

複雑性を有する社会シミュレーションに対する
最適化手法の応用に関する研究

2023年03月

柿本 陽平

Abstract

Social simulation is a method used to reproduce global trends appeared by the interactions of autonomous agents in a large-scale space designed for the real world. In general, if a social simulation is conducted to predict an impact or effect that a specific measure has on society, the dimension and range of the input data should be complex. The multi-agent system (MAS) is the conventional method used to make predictions in social simulations.

The MAS is widely used and recognized with the development of calculators. In complex social simulations, it is essential to make outputs converge by numerous simulations because the autonomous agents responsible for constructing society possess uncertainty. Meanwhile, since the space evaluated by complex social simulations is essentially large-scale, considerable computation cost is required to eliminate uncertainty. Additionally, if the multiple measures that must be verified are confirmed to exist, then numerous scenarios can be generated by combining various measures. To verify the effects of these numerous scenarios, the uncertainty should be eliminated. Further, the considerable computation cost poses a significant problem if the conventional MAS is used to predict the effects of multiple measures in the real world.

This thesis proposes optimization methods that are less affected by the uncertainty within the complex systems that structure society and reduce the computational cost of the social simulation. First, conventional MAS is reviewed to reveal its limitations and reliability. Then, to solve the limitations of conventional MAS, this thesis considers applying integer programming for social simulation. Integer programming is one of the optimization methods used to obtain a unique solution. Moreover, this thesis constructs a versatile framework to quickly identify a measure that impacts society is constructed by applying machine learning to the MAS that contains uncertainty. Finally, the method's construction is examined, taking into consideration the effect of scattered small-scale space on society for in increasing prediction accuracy for large-scale simulation.

Contents

1	序論	4
1.1	社会シミュレーション	4
1.1.1	決定論的手法	5
1.1.2	確率論的手法	7
1.2	研究目的	8
1.3	本論文の構成	9
2	Multi-agent システム	12
2.1	緒言	12
2.2	MAS シミュレータ: 感染症拡大に対する MAS	13
2.2.1	感染症の伝搬	13
2.2.2	シミュレーションの流れ	17
2.3	ODE による感染症数理モデル	18
2.4	MAS シミュレータの信頼性評価	19
2.5	数値実験	22
2.5.1	実験条件	22
2.5.2	結果および考察	22
2.6	結言	26
3	整数計画法による社会シミュレーションの定式化	27
3.1	緒言	28
3.2	Location set covering model	30
3.3	モデル定式化	30
3.3.1	Rest-area location model	30
3.3.2	Rest-area location model for time-driven demands	31
3.3.3	各種問題の複雑性	35
3.4	数値実験	36
3.4.1	小規模仮想ネットワークを用いた予備実験	37
3.4.2	RALMTD の評価	38
3.5	結言	43

4	機械学習モデルによる高速なシナリオ選定のための枠組み	46
4.1	緒言	46
4.2	先行研究	49
4.3	シナリオ選定のための枠組み	51
4.3.1	枠組みの概要	51
4.3.2	感染症拡大を表現する MAS シミュレータ	52
4.3.3	Support vector regression	55
4.4	数値実験	56
4.4.1	実験方法	56
4.4.2	ハイパーパラメータチューニング	58
4.4.3	結果と考察: MAS-ML の検証	60
4.4.4	結果と考察: MADE との比較	64
4.4.5	結果と考察: 自宅待機命令に対する感度分析	65
4.5	結言	65
5	小規模空間に対するシミュレーション	67
5.1	緒言	67
5.2	飲食店における感染リスク	69
5.3	感染リスクの増加を抑える座席割当モデル	71
5.3.1	感染リスクを抑制するパラメータ θ	71
5.3.2	座席割当手法	73
5.3.3	提案モデルのフローチャート	77
5.4	数値実験	78
5.4.1	実験の目的と概要	78
5.4.2	結果と考察	83
5.5	結言	88
6	大規模空間に対する小規模シミュレータ導入のための地域分類	89
6.1	緒言	89
6.2	分析手法	90
6.2.1	対象地域の概要と利用データ	90
6.2.2	カーネル密度推定	91
6.2.3	対数尤度 Cross validation	92

6.3	数値実験	93
6.3.1	実験方法	93
6.3.2	バンド幅 h の決定	94
6.3.3	実験結果と考察	95
6.4	結言	98
7	結論	100
7.1	本研究の貢献	100
7.2	総括	101
	謝辞	103
	参考文献	104
	業績リスト	117

Table list

2.1	Simulation conditions of MAS / basic parameters	17
2.2	Simulation conditions of MAS / variables parameters	21
2.3	Reliability verification of MAS based on comparison with ODE	25
3.1	The number of variables by the models	36
3.2	Objective values and computation time by capacity and expendable time of facilities.	42
4.1	Advantages and disadvantages of each simulation method.	52
4.2	Parameters of the MAS-based simulator for infectious disease transmission.	53
4.3	Input configuration parameters of the ML training dataset.	54
5.1	Standard deviation σ of cumulative infection risk ratio obtained by the non-interventional model (100 trials)	83
5.2	Ratio of outputs obtained by the proposed model with parameter $\theta = 1.00$ and the non-interventional model by distance parameter h	88
6.1	Overview of Narashino city	90

Figure list

1.1	Diagram of the thesis structure	11
2.1	Transition model of infection states	13
2.2	MAS-based simulator	16
2.3	The outputs of infection spread dynamics (left: MAS, center: ODE, right: ODE's optimal params.)	24
3.1	(a) Small network consisted of 25 nodes (b) Divided network by time steps based on (a).	37
3.2	Location of facilities and movement locus of vehicles.	38
3.3	Example of movement locus.	39
3.4	Network instance based on highway network around Tokyo, Japan. (a) Nodes and edges. (b) Including color depth expressing the number of freight vehicles.	40
3.5	Aggregation method.	40
3.6	Optimal location. (a) RALM; (b) RALMTD with $c_i = 100, \forall i \in I$	43

3.7	Location of facilities and the maximum number of freight vehicles by each capacity.	44
4.1	Diagram of the MAS-ML framework.	51
4.2	Flowchart of hyperparameter tuning.	59
4.3	Prediction results for random sampling and outlier test dataset.	60
4.4	Determination coefficients obtained for different numbers of random seeds. When a large number of random seeds are used for averaging, the randomness is removed and the determination coefficients become stable and have high values.	61
4.5	Averages and standard deviations of the MAS-based simulation computation time for varying population scale and infection rate configurations. Color depth indicates time length; standard deviation values are shown in brackets.	62
4.6	Determination coefficient R^2 transition of MADE for connecting time t . If the simulation method is switched at the early time t , MADE excessively estimates the infection rate λ and the prediction accuracy decreases. As the computation costs by MAS increase if time t is large, this trend indicates that MADE has a trade-off structure.	63
4.7	Transition of the number of infected individuals by “reduced trip probability levels” under the “start condition” of stay-at-home. Prediction by (a) MAS and (b) MAS-ML. This implies that MAS-ML can predict the number of infected individuals who are intuitively correct for inputs that do not exist in the train dataset.	64
5.1	Flowchart of the proposed model	77
5.2	Seating chart on the virtual restaurant	78
5.3	Statical seating chart used on non-interventional model	79
5.4	Transition of comulative infection risk ratio and the number of users ratio by parameter θ	81
5.5	Comparision of simulation by (a) proposed model and (b) non-interventional model if one customer arrivals for a step (parameter $\theta = 1.00$ and extracted results until two steps elapsed from 2:00)	82
5.6	An instance of restaurant operation with the proposed model ($\theta = 0.40$, arrivals by one step: 6, extracted utill 6 steps)	85

5.7	An instance of restaurant operation with the non-interventional model (arrivals by one step: 6, extracted until 6 steps)	86
6.1	Estimation result for target A using Eq. 6.5 ($h_s = 2^{-11}, \forall s \in S$)	95
6.2	Classification of densely populated areas for target A (numerical values in brackets are representative value)	96
6.3	Estimation result for target B using Eq. 6.5 ($h_s = 2^{-11}, \forall s \in S$)	97
6.4	Classification of densely populated areas for target B (numerical values in brackets are representative value)	98
6.5	Ratio of relative density population in each facility for target A and B. Note that the numerical value in cells is ratio of column entry for row entry.	99

1 序論

1.1 社会シミュレーション

社会シミュレーションとは、多数の個体が一定のルールのもと動き、局所的に相互作用する大規模空間において大域的な動向を予測する手法である。一般に社会シミュレーションは、比較的単純な個体の活動とルールが絡み合い構成される複雑系の動態を数理モデルやコンピュータモデルにより再現する。社会シミュレーションが対象とする社会を構成する要素は、人や自動車を個体とみなすものや、それらが構成する集団を一つの個体とみなすものなど様々である。本研究においては前者の人や自動車といった単位で構成される社会を対象としている点に注意する。

社会科学におけるシミュレーション手法やその枠組みに関する研究は1960年ごろから存在したものの、前述の文脈における社会シミュレーションは1990年代からコンピュータの普及に伴い発展した[1-5]。社会シミュレーションの主な目的は、社会で起きる現象の理解と社会に対する施策効果の予測の二つである[5]。前者が目的となる場合、シミュレーションにおける相互作用のルールは理解したい現象にしばり単純であったほうが良い。一方で後者が目的である場合には、社会を精度よく再現するために複雑性を与えることが望ましい。

社会シミュレーションにより得られた出力は社会に対する施策施行などの意思決定に役立てられる。シミュレーションにより社会動態の予測を行う場合には、上述の通り入力に対する複雑性を持たせることでその精度を向上させることが必要とされる[5]。ここで入力の複雑性とは、入力次元、入力を取る範囲の広さにより決まるパラメータ空間の広さや内部状態の多様性を指す。しかし、入力に対する複雑性の向上は不確実性を増大させる側面が大きい。基本的に社会シミュレーションが対象とするのは人や人が介在する乗り物などのツールである。人の活動は複雑系であることからシミュレーションモデルを設計する場合、確率事象が介在し、社会シミュレーションの対象となる地域は規模の大きな空間を対象とすることが多い。そのため、シミュレーションの内部状態が多様であると人口規模が大きくなるにつれて膨大な処理が必要となり、確率事象の増加につながる。社会シミュレーションにおいては、このような入力の複雑性による出力の不確実性に大きな課題がある。

