部 繁樹, 鶴田 翔太, 清水 佑馬. 高速道路の事故多発 S 字曲線区間における車両走行挙動と道路線形の関係分析. 交通工学論文集, Vol. 8, No. 2, pp. A_291–A_299, 2022. (125 ページで参照)
- [90] 安藤 圭祐, 内種 岳詞, 向 直人, 岩田 員典, 伊藤 暢浩. 愛知県における交通事故特徴の空間分析. 信学技報, Vol. 123, No. 412, pp. 12–17, 2024. (125 ページで参照)

索引

あ 行

愛知県交通安全計画 65
 アルゴリズムモジュール 25
 依存エンティティ 78
 一様カーネル 87
 ウォード法による階層的クラスタリング 115
 右直事故 129
 エージェント 6
 エージェントシミュレーションコンペティション 30
 エージェントプログラム 8
 エパネチニコフカーネル 100
 エポック 114
 エンティティ (データベース) 76
 エンティティ (ロボカップレスキューシミュレーション) 13
 オープンセット 38

か 行

カーディナリティ 77
 カーネル 21, 87
 カーネル密度推定 86
 ガウシアンカーネル 87
 確率密度関数 86
 可視化 83
 完全空間ランダム性 98
 基準地域メッシュ 111
 救急隊エージェント 16
 救出 15
 救助行動制御モジュール 27
 救助戦略 12
 救助対象検出モジュール 26
 救助部隊エージェント 15
 境界効果 101
 共分散構造分析 58
 許容性 40
 クイーン型 96
 空間カーネル密度推定 88
 空間データ 76
 空間的自己相関 89
 空間分析 75
 空間ラグ 97
 区間交通量 74
 矩形啓開 17

クラスタリングモジュール 25
 グループ形成 24
 クローズドセット 38
 啓開 16
 啓開行動決定モジュール 27
 啓開対象検出モジュール 26
 経路探索 24
 経路探索モジュール 25
 交通安全基本計画 64
 交通安全研究 67
 交通事故 63
 交通事故データ分析システム 84
 交通事故データベース 74
 交通事故統計 67
 交通戦争 63
 行動 7
 行動制御プログラム 26
 行動制御モジュール 27
 国土数値情報 74
 個別啓開 18
 コンテナ 84

さ 行

サービス率 51
 災害シナリオ 22
 サブシミュレータ 21
 サンプルエージェント 52
 サンプルデータベース 80
 ジオメトリ 76
 時間カーネル 92
 時空間カーネル 92
 時空間セグメント 91
 時空間自己相関 95
 時空間ネットワーク 91
 時空間ネットワークカーネル密度推定 91
 自己組織化マップ 110
 事故リスク 86
 死亡事故 63
 シミュレーションステップ 12
 市民エージェント 14
 重要道路 45
 情報共有 24
 情報収集 24
 消防隊エージェント 15
 指令所エージェント 19

人身事故 63

整然化 83

整然データ 83

設定データ 22

戦略設計プロセス 9

戦略プログラム 22

戦略モジュール 22

ゾーン 30 64

ゾーン 30 プラス 64

属性データ 76

た 行

対象検出モジュール 26

第二次交通戦争 64

タスク割り当て 24

建物 20

探索的データ分析 82

探索モジュール 26

断面交通量 74

地域メッシュ統計 76

知覚 7

地図データ 22

地物 75

チャンネルサブスクライバー 28

地理空間データ 75

地理空間データ型 77

地理空間データベース 76

通信プログラム 27

通信モジュール 28

データ探索 82

的中率 107

当事者 68

当事者順位 68

到着率 51

等分割カーネル 93

等分割連続カーネル 93

道路 20

道路交通事故 63

道路交通センサス (全国道路・街路交通情勢調査)
74

特徴量重要度 133

独立エンティティ 78

都市価値 57

都市価値維持率 57

土木隊エージェント 16

な 行

ネットワークカーネル 89

ネットワークカーネル密度推定 89

ノンパラメトリック 86

は 行

配置データ 22

ハンガリアンアルゴリズム 44

搬出 16

搬送行動決定モジュール 27

搬入 16

避難所 16

ヒューリスティック関数 38

評価プロセス 9

標準問題 24

複合モジュール 26

物損事故 63

負の二項分布 69

分散型協調戦略 31

並列バッチ自己組織化マップ 116

ベースカーネル 100

変換 83

ホットスポット 86

ま 行

マクロ的分析 70

待ち行列モデル $M/M/c$ 51

マップ空間 114

マルチエージェントシステム 6

マルチエージェントシミュレーション 6

ミクロ的分析 70

メッセージコーデイナータ 28

メッセージバンドル 28

メッセージマネージャ 28

メンガーの曲率 130

面積率 107

モデリング 83

モデル化プロセス 9

モラン散布図 97

モランの測度 I 113

ら 行

利用率 51

旅行速度 74

リレーショナルデータベース 76

リレーション 76

ルーク型 96

ルンバ 23

レスキューシミュレーションリーグ 30

ローカルモラン統計量 90

ロボカップレスキューシミュレーション 12

わ 行

ワールドモデル 22

英 数

- A* アルゴリズム 38
- ADF 23
- AIT-Rescue 30
- arixel 91
- ChannelSubscriber 28
- ClearSimulator 22
- Clustering 25
- CollapseSimulator 22
- CommunicationModule 28
- Crow's Foot Notation 77
- DBI 119
- DBSCAN 134
- Docker 84
- DRM データ 74
- ER 図 76
- ExtAction 27
- ExtActionClear 27
- ExtActionRescue 27
- ExtActionTransport 27
- GeoPandas 82
- GIS 22
- Hadley Wickham 82
- HumanDetector 26
- ITARDA 67
- JARTIC (日本道路交通情報センター) 74
- jpmesh 81
- kohonen 116
- k-means 法 43
- k-means++ 法 43
- LISA クラスタマップ 97
- LISTA クラスタマップ 97
- LogViewer 22
- Mapbox 74
- MessageBundle 28
- MessageManager 28
- MiscSimulator 22
- OpenStreetMap 78
- PAI 94
- PathPlanning 25
- pavement 104
- pgRouting 123
- PostGIS 81
- PostgreSQL 81
- QGIS 82
- R (プログラミング言語) 81
- RefugeSelector 52
- ringo-viewer 22
- RoadDetector 26
- Rodney Brooks 23
- RRS-ADF 23
- RSL21 スコア関数 30
- RStudio Server 84
- Search 26
- sf 81
- Simple Features 77
- Tactics 22
- TargetDetector 26
- tidyverse 84
- TrafficSimulator 22
- Viewer 22
- 2 進の重み係数 96