社会シミュレーションに対するアプローチは様々であるが、本研究においては大きく決定論的手法と確率論的手法の二つに大別する。

1.1.1 決定論的手法

決定論的手法は初期条件を決定すれば一意に出力が定まる。すなわち、社会シミュレーションにおいてはシミュレーションの初期状態を定めることで対象空間の動態の行く先が定まる。微分方程式により群衆の相互作用を表現し社会動態を予測する手法は多岐にわたり、研究されている。例えば Helbing *et al.* は歩行者の行動モデルをランジュバン方程式によりモデル化しシミュレーションする手法を提案している [6]。また、Moussaid *et al.* は群衆の中にある複数の集団同士の相互作用を考慮した群衆行動シミュレーションに関する手法を提案している [7]。さらに2019年12月のCOVID-19 感染症拡大以降、微分方程式による感染症の感染拡大シミュレーションのための手法も数多く提案されている [8–10]。

ここで本論文において特に関連のあるシミュレーションのための数理モデルとして、感染症拡大シミュレーションのための微分方程式による SIR モデルを例に取り上げる [11]。SIR モデルは次の微分方程式により記述できる。

$$\begin{aligned}\frac{dS(t)}{dt} &= -\lambda S(t)I(t), \\ \frac{dI(t)}{dt} &= \lambda S(t)I(t) - \gamma I(t), \\ \frac{dR(t)}{dt} &= \gamma I(t).\end{aligned}$$

ここで、 $S(t), I(t), R(t)$ はそれぞれ時間 t における感受性者 (susceptible), 感染者 (infectious), 回復者 (recovered) を表す。SIR モデルという名称はこれらの状態の頭文字から来ている。パラメータ λ, γ はそれぞれ感染率, 回復率を表す。SIR モデルはこのようにして記述される微分方程式を解析的あるいは数値的に解くことにより、ある期間内における感染者数の推移を予測することが可能である。

微分方程式による社会シミュレーションにおいて、社会を構成する人々の動きは単純化されている。例に挙げた SIR モデルでは感染者数の増加がパラメータ λ と感受性者と感染者の数によって決まる。これは人々の行動パターンやウイルス本体の感染力、それらの不確実性などがパラメータ λ に集約されていることを意味する。しかし現実社会において人々の行動パターンは、その時々的情勢により大きく異なり、決して一元化できるものではないことは容易に想像がつく。

人々の動きをある整数変数で表現し、その変数を複数の制約条件により制御することを考える。このとき、最大化もしくは最小化すべき評価関数を与えるとこれは整数計画法により定式化される整数計画問題となる。ここで整数計画問題を解くこ

とにより得られた評価関数の最適値はをある施策効果の指標と考えれば、これは予測のための社会シミュレーションの整数計画法による定式化とみなすことができる。本論文では、整数計画問題に対するある手法が最適性を保証する解を得るとき、その手法を決定論的手法と呼ぶ。すなわち、整数計画問題として定式化した問題に対する発見的解法は決定論的手法に含まれない点に注意する。代表的な整数計画問題として巡回セールスマン問題や配送計画問題、施設配置問題などが挙げられる [12–18]。これらの問題は制約条件を追加していくことで、微分方程式によるシミュレーション手法に比べて柔軟に社会構造を表現することができる。一般に整数計画問題はNP困難な問題として知られており、最悪計算量を多項式時間で与えることはできないとされているが、近年では計算機や問題を解くためのソルバーの性能が飛躍的に向上していることもあり、実運用での応用が非常に多くされている。対象空間の高解像度化は組み合わせ爆発を起こしてしまい、現実的な時間で問題を解くことが難しくなるが、適切な空間サイズであれば複雑な条件に対しても有効である。さらに、対象空間の不確実性を評価関数や制約条件に組み込む確率計画法 [19] やロバスト最適化 [20] などの研究も盛んである。一方でこれらの手法は微分方程式のように社会構造をあるパラメータにより単純化しなければならない場合も多く、その表現能力にはやはり限界が存在する。

これらのことから、決定論的手法による社会シミュレーションは初期条件を定めれば一意的に出力が得られるというメリットがあるが、その初期条件やルールが複雑すぎると数理モデルで表現することが現実的ではなくなるか、表現することができても計算コストの観点から実用的でないというデメリットが存在することがわかる。そのため、決定論的手法では検証したい対象を絞ってなるべく単純化した数理モデルを構築し、利用されることが多い。

一方近年では、最適化手法の一つである機械学習による社会動向の予測手法が注目を浴びている。機械学習モデルは、入力と出力の組からなる教師データを任意の手法により学習させることで構築される。学習のための手法は様々であるが、多くは入力とそれに対する出力の組を与えればモデルを作成できることから、その応用範囲は非常に広い。そのような理由から社会の動向を予測するために利用されることも多い [21, 22]。一方、十分なデータセットが存在しないと構築されたモデルの予測精度は向上しない。社会シミュレーションの予測対象である実社会では、入力構成が複雑すぎる場合十分なデータセットを蓄積することは困難である。

1.1.2 確率論的手法

社会シミュレーションに対する確率論的手法は個別のイベントを確率的に与える。代表的な手法としては、1990年代の社会シミュレーション普及のきっかけとなった Multi-agent システム (MAS) があげられる [1,5]。従来の MAS は個体のふるまいに対する不確実性を確率事象として容易に表現することが可能であり、シミュレーションに対する諸条件を詳細に与えることができるため、高い複雑性を有するシミュレーションを行うことができる。一方で従来の MAS による社会シミュレーションで得られた結果には不確実性の影響がある前提として分析する必要がある。すなわち、不確実性の影響を取り除いたシミュレーション結果を得るためには、シミュレーションを多数回の試行することにより出力のある状態に収束させる必要がある。一方で、シミュレーションの内部状態が増えると収束までに必要な試行回数も増加するため、内部状態が多様であるほど一つの入力構成に対して多くのシミュレーションを行わなければならない。さらに、入力次元が増えるとその組み合わせ、すなわち入力構成の数が指数的に増えていく。例えばある行動に対して実行するかしないか、を 0, 1 で表現するような入力を考える。ここでそのような入力が n 個存在するとすると、入力の組み合わせは 2^n となる。実際には入力の取り得る値は 2 パターンとは限らず、ある範囲で連続値を取るような場合もある。

このように従来の社会シミュレーションは、入力の複雑性と出力に対する不確実性を要因として、非常に大きな計算コストを必要とする。またこのような計算コストに関する問題により、従来の社会シミュレーション手法を用いて施策に対するある種のスクリーニングを行うことは、計算コストの面から現実的とは言えない。これらのことから、確率論的手法による従来の社会シミュレーションは単一の施策の効果を検証する能力は高いが、多くの施策に対する効果を試行錯誤的に検証することには適していないことがわかる。

なお、実際のコンピュータによる従来の MAS シミュレーションは、乱数シードを固定することにより一意的に出力が定まることから、決定論的手法であるという解釈も存在する [23]。一方で、従来の MAS は上述の通り確率事象の積み重なりによる不確実性の影響を除外するために多数の乱数シードを使用する必要があることや、そのような Multi-agent ベースのシミュレーションモデルが決定論的か確率論的であるかは解釈により変わることから [24]、本研究では従来の MAS を確率論的手法と位置づける。

1.2 研究目的

本研究では、複雑性を有する社会に対して数多くの施策の効果を迅速に予測することのできるシミュレーション手法を構築し、その有効性を示すことを大きな目的とする。その準備として、まず社会動向の予測を目的とした複雑性を有する社会シミュレーション手法である従来のMASによるシミュレーション手法のレビューと有効性の検証を行う。また、決定論的手法による複雑性を有する社会シミュレーションとして整数計画法によるMASの定式化を行い、得られた整数計画問題の複雑性と最適解を得るための計算コストについて検証をする。これらの検証では従来手法や最適化問題による複雑系の定式化の利点と欠点を明らかにする。

さらに、最適化手法の一つである機械学習と従来の確率論的アプローチによるMASを組み合わせることにより、従来の手法では難しかった入力複雑性と出力の信頼性を両立した社会シミュレーション手法の構築を目指す。機械学習とMASを組み合わせた施策選定のための枠組みに関する基本的なアイデアはLamperti *et al.*により提案されている[25,26]。一方で既存の枠組みは決定論的なMASを想定しており、MASの不確実性に対する検証がされていない。本研究で構築する枠組みは不確実性を内在するMASを想定し、出力に対してロバストな予測を行うことを可能にするものである。複雑な入力を担保しつつ、少ない計算コストにより信頼性の高い出力を得ることが可能な社会シミュレーションは、あらゆる施策の効果をスクリーニングすることができ、多様な未来予測を行うことを可能とする。本研究が目指す手法はMAASが適用可能な分野、題材であれば応用可能であり、経済、商業、福祉といったあらゆる分野への波及性が見込める。

本研究においては小規模な空間におけるシミュレーションの影響についても検討する。社会シミュレーションが対象とする大規模な空間は、小規模な空間を内在する。一般の地域社会においては商業施設や駅などが小規模空間にあたる。社会に対して任意の施策を適用する場合、その影響は小規模空間に及ぶ。すなわち、小規模空間におけるシミュレーションは高精度な施策効果の予測に必要不可欠であるといえる。そこで、小規模空間における施策効果の影響を考慮するための、決定論的アプローチによるシミュレーション手法を構築する。さらに構築した小規模空間におけるシミュレーションの影響を大規模な空間に組み込むための手法の検証を行う。

ここで本研究の目的を下記にまとめる。

- 従来のMASによる複雑性を有する社会シミュレーション手法の信頼性検証とその限界の調査

- 整数計画法による社会シミュレーションの定式化とその検証
- 確率論的アプローチによる MAS と最適化手法を組み合わせた複雑性を有する実用的な社会シミュレーション手法の確立
- 小規模な空間における不確実性の影響を受けない社会シミュレーション手法の構築と大規模空間への適用に向けた検証

1.3 本論文の構成

以下では本論文の構成について述べる。また、Fig. 1.1 に各章の位置づけを示す。

第2章では、社会シミュレーションにおける伝統的な手法の一つである確率論的アプローチによる MAS について調査する。そのために先行研究として COVID-19 感染症の感染拡大を再現する MAS によるシミュレーション手法を紹介する。さらに、伝統的な MAS によるシミュレーションの信頼性を検証するため、感染症拡大を表す微分方程式による数理モデルと比較することにより検証する。具体的には初期条件を一致させ、MAS によるシミュレーションの出力、すなわち総感染者数と、微分方程式による感染症拡大モデルとが一致することを示す。それにより両者の類似性を確認し、MAS によるシミュレーションが有効であることを示す。この成果は [27] により得られたものである。

第3章では、交通シミュレーションを題材として整数計画法による MAS の定式化とその数理モデルについて論じる。第2章で紹介する MAS はシミュレーションの過程で多数の不確実性を含む事象が存在することから、シミュレーション結果に対する一意性が保証されず、多数回の試行による不確実性の排除が必要であった。整数計画問題は解に対する最適性が保証される厳密解法を用いることで、評価関数に対する最適性が保証される。すなわち、不確実性を内在する MAS のように出力の収束性を考慮する必要がない。具体的には道路ネットワーク上で時間駆動する貨物輸送車を MAS における個体と仮定し、対象の空間内で個体が相互作用する施設の配置モデルを提案する。一般的な貨物輸送車の輸送スケジュールには遅延リスクに対処するためのバッファ時間が挿入される。もし遅延が発生せずバッファ時間が余った場合、バッファ時間は休憩施設によって適切に消化されなければならない。提案する手法は需要、すなわち個体が持つバッファ時間が時間駆動するものとみなし、休憩施設の配置と車両がいつ、どこで、どれだけ施設を利用するのか、という輸送スケジュールを同時に与えることを可能にする。実験では日本の首都圏をもと

に生成した仮想ネットワークを用いて提案した手法の有効性を検証する。この成果は [28,29] により得られた成果である。

第4章では、感染症が蔓延した社会を想定し、感染症予防の施策の効果を高速にスクリーニングするための枠組みを提案する。感染症に対する社会シミュレーションとして代表的な DE による数理モデルは少ない計算コストで試行錯誤的に施策の検証ができるが、複雑性を有する社会を再現するためにはその表現能力に限界があった。また、従来の MAS は複雑性を有する社会シミュレーション手法であるが、第1.1節で述べた通り、計算コストの面で問題を抱えていた。そこでここでは、従来の確率論的アプローチによる MAS と最適化手法の一つである機械学習を組み合わせることにより、ここまで示した手法の弱点を克服し、少ない計算コストで感染症拡大抑制に有効な施策を発見するための手法を提案する。具体的には、あらかじめ MAS により作成した学習用データセットを用いて Support vector regression (SVR) モデルをさせることで、有効な施策を発見するための枠組みを開発し、その有効性を数値実験により検証することで、提案手法の優位性を示す。さらに、提案した枠組みにより構築した SVR モデルの予測精度と学習用の MAS による出力の収束性について論じる。この成果は [30] により得られた成果である。

第5章では、社会シミュレーションで対象となる空間に点在する小規模な空間におけるシミュレーション手法を提案する。通常、社会シミュレーションで対象となるのは居住地域、商業地域、工業地域などを含む大規模な空間である。そのようなシミュレーションの精度を向上させるにはそれぞれの地域に点在する施設内、すなわち小規模な空間における事象も含むことが好ましい。ここでは、第4章同様、COVID-19 感染症流行禍における社会を想定し、感染拡大の大きな原因となる飲食店舗における利用者の相互作用を再現するシミュレーターを開発する。一般の飲食店舗では、店舗利用者の行動に不確実性があることを前提とするが、感染症が蔓延する社会においてはそれが感染拡大の原因となりうるため好ましくない。そこで本章では、店舗営業に一定のルールを介在させ最適化手法を適用することで不確実性を排除し、感染症の拡大を予防するようなモデルを提案する。実験では小規模スケールな仮想空間に対して提案手法を適用し、単一のパラメータにより店舗の利益損失と感染リスクを抑制できることを示す。この成果は [31,32] により得られた成果である。

第6章では、第5章に提案した小規模な空間に対するシミュレーション手法を大規模空間に導入する場合を想定し、どのような地域に対して導入することが有効であるか、検証した。具体的には千葉県習志野市を対象に、人口流動データを用いてカーネル密度推定法により人口分布を推定し、整合性を検証する。この成果は [33]

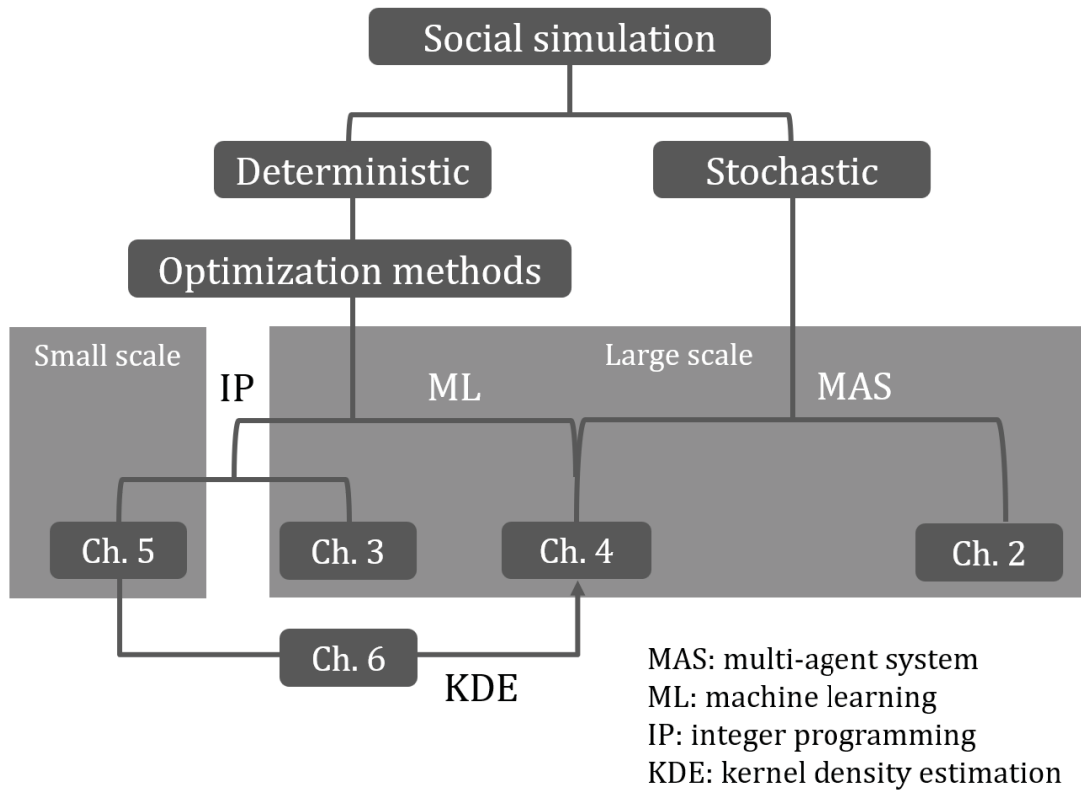


Fig. 1.1: Diagram of the thesis structure

により得られた成果である。

第7章では、本研究により得られた成果と貢献を総括する。

2 Multi-agent システム

複雑性と計算コスト削減を実現する社会シミュレーションに対する枠組み開発するためには、従来の MAS によるシミュレーションの調査と信頼性の検証が必要である。そこで本章では、従来の MAS について具体例を取り上げレビューし、その信頼性の検証を行う。具体的には、大前らにより提案された 2019 年以降から 2022 年現在まで拡大を続けている COVID-19 を対象とした人口流動をシミュレーションする確率論的アプローチによる MAS シミュレータを取り上げる [34]。対象の MAS シミュレータは外出自粛や感染症に罹患した患者を隔離するための病床が感染症拡大に与える影響を論じている。一方で、その信頼性の検証は不十分であった。

そこで、本章では確率論的手法によるシミュレータについて、先行研究 [34] をレビューし確認する。さらに、先行研究 [34] で不十分であったシミュレータの信頼性検証を感染症拡大抑制において重要とされる病床リソースを具体例として行う。

2.1 緒言

ウイルス性感染症の拡大は世界各地でたびたび報告されており [35,36]、その特性を理解するためには感染症拡大シミュレータの開発と利用が重要である。Hou *et al.* は中国武漢における COVID-19 感染拡大のシミュレーション結果を報告している。また、Chatterjee *et al.* はインドにおける COVID-19 の感染症拡大シミュレーションを行い、都市の封鎖、いわゆるロックダウンによる感染者数の減少効果を報告している。このほかにも COVID-19 に対するシミュレーションの事例報告は多々存在する (“中国湖南省 [37,38]”, “オランダ [39]”, “中国, イタリア, フランス [40]” など)。これらの研究はウイルス性感染症拡大の特性を定量的に評価するために重要である。

一方でこれらの研究では、ウイルスに感染した罹患者が隔離される病棟を考慮することはできない。インフルエンザや SARS, COVID-19 といったウイルス性感染症の罹患者は、他者に感染を伝搬させる可能性があるため通常の病棟に入院することができない。そこで大前らは感染症の罹患者が病床を利用することを想定した MAS を開発した [34]。大前らにより開発された MAS は罹患者が利用する病床に定員が設定され、病床リソースによる感染症拡大の影響を表現することを可能としている。一方で、その信頼性の検証は十分にされていない。確率論的手法による MAS シミュレータの精度検証は実社会との比較が最も効果的であるが、実社会における感染者数やそれによる死亡者数は、多種多様な要素が複雑に絡み合って決まるものである。




Fig. 2.1: Transition model of infection states

また，実社会において検証可能な結果はただ一つであるため，シミュレータの信頼性検証を実社会との比較で行うことは難しい．そこで，十分に検証されている既存の感染症拡大を表現するシミュレータと比較することが求められる．

感染症拡大シミュレーションに対する常微分方程式 (ODE: ordinary differential equation) によるアプローチは，伝統的な手法として知られている．特に ODE による SEIR モデルが代表的であり，その拡張モデルも盛んに研究されている [41–44]．COVID-19 に対する ODE ベースの SEIR モデルによるシミュレーション結果も多く報告されており，その信頼性は高いと考えられる [45,46]．そこで，本章では大前らにより提案された MAS シミュレータ [34] を，ODE ベースの SEIR モデルと比較することによりその信頼性を評価する．

2.2 MAS シミュレータ: 感染症拡大に対する MAS

ここでは本章で扱う大前らにより提案された確率論的手法による MAS シミュレータ [34] の概要について述べる．なお，大前らが開発した MAS シミュレータ [34] は病床と外出自粛制限による感染症拡大抑制を表現することができる．一方で信頼性検証に ODE ベースのシミュレータと比較を行うことから，MAS 感染症拡大抑制の施策表現能力は単純化したほうがよい．そこで本章では，MAS における感染症拡大抑制にかかる施策を病床リソースの再現のみに限定する．

2.2.1 感染症の伝搬

感染症の伝搬を表現するため，ODE に基づく SEIR モデルに倣い五つの状態を定義する [47]．SEIR モデルでは個体の状態を S, E, I, R, D に分別する．それぞれ，感染していない個体 (susceptible)，感染かつ発症していない個体 (exposed)，感染かつ発症している個体 (infectious)，感染から回復した個体 (recovered)，死亡個体 (dead)

を意味する。また、以後それぞれを感受性者、暴露者、感染者、回復者、死亡者と表現する。これらの状態は Fig. 2.1 に示すように状態遷移する。

状態遷移を記述するため、遷移確率を

$$P(X_{t_{\text{step}}+1}|X_{t_{\text{step}}}, C, T, H), \quad (2.1)$$

と定義する。ここで C は I または E 状態の人と接触しているかどうかを示す変数であり、

$$C = \begin{cases} 1: \text{接触している,} \\ 0: \text{その他,} \end{cases}$$

である。また、 T は状態が変化してから経過した日数を意味し、 H は I 状態の個体が入院しているかを表す。すなわち、

$$H = \begin{cases} 1: \text{入院している,} \\ 0: \text{その他.} \end{cases}$$

変数 t_{step} はシミュレーションの経過時間である。変数 $X_{t_{\text{step}}}$ は時間 t_{step} における個体の状態を表現しており、

$$X_{t_{\text{step}}}, X_{t_{\text{step}}+1} \in \{S, E, I, R, D\}. \quad (2.2)$$

である。

S から S 状態への遷移確率は

$$P(X_{t_{\text{step}}+1} = S | X_{t_{\text{step}}} = S, C) = \begin{cases} 1 & (C = 0) \\ 1 - \alpha^{\text{MAS}} & (C = 1) \end{cases}, \quad (2.3)$$

ここで α^{MAS} は MAS 環境における 1 ステップあたりの感染率を意味する。 $C = 0$ あれば状態 S は状態を維持し、 $C = 1$ であれば感染リスクを負う。

S から E 状態への遷移確率は

$$P(X_{t_{\text{step}}+1} = E | X_{t_{\text{step}}} = S, C) = \begin{cases} 0 & (C = 0) \\ \alpha^{\text{MAS}} & (C = 1) \end{cases}. \quad (2.4)$$

である。S 状態の個体が E もしくは I 状態の個体と接触した場合、S から E 状態への遷移確率は a^{MAS} である。

E 状態から E 状態への遷移確率は

$$P(X_{t_{\text{step}}+1} = E | X_{t_{\text{step}}} = E, T) = \begin{cases} 0 & (T = T_{E \rightarrow I}^{\text{MAS}}) \\ 1 & (T \neq T_{E \rightarrow I}^{\text{MAS}}) \end{cases}. \quad (2.5)$$

であり、E 状態から I 状態への遷移確率は

$$P(X_{t_{\text{step}}+1} = I | X_{t_{\text{step}}} = E, T) = \begin{cases} 0 & (T \neq T_{E \rightarrow I}^{\text{MAS}}) \\ 1 & (T = T_{E \rightarrow I}^{\text{MAS}}) \end{cases}, \quad (2.6)$$

である。ここで $T_{E \rightarrow I}^{\text{MAS}}$ は暴露から発症までに必要な潜伏期間 [day] である。すなわち、 T が $T_{E \rightarrow I}^{\text{MAS}}$ と等しくなれば E 状態の個体は必ず I 状態へと遷移する。それ以外の場合には E 状態を維持する。E 状態は E もしくは I 状態へしか遷移しないことから、

$$P(X_{t_{\text{step}}+1} = E | X_{t_{\text{step}}} = E) + P(X_{t_{\text{step}}+1} = I | X_{t_{\text{step}}} = E) = 1, \quad (2.7)$$

を満たす。

I 状態から I 状態への遷移確率は

$$P(X_{t_{\text{step}}+1} = I | X_{t_{\text{step}}} = I, T) = \begin{cases} 1 & (T \neq T_{I \rightarrow \text{RD}}^{\text{MAS}}) \\ 0 & (T = T_{I \rightarrow \text{RD}}^{\text{MAS}}) \end{cases}, \quad (2.8)$$

であり、I 状態から R 状態への遷移確率は

$$P(X_{t_{\text{step}}+1} = R | X_{t_{\text{step}}} = I, T, H) = \begin{cases} 0 & (T \neq T_{I \rightarrow \text{RD}}^{\text{MAS}}) \\ 1 - \delta_0^{\text{MAS}} & (T = T_{I \rightarrow \text{RD}}^{\text{MAS}} \wedge H = 0) \\ 1 - \delta_1^{\text{MAS}} & (T = T_{I \rightarrow \text{RD}}^{\text{MAS}} \wedge H = 1) \end{cases}. \quad (2.9)$$

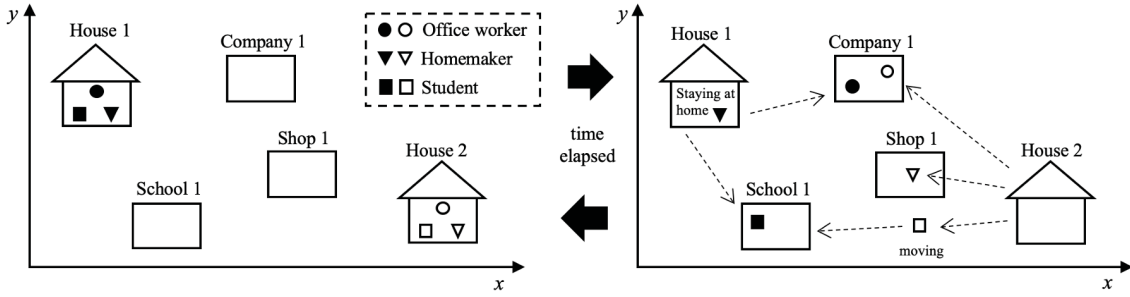


Fig. 2.2: MAS-based simulator

である。また、I 状態から D 状態への遷移確率は

$$P(X_{t_{\text{step}}+1} = D | X_{t_{\text{step}}} = I, T, H) = \begin{cases} 0 & (T \neq T_{I \rightarrow RD}^{\text{MAS}}) \\ \delta_0^{\text{MAS}} & (T = T_{I \rightarrow RD}^{\text{MAS}} \wedge H = 0), \\ \delta_1^{\text{MAS}} & (T = T_{I \rightarrow RD}^{\text{MAS}} \wedge H = 1) \end{cases}, \quad (2.10)$$

である。ここで $T_{I \rightarrow RD}^{\text{MAS}}$ は I 状態からほかの状態へと遷移するために必要な感染期間 [day] を意味する。E から I 状態へ遷移してからの経過日数 T が $T_{I \rightarrow RD}$ と等しくなるとき、個体は必ず R もしくは D 状態へ遷移する。また、 δ_0^{MAS} および δ_1^{MAS} はそれぞれ非入院 ($H = 0$) および入院時 $H = 1$ の致死率である。すなわち、個体の入院状態により致死率が変化することを意味する。一般的には、 $\delta_0^{\text{MAS}} > \delta_1^{\text{MAS}}$ とすることが望ましい。I 状態の個体は I もしくは R, D 状態へしか遷移しないため、

$$\sum_{x \in \{I, R, D\}} P(X_{t_{\text{step}}+1} = x | X_{t_{\text{step}}} = I) = 1, \quad (2.11)$$

を満たす。

R 状態は個体が免疫を獲得した状態、D 状態は死亡した状態を意味することから、それぞれ

$$P(X_{t_{\text{step}}+1} = R | X_{t_{\text{step}}} = R) = 1, \quad (2.12)$$

$$P(X_{t_{\text{step}}+1} = D | X_{t_{\text{step}}} = D) = 1, \quad (2.13)$$

を満たす。

Table 2.1: Simulation conditions of MAS / basic parameters

parameters	values
Simulation period	29 [days]
Houses	Refer to Table 2.2
Initial symptomatic agents	10 [people]
Facility locations (companies)	10 places
Facility locations (shops)	10 places
Facility locations (schools)	10 places
Trip prob. (workers)	99.0–100 [%]
Trip prob. (homemakers)	50.0–100 [%]
Trip prob. (students)	99.0–100 [%]
Departure time (workers)	8:30:00 ± 1:30:00
Departure time (homemakers)	10:30:00 ± 1:30:00
Departure time (students)	8:30:00 ± 1:30:00
Stay time outside (workers)	6:00:00–8:00:00
Stay time outside (homemakers)	0:10:00–0:30:00
Stay time outside (students)	5:00:00–6:00:00
Prob. of hospital visiting	60.0 [%]
Capacity of isolation wards	Refer to Table 2.2
Infection prob.: α^{MAS}	Refer to Table Table 2.2
Incubation periods (from E to I): $T_{E \rightarrow I}^{\text{MAS}}$	3, 5, 7 [day]
Infection periods (from I to R, D): $T_{I \rightarrow \text{RD}}^{\text{MAS}}$	8, 10, 12 [day]
Fatality rate (nonhospitalization): δ_0^{MAS}	10.0[%]
Fatality rate (hospitalization): δ_1^{MAS}	1.0[%]

$a \sim b$: a uniform random number from a to b .

$a \pm b$: a Gaussian random number applied mean a and std. b .

2.2.2 シミュレーションの流れ

ここでは Fig. 2.2 に示す MAS シミュレータにおける仮想社会について説明する。仮想社会上の個体数は 0–1000 [people] であり、2次元空間上に存在する。MAS シミュレータの挙動を決める各パラメータとその設定値を Table 2.1 に示す。“Max simulation period” はシミュレーションの最大期間を示す。また、“The number of houses” はシミュレーション空間上に配置される個体の居住地の数、すなわち世帯数を示す。すべての世帯について会社員、主婦／主夫、学生が一名ずつ居住しているものとする。すなわち、個体数は世帯数の 3 倍である。“The number of initial infectors” はシミュレーションの開始時に存在する I 状態の個体数であり、それらの個体が感染症

拡大を引き起こす。

シミュレーション空間上には個体の居住地および個体種別ごとの目的地が任意の座標に配置される。会社員および主婦／主婦，学生はそれぞれ会社，店，学校を目的とする。それぞれの施設はシミュレーション空間上に多数存在し，それぞれの座標はシミュレーション開始時に一様乱数により決定される。目的地は 1 個体 1 施設であり，シミュレーション開始後変更されることはない。

“Trip prob.” は各個体が目的地の施設へと出かける外出確率である。個体が外出するかはこの外出確率に基づき各日の 0 時 0 分に決定される。“Departure time” は個体が居住地を出る時間である。各個体は家から施設まで直線，すなわちユークリッド距離で移動する。施設に到着した個体はその座標に一定時間滞在する。この時間を “Stay time outside” とする。“Stay time outside” に設定された時間が経過すると個体は同じくユークリッド距離で居住地へと戻る。

“Prob. of hospital visiting” は I 状態の個体が病院に訪れ入院する確率である。このときその個体の外出確率 (Trip prob.) は 0 となる。入院した個体が R 状態へと遷移した場合，退院させ入院以前と同様の行動を取る。ただし，病床リソースの定員を超えた場合，たとえ個体が I 状態であっても入院できず行動様態は変化しない。

Table 2.1 に示した感染率に関するパラメータは第 2.2.1 項で説明した通りである。本節で説明した MAS シミュレータにおける単位時間 (1 ステップ) は 10 分である。すなわち，1 日のシミュレーションは 144 ステップ (24 時間) となる。

また，任意の日 t における各状態ごとの個体数を

$$Z^{\text{MAS}}(t) \in \{S^{\text{MAS}}(t), E^{\text{MAS}}(t), I^{\text{MAS}}(t), R^{\text{MAS}}(t), D^{\text{MAS}}(t)\}, \quad (2.14)$$

と定義する。なお，

$$t = \frac{1}{144} t_{\text{step}}. \quad (2.15)$$

である。なお，1 ステップ 10 分であることから 144 ステップは 1440 分，すなわち 1 日である。

2.3 ODE による感染症数理モデル

ここでは，従来の感染症拡大シミュレーションモデルである ODE に SEIR モデルについて述べる [41–43]。ODE モデルでは各状態の個体数は変化率で表現されるた

め、少ない計算コストで感染症拡大の動態を予測することが可能である。

ODE による SEIR モデルは以下の式により表現される。

$$\frac{dS^{\text{ODE}}(t)}{dt} = -\alpha(t)S^{\text{ODE}}(t)\{I^{\text{ODE}}(t) + E^{\text{ODE}}(t)\}, \quad (2.16)$$

$$\frac{dE^{\text{ODE}}(t)}{dt} = \alpha(t)S^{\text{ODE}}(t)\{I^{\text{ODE}}(t) + E^{\text{ODE}}(t)\} - \beta E^{\text{ODE}}(t), \quad (2.17)$$

$$\frac{dI^{\text{ODE}}(t)}{dt} = \beta E^{\text{ODE}}(t) - \gamma I^{\text{ODE}}(t), \quad (2.18)$$

$$\frac{dR^{\text{ODE}}(t)}{dt} = \{1 - \delta(t)\}\gamma I^{\text{ODE}}(t), \quad (2.19)$$

$$\frac{dD^{\text{ODE}}(t)}{dt} = \delta(t)\gamma I^{\text{ODE}}(t), \quad (2.20)$$

$$Z^{\text{ODE}}(t) = \int_0^t \frac{dZ^{\text{ODE}}(t)}{dt} dt + Z^{\text{ODE}}(0), Z^{\text{ODE}}(0) = \text{const.},$$

$$Z^{\text{ODE}}(t) \in \{S^{\text{ODE}}(t), E^{\text{ODE}}(t), I^{\text{ODE}}(t), R^{\text{ODE}}(t), D^{\text{ODE}}(t)\}. \quad (2.21)$$

ここで、 $S^{\text{ODE}}(t), E^{\text{ODE}}(t), I^{\text{ODE}}(t), R^{\text{ODE}}(t), D^{\text{ODE}}(t)$ は ODE モデルによるシミュレーションで計算される t 日における S, E, I, R, D 状態の個体数である。Eq.2.5 に示したとおり、I および E 状態の個体と接触した S 状態の個体は感染率に基づいて E 状態へと遷移する。そのため、Eqs.2.16, 2.17 第1項に t における I および E 状態の個体数を加算した値に S 状態の個体数が掛けられている。なお、 $\alpha(t)$ は t 日目の感染率である。E 状態の個体は時間経過により、I 状態へと遷移するため、Eqs.2.17, 2.18 に E 状態が含まれる。ここで β は潜伏期間の逆数である。同様に、I 状態の個体は時間経過に応じて R もしくは D 状態へと遷移するため、Eqs. 2.18, 2.19, 2.20 に I 状態が含まれる。また γ は感染期間の逆数であり、 $\delta(t)$ は t 日目の致死率である。

なお、Eqs. 2.16–2.20 は微分係数であるから、Eq. 2.21 に示すように積分することでその総数を求めることができる。ただし、パラメータ $\alpha(t)$ および $\beta, \gamma, \delta(t)$ は任意の値を与える必要がある。

2.4 MAS シミュレータの信頼性評価

MAS シミュレータの信頼性を評価するために、ODE に基づくシミュレータ (ODE シミュレータ) と比較してその出力の類似性を確認する。MAS シミュレータは Table 2.1 に示した通り多くのパラメータが存在する一方、ODE シミュレータは四つのパラメータしか存在しない。そのため、MAS に ODE シミュレータのパラメータをフィッ

ティングする必要がある。MAS にフィッティングさせたパラメータを用いて得られた ODE シミュレータの出力が MAS シミュレータの出力と類似していれば、MAS シミュレータの信頼性を担保することができる。

ODE シミュレータにおける β および γ はそれぞれ潜伏期間および感染期間の逆数である。一方、MAS シミュレータにおいて、潜伏期間と感染期間はそれぞれ $T_{E \rightarrow I}^{\text{MAS}}$ および $T_{I \rightarrow \text{RD}}^{\text{MAS}}$ により表現可能である。すなわち、

$$\beta^* = \frac{1}{\text{mean}[T_{E \rightarrow I}^{\text{MAS}}]}, \quad \gamma^* = \frac{1}{\text{mean}[T_{I \rightarrow \text{RD}}^{\text{MAS}}]}, \quad (2.22)$$

をそれぞれ ODE シミュレータにおける β および γ とみなす。なお、 $\text{mean}[\cdot]$ は複数の値に対して平均値をとる演算子である。MAS シミュレータの場合、Table 2.1 に示すように潜伏期間と感染期間に複数の値を設定することが可能であるため、その平均値を使用することとする。例えば、Table 2.1 においては $\text{mean}[T_{E \rightarrow I}^{\text{MAS}}] = 5$ 、 $\text{mean}[T_{I \rightarrow \text{RD}}^{\text{MAS}}] = 10$ である。続けて、ODE シミュレータにおける $\alpha(t)$ および $\delta(t)$ について検討する。パラメータ $\alpha(t)$ は t 日目における感染率を表し、 $\delta(t)$ は t 日目の死亡率を表す。MAS シミュレータにおいては、感染率 α^{MAS} が使用されるが、これは感染者と感受性者が 1 ステップ接触した場合の感染率である。また、致死率は $\delta_{(0,1)}^{\text{MAS}}$ が使用されるが感染個体の入院状態によって取る値が異なる。すなわち、ODE シミュレータにおける $\alpha(t)$ および $\delta(t)$ は MAS シミュレータにおける α^{MAS} および $\delta_{(0,1)}^{\text{MAS}}$ と類似しているが、異なるものである。そこで、ODE および MAS シミュレータの出力を適合させることで ODE シミュレータのパラメータを与える。ODE シミュレータにおける $\alpha(t)$ は S および E 状態の個体数に影響を与えるため、ODE および MAS シミュレータにおける S および E 状態の個体数の差が最小になるような $\alpha(t)$ を採用する。また、 $\delta(t)$ は R および D 状態の個体数に影響を与えることから、同様に R および D 状態の個体数の差を最小とする $\delta(t)$ を採用する。すなわち、

$$\alpha^*(t) = \underset{\alpha(t)}{\text{argmin}} \left[|S^{\text{ODE}}(t+1) - S^{\text{MAS}}(t+1)| + |E^{\text{ODE}}(t+1) - E^{\text{MAS}}(t+1)| \right], \quad (2.23)$$

$$\delta^*(t) = \underset{\delta(t)}{\text{argmin}} \left[|R^{\text{ODE}}(t+1) - R^{\text{MAS}}(t+1)| + |D^{\text{ODE}}(t+1) - D^{\text{MAS}}(t+1)| \right], \quad (2.24)$$

を ODE シミュレータにおけるパラメータ $\alpha(t)$ と $\delta(t)$ とみなす。以降の実験では、MAS シミュレータと $\alpha^*(t)$ および $\beta^*, \gamma^*, \delta^*(t)$ を採用した ODE シミュレータにより得られと出力を比較することでその信頼性を評価する。

Table 2.2: Simulation conditions of MAS / variables parameters

Case ID	Case 0	Case 1	Case 2	Case 3	Case 4	Case 5	Case 6	Case 7
The number of houses [units]	1000	1000	1000	1000	1500	1500	1500	1500
The number of agents* [ppl.]	3000	3000	3000	3000	4500	4500	4500	4500
Infection probability α^{MAS} [%]	0.06	0.06	0.09	0.09	0.06	0.06	0.09	0.09
Cap. limit. of isolation wards [beds]	0	15	0	15	0	15	0	15

*: The number of agents is 3 times of num. of houses (office worker, homemaker and student).

2.5 数値実験

2.5.1 実験条件

ここでは、病床リソースを表現可能な MAS シミュレータの信頼性を実際に評価する。MAS シミュレータの評価は第 2.4 節で述べた通り、ODE シミュレータの出力と比較することにより行う。MAS シミュレータにおけるパラメータは Table 2.1 および Table 2.2 に示すとおりであり、これらは先行研究 [47] に基づいて決定した。Table 2.2 に示す通り、2 パターンの集団、感染率および病床リソースの有無の組み合わせからなる 8 個のケースが存在する。また、ODE シミュレータのパラメータ $\alpha^*(t), \beta^*, \gamma^*$ and $\delta^*(t)$ は Eq. 2.22 および (2.23, 2.24) により決まる。

2.5.2 結果および考察

感染拡大動態を Fig. 2.3 に示す。Fig. 2.3 における左および中央、右のグラフはそれぞれ MAS シミュレータおよび ODE シミュレータ、Eqs. 2.23, 2.24 によって得られた最適パラメータである。MAS および ODE シミュレータを比較するとわずかなずれはあるものの、その出力傾向には高い類似性があることがわかる。また、病床リソースがない場合 (Case 0, 2, 4, 6) とある場合 (Case 1, 3, 5, 7) を比較すると、ある場合の方が感染拡大の速度が緩やかであることがわかる。また、病床リソースがある場合とない場合の $\alpha^*(t)$ および $\delta^*(t)$ を比較するとない場合のほうが低くなっていることが確認された。パラメータ $\alpha^*(t)$ および $\delta^*(t)$ はそれぞれ ODE シミュレータにおける感染率および致死率であるため、病床リソースは感染拡大と死亡者数の増加を抑制させる効果があることが確認された。この結果は大前らによる先行研究 [34] の結果と類似している。

MAS シミュレータの信頼性を評価するため、MAS および ODE シミュレータの出力間の決定係数 r^2 を算出する。なお決定係数 r^2 は

$$r^2 = 1 - \frac{\sum_{t=0}^{T_{\max}-1} (Z^{\text{MAS}}(t) - Z^{\text{ODE}}(t))^2}{\sum_{t=0}^{T_{\max}-1} (Z^{\text{MAS}}(t) - \text{mean}[Z^{\text{MAS}}])^2}, \quad (2.25)$$

$$\text{mean}[Z^{\text{MAS}}] = \frac{1}{T_{\max}} \sum_{t=0}^{T_{\max}-1} Z^{\text{MAS}}(t), \quad (2.26)$$

により定義される。決定係数 r^2 は 1 に近いほど MAS シミュレータの出力が ODE シミュレータの出力と一致していることを意味する。Table 2.3 は算出された決定係数を示しており、状態 R の一部を除いたほとんどの場合で r^2 は高い値が得られて

いる。また、Table 2.3 の7 および8 行目から、シミュレーション最終日の MAS シミュレータの出力は多くの場合で ODE の出力とほぼ一致していることがわかる。

一方で病床リソースがある場合の回復者 R の決定係数は他と比べ低い傾向にある。病床リソースが存在する場合には、感染者は来院確率によって入院するかどうかが決まる。感染者数が多いほど来院するかどうかという確率事象が増え、その不確実性が回復者 R への状態遷移に表れている。それにより、ODE における致死率 $\delta(t)$ のパラメータ推定が難しくなり、このような結果になったと考えられる。特にその影響は case 3 と case 7 で顕著に表れている。これは case 3 と case 7 では感染確率がそのほかの病床リソースがあるケースに比べて高く、リソースの定員を超過してしまうことにより、ODE における致死率 $\delta(t)$ の推定が難しくなっていることが原因と考えられる。しかし、相対的に低いものもあるが、いずれの決定係数も絶対的には十分高く、これらの結果から病床リソースを表現可能な MAS によるシミュレータの信頼性は高いと考えられる。

第2章 Multi-agent システム

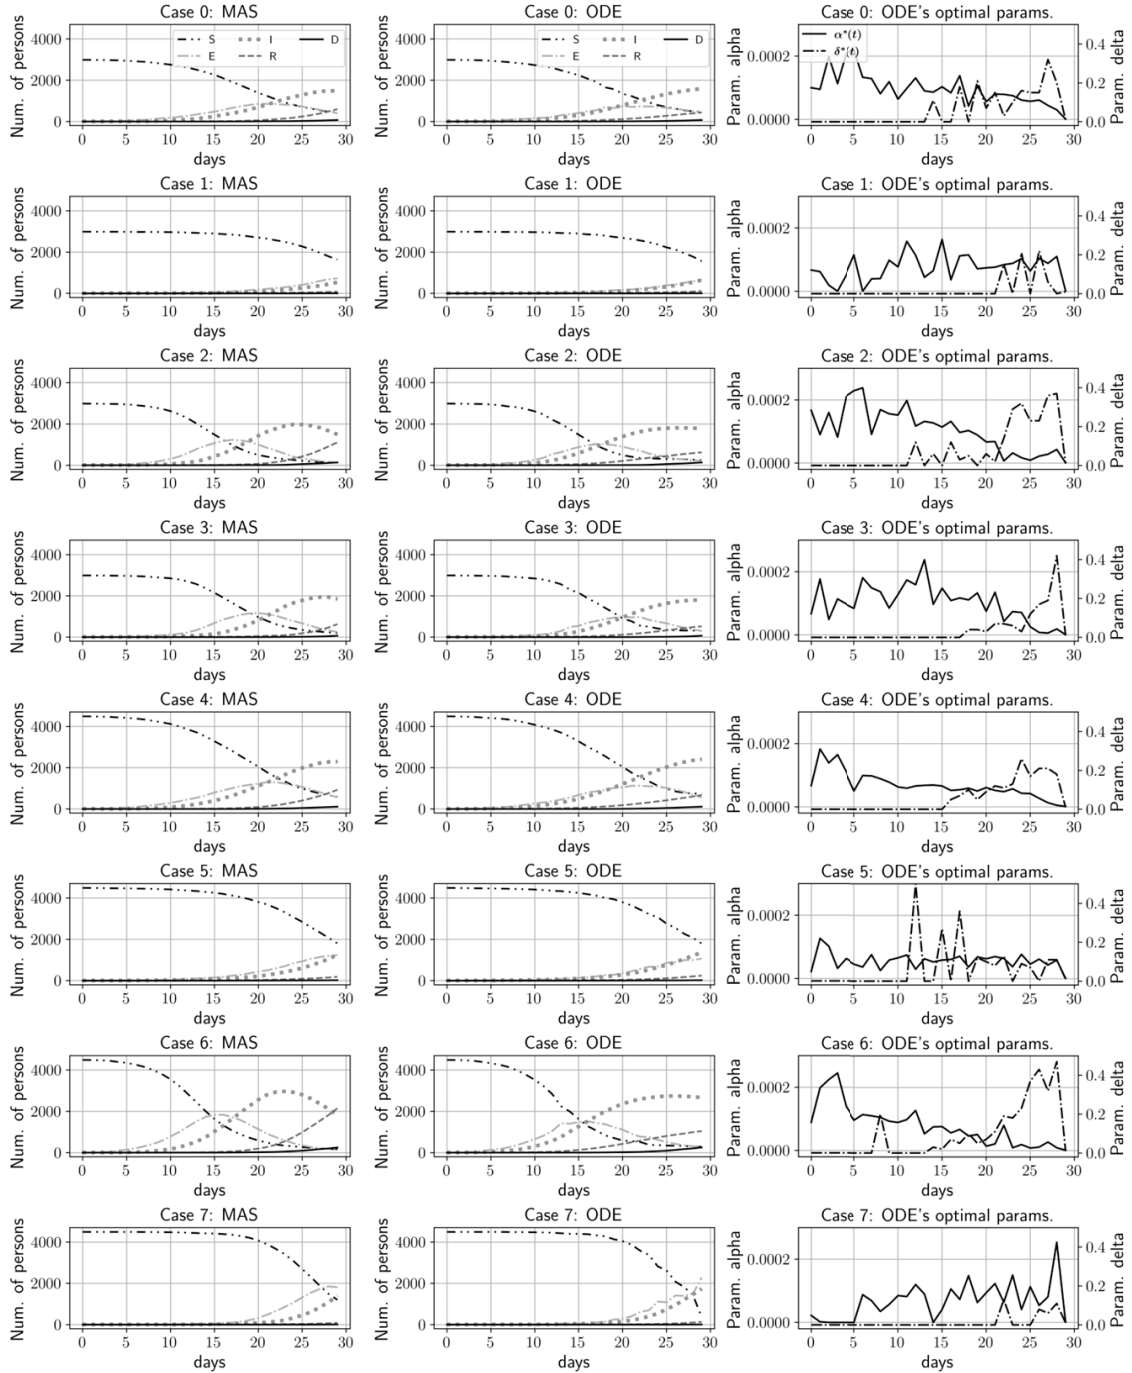


Fig. 2.3: The outputs of infection spread dynamics (left: MAS, center: ODE, right: ODE's optimal params.)

Table 2.3: Reliability verification of MAS based on comparison with ODE

	Case 0	Case 1	Case 2	Case 3	Case 4	Case 5	Case 6	Case 7
Coef. of determination r^2 of state S	0.999	0.998	0.998	0.999	1.000	0.998	0.999	0.993
Coef. of determination r^2 of state E	0.957	0.970	0.945	0.955	0.959	0.967	0.935	0.963
Coef. of determination r^2 of state I	0.990	0.912	0.981	0.981	0.994	0.933	0.968	0.715
Coef. of determination r^2 of state R	0.922	0.811	0.827	0.671	0.925	0.853	0.781	0.711
Coef. of determination r^2 of state D	1.000	1.000	1.000	1.000	1.000	1.000	1.000	0.935
The number of total infectors / MAS	2565.00	1358.00	2872.00	2796.00	3765.89	2696.00	4333.00	3298.00
The number of total infectors / ODE	2535.52	1439.09	2754.71	2694.70	3759.73	2699.37	4212.74	4144.30

2.6 結言

本章では、大前らにより開発された病床リソースとその定員制限を表現可能な確率論的アプローチによる MAS ベースの感染症拡大シミュレータをレビューし、その信頼性を検証した。信頼性の評価は感染症拡大シミュレーション手法として代表的な ODE に基づく SEIR モデルによる出力との比較により行った。Fig. 2.3 や Table 2.3 に示したように、MAS に基づくシミュレータにより得られた出力と ODE に基づくシミュレータにより得られた出力との間に高い類似性が確認された。これにより、確率論的アプローチによる MAS シミュレータは高い信頼性を保持していることが示された。

また、伝統的な確率論的アプローチによる MAS はある特定の社会に対する特定の施策による社会動態を予測し、その効果を検証するために有効であることを示した。一方で、本章で紹介した MAS の不確実性に関する問題が Omae *et al.* により論じられている [48]。また、感染症拡大予防を目的とした携帯端末用のアプリケーションの効果を検証した研究 [48] では、確率論的アプローチによる MAS は乱数に対する依存性が強いことに触れ、出力の正規性を確認するために一つのシナリオあたり 60 回のシミュレーションを行っているとしている。また、検証した 25 個のシナリオのうち出力の分布に正規性が認められたものは 22 パターンであることを示している。これらは確率論的アプローチによる MAS は複雑系シミュレーション特有の不確実性の影響を強く受けることを示唆している。さらに、MAS の出力がシミュレーション内部の確率事象の影響を強く受ける場合、不確実性を除去するためには多数回のシミュレーションを行うことの重要性も示されている。そのため、不確実性の影響が大きくなることは有効な結果を得るための計算コストが増大することがわかる。このように、確率論的アプローチによる MAS は計算コストと複雑系空間が内在する不確実性に関して大きな弱点が存在する。

3 整数計画法による社会シミュレーションの定式化

第2章でレビューした確率論的手法によるMASは、あるシナリオに対して有効な結果を得るためには確率イベントによるばらつきの影響を排除する必要がある。すなわち、あるシナリオに対して十分な数の試行を行い平均化しなければならない。また、確率論的手法による従来のMASはある条件における社会動態を観測することが主な目的である一方で、社会に対して何か施策を行う際その施策による効果を最大化することは難しい。

ここで、MASにおける個体の状態を数値で表現することを考える。MASにおける個体の状態を数値で表現することを考えると個体がとりうる行動に数値を割り当てるような場合、各個体に対して整数変数を割り当てることが可能である。また各整数変数、すなわち個体の状態に対してルールを与える場合には、数式で表現される制約条件を与えることがこれにあたる。また、MASを適用したい社会に対して施策の効果を最大化したい場合には、そのように設計された評価関数を与えればよい。このような制約条件と評価関数のもと個体の行動を再現し、評価関数を最大化(もしくは最小化)させる場合、この問題は整数計画問題として定式化可能である。

そこで本章では、MASを整数計画問題として表現し、その問題を解くことで社会シミュレーションを行う手法を提案する。一般に整数計画問題に対する大域的最適解を求める多項式時間アルゴリズムは存在しないが、近年のハードウェアや整数計画ソルバーの性能向上に伴い、解ける問題の規模は大きくなってきている。整数計画問題に対する大域的最適解を求めるアルゴリズムは、前処理としてヒューリスティクス手法により初期解を生成するため最適解への一意性は保証されない一方、評価関数の最適値への一意性は保証される。すなわち、施策の効果に対しては一意性が保証されていることから、従来のMASのように乱数に依存する出力の収束性を考慮する必要はない。

本章では、整数計画問題によりMASを定式化するためにシミュレーションの対象を単純化し、その有効性を検証する。具体的には個体を与えられたネットワーク上のみを移動できる自動車と仮定する。交通道路ネットワークに対するMASを実装することで、複雑性と計算量の両面からその有効性を検証する。また、交通道路ネットワークにおける個体の相互作用を再現し確認するため、輸送スケジューリング問題を対象として決定論的手法の検証を行う。さらに、整数計画問題によるMAS

の優位性を示すため、輸送スケジューリング問題における時間的制約に着目する。

3.1 緒言

道路ネットワーク上を移動する車両の輸送計画には、遅延リスク削減のためのバッファ時間を計画に加える。特に大型貨物輸送車は Just-in-time で目的地につかなければならないことが多い。しかし、遅延が発生せずにバッファ時間が余った場合には大型貨物車はその時間を消化するために幹線道路上での路上待機を行う。これが渋滞やそれに伴う環境汚染の大きな原因となる [49]。この問題は車両がバッファ時間の消費を行う休憩所を適切に利用することにより解消される。貨物車に対する休憩所の適切な配置がもたらす経済効果や事故減少に関する研究 [50, 51] は数多く報告されており、その重要性は明白である。このような施設に対する配置モデルは貨物輸送車の輸送スケジュールに組み込まれるバッファを適切に消化するための休憩施設の配置モデル (RALM: rest-area location model) とみなすことができる。RALM の主な要件は、コスト削減のために道路ネットワーク上に配置する施設の数をも最小化すること、配置された施設はすべての貨物輸送者のバッファを消化することである。

道路ネットワーク上を移動する車両が立ち寄る拠点や経路を探索する代表的な問題として配送計画問題 (VRP: vehicle routing problem) が挙げられる [13, 14]。VRP はある Depot の周りに散らばっている顧客需要に複数の車両を用いてサービスを提供する経路を見つける問題であり、研究が盛んに行われている [52, 53]。しかし、これら VRP はすでに存在する需要点を通る経路を探索する問題であり、RALM に適用することはできない。しかし、VRP は車両が利用する施設配置について関知しないため、RALM に応用することは難しい。Csehi *et al.* [54] は長距離貨物車の輸送スケジュールを作成する際に必要な、経路、運転手の休憩箇所、給油施設の選択を考慮した単一車両のスケジューリング手法を提案しているが、複数の車両の競合等を考慮した施設配置を前提としていない。Rawinun *et al.* [55] は HDD 製造におけるマルチロボットシステムにおける最短経路探索およびタスク割り当てを行うモデルを提案している。しかし、このモデルは最短経路探索とタスク割り当てに焦点を置いており、すでに経路が与えられタスク割り当てと複数の車両の競合などに焦点を当てる RALM に適用するのは適切ではない。

ここで施設配置モデルによるアプローチを考える。道路ネットワークにおける交通の流れを対象とした施設配置モデルは各車両が持つバッファ時間を需要、車両の休憩所を施設とすると RALM は集合被覆モデル (LSCM: location set covering

model) [18, 56] とみなすことができる。LSCMによって配置される施設は人口などといった対象地域上に静的に分布する需要を対象としているが、RALMでは車両のような地域上のある点からある点へと移動するような動的需要を対象としている。需要種別の違いは需要集合の定義を見直すだけで簡単に対応可能である。Fei *et al.* や Bianco *et al.* は動的需要に対するLSCMを起点終点(O-D: origin and destination)交通量推定のための交通センサー配置問題に適用した研究を行っている[57,58]。しかし、RALMや先行研究[57,58]で提案されたモデルでは需要の時間的要素、すなわち、需要がいつ、どこで、どれだけ施設を利用するのか、といったことは考慮できない。一方、時間軸を考慮した動的需要のための施設、例えば給電ステーションなど、の配置モデル[59,60]は数多く提案されているが、これらの研究は施設がカバーする需要の最大化に観点を置いており、RALMへの適用はできない。そこで本研究ではRALMを基に時間駆動する需要、すなわち車両に対する施設配置モデル(RALMTD: RALM for time-driven demand)を構築する。RALMTDは需要が時間駆動で道路ネットワーク上を移動するものとみなすことで施設配置と同時に車両の輸送スケジュールを与えることができる。また、RALMTDは施設という局所的な点で二次元道路ネットワーク上を移動する個体の相互作用を予測し、施設の配置を決める一種のMASと考えることができる。RALMTDによる配置と貨物車両の輸送スケジュールを適切に利用すれば、現実で問題となっている余剰時間消化のための路上駐車を解消できる。それにより、路上駐車に起因する渋滞や事故等を減少させる可能性があり、道路の運用効率を向上させることが示唆される。

実験ではRALMとRALMTDを単純な仮想ネットワークに適用し、それぞれの挙動を確認する。また、東京周辺の道路ネットワークを基に作成した仮想ネットワークを用いて、RALMとRALMTDの有効性を定性的、定量的に評価する。その結果、RALMTDはRALMに比べて大幅に計算コストを要するものの、既存研究では考慮されていなかった複数車両に対する輸送スケジュールの作成及び車両の競合を考慮できることが確認された。

3.2 Location set covering model

LSCM [18, 56] は人口など静的に分布する需要をすべてカバーできるような施設配置を探索するものであり、次のように定式化される。

$$\text{Minimize } z = \sum_{i \in I} x_i, \quad (3.1)$$

$$\text{subject to } \sum_{i \in I_j} x_i \geq 1, \forall j \in J, \quad (3.2)$$

$$x_i \in \{0, 1\}, \quad (3.3)$$

ここで I, J はそれぞれ施設配置点と需要点の集合を意味し、 i, j はそれぞれ I, J の要素である。 I_j は需要点 j を被覆する施設配置店の集合である。決定変数 x_i は0または1 (以後0-1と表記する) を取る整数変数変数であり、次のように定義される。

$$x_i = \begin{cases} 1: & \text{facility is located on a node } i, \\ 0: & \text{otherwise.} \end{cases}$$

目的関数 (Eq. 3.1) はネットワーク上に配置される施設数を最小化する。制約式 (Eq. 3.2) はすべての需要点は少なくとも一つの施設によってカバーされていることを保証する。このような構造から LSCM はバッファ消化のための施設配置モデルに応用可能である。経済的観点などから休憩所の配置を検討する研究 [61] はみられるが、LSCM を用いたアプローチは見られない。

3.3 モデル定式化

3.3.1 Rest-area location model

休憩施設配置問題は道路ネットワーク上の全需要、すなわち全車両に与えられたバッファを最小の施設でカバーする LSCM の一種であり、第 3.2 節で定義した変数 x_i を使って次のように定式化できる。

$$\text{Minimize } z = \sum_{i \in I} x_i, \quad (3.4)$$

$$\text{subject to } \sum_{i \in I_j} u_i x_i \geq b_j, \forall j \in J, \quad (3.5)$$

$$x_i \in \{0, 1\}, \quad (3.6)$$

ここで I, J はそれぞれノード及び貨物輸送車の集合であり, i, j はそれぞれ I, J の要素である. また, I_j は車両 j が通るノードの集合であり, b_j は車両 j が消化しなければならないバッファ時間, u_i はノード i で消化可能な時間を表す. このとき, $u_i = 1, \forall i \in I$ かつ $b_j = 1, \forall j \in J$ とすると一般的な LSCM とその構造は同じである.

一般的な LSCM と式 (Eqs. 3.4–3.6) に示す RALM の大きな違いは対象とする需要の種別である. LSCM では人口などといった対象地域上に静的に分布する需要を対象としている. 一方, RALM ではある点からある点に移動する交通流のような需要を対象とする. 静的需要を対象とする代表的な施設配置モデルとして LSCM のほかに最大被覆配置モデル (MCLM: maximal covering location model) [16] があるが, MCLM では固定施設数でカバーできる需要の量を最大化する. また, フロー捕捉型施設配置モデル (FCLM: flow-capturing location-allocation model) [62] は動的需要を対象とした代表的な施設配置モデルであり, MCLM の一種である. 筆者らは電気自動車が利用する充電施設に対する FCLM の拡張手法を提案し, その有効性を確認している [28]. MCLM から FCLM への拡張は対象とする需要集合の定義を見直すことで可能となる. LSCM から RALM への拡張も同じ文脈で拡張可能であり, 基本的な違いは需要の定義のみである.

式 (Eqs. 3.4–3.6) はシンプルに RALM を表現できる一方, 需要となる車両同士の時間的競合を考慮することができない. さらに, 各車両リソースがいつどこでどれだけ施設を利用するか, という詳細な輸送スケジュールを与えることはできない.

3.3.2 Rest-area location model for time-driven demands

第 3.3.1 項で提案した RALM に時間駆動する需要を考慮することで, 施設配置と車両リソースがいつどこでどれだけ施設を利用するのか, という輸送スケジュールを同時に与えることができる. 本節では時間駆動する需要をカバーする RALM for time-driven demands (RALMTD) を定式化する. RALMTD が満たすべき要件を, (i) 各車両に割り当てられたバッファ時間をすべて消費する最小の施設配置箇所を求める, (ii) 施設を利用する車両は単位時間ごとに移動する, (iii) 施設には容量が与えられる, とする. (i) は第 3.3.1 項で提案した RALM のものである. (ii) は需要となるすべての車両に識別番号を付与し単位時間ごとの移動に関する制約を与えることで実現可能である. (iii) は各時間ステップで施設配置可能点 (PFL: potential facility locaiton) i に存在する車両の総和を取ることで実現できる. (i — iii) を満たす RALMTD を定式化するため, 第 3.3.1 項で定義した諸記号に加え, 新たに次のような諸記号と変数

を定義する.

P : set of PFLs ($P \subseteq I$)

P_j : set of PFLs through which freight vehicle j passes ($P_j \subseteq I_j$)

$\bar{P}_j := P_j \setminus \{o_j, d_j\}$

T : set of time steps (index t is an entry),

$\bar{T} := \{t | t \leq |T| - u_i, t \in T\}$.

$$y_{i,t}^j = \begin{cases} 1: & \text{freight vehicle } j \text{ drives on a node } i \text{ at time step } t, \\ 0: & \text{otherwise.} \end{cases}$$

$$z_{i,t}^j = \begin{cases} 1: & \text{freight vehicle } j \text{ starts rest on a PFL } i \in P \text{ at time step } t, \\ 0: & \text{otherwise.} \end{cases}$$

記号 o_j および d_j は貨物車両 j の O-D, すなわちそれぞれ起点と終点を示す. これらの諸記号と変数を用いて RALMTD を定式化していく. RALMTD における目的関数は次のように定義される.

$$\text{Minimize } z = \sum_{i \in P} x_i. \quad (3.7)$$

Eq. 3.7 は道路ネットワークに配置する施設数を最小化している. また, 全車両に設定されたバッファ時間がすべて消化できるように施設を配置するための制約を

$$\sum_{i \in \bar{P}_j} \sum_{t \in \bar{T}} u_i z_{i,t}^j \geq b_j, \quad \forall j \in J, \quad (3.8)$$

とする. Eq. 3.8 の左辺は車両 j が施設で休憩した総時間, 右辺はその車両が休憩すべき総時間を表している. ここで制約式の構造に着目する. 左辺は各貨物車両についてある時間 t に休憩を開始することを示す変数 $z_{i,t}^j$ と休憩を開始した施設で消化できる時間ステップ数である u_i の積になっている. 一方, 右辺は消化すべきバッファ時間 b_j であるため, 制約式 (Eqs. 3.8) は任意の貨物車両 j はかならず所望のバッファ時間 b_j を消化するよう構成されている.

続けて、施設容量に関する制約を

$$\sum_{j \in J} \sum_{s=t-u_i}^t z_{i,s}^j \leq c_i + M(1 - x_i), \forall i \in \bar{P}_j, \forall t \in T, \quad (3.9)$$

と定義する。Eq. 3.9 は PFL i に施設が配置されたとき、同時間帯に施設を利用する車両の数がその PFL の容量 c_i を超過しないことを保証する。左辺は時間 $t - u_i$ から時間 t までに施設を開始した車両数の総和になっており、右辺の c_i 以下になるよう式が構成されている。なお、右辺第2項の M は十分大きな定数である。施設が PFL i に配置されない場合、右辺第2項は M となり制約式は常に満たされる。一方、施設が配置された場合、右辺第2項は 0 となり制約式が意味を持つ。このように十分大きな定数を用いて制約式をオン、オフする手法を big-M 法と呼ぶ [63].

車両の移動に関する制約は

$$y_{l_{i,j},t+1}^j - y_{i,t}^j \geq 0, \forall i \in I_j \setminus \bar{P}_j, \forall j \in J, \forall t \in \{t | t \leq |T| - 1, t \in T\}, \quad (3.10)$$

$$y_{l_{i,j},t+1}^j - y_{i,t}^j + \sum_{s=t-u_i}^t z_{i,s}^j \geq 0, \forall i \in P_j, \forall j \in J, \forall t \in \{t | t > u_i, t \in T\}, \quad (3.11)$$

と表現できる。Eq. 3.10 は PFL でないノードにおいて車両 j は次のタイムステップで必ず隣接するノードへ移動することを保証する。なお、 $l_{i,j}$ は貨物車両 j が走行する経路に存在するノード i の進行方向に存在する隣接ノードを意味している。貨物車両 j が PFL でないノード $i \in I_j \setminus P_j$ に存在するとき、時間 t における変数 $y_{i,t}^j$ は 1 となる。また、車両が PFL でないノードに存在する場合、次の時間 $t+1$ では必ず隣接するノード $l_{i,j}$ に移動していなければならないため、 $y_{l_{i,j},t+1}^j$ と $y_{i,t}^j$ の差は常に 0 以上、すなわち $y_{l_{i,j},t+1}^j = 1$ でなければならない。Eq. 3.10 はその要件を満たしている。Eq. 3.11 は車両 j が PFL i で休憩しない場合、次のタイムステップで隣接するノードへ移動する制約である。この制約式は PFL に属するノードにおいて、Eq. 3.10 において車両が施設で休憩する場合の例外処理を考慮している。もし貨物車両 j が時間 t において PFL $i \in P_j$ で休憩をするならば左辺第3項が 1 となり、次の時間 $t+1$ に置ける変数 $y_{l_{i,j},t+1}^j$ の値は 1 に固定されなくなる。これにより Eq. 3.11 は貨物車両が施設を利用する場合、移動に関する制約を無効にし、利用しない場合有効にするような構造をしている。

また、車両が存在しかつその車両が施設で休憩する場合の隣接ノードとの関係に

関する制約を

$$y_{l_{i,j},t+u_i}^j - y_{i,t}^j + M(1 - z_{i,t}^j) \geq 0, \forall i \in P_j, \forall j \in J, \forall t \in \bar{T}, \quad (3.12)$$

とする。Eq. 3.12 は PFL i において、貨物車両 j が休憩する場合、その施設における消費可能時間 u_i だけ休憩した後、隣接する次のノード $l_{i,j}$ に移動することを保証している。左辺第3項が $z_{i,t}^j$ の値によって制約式の有効無効状態を定めている。貨物車両 j が時間 t において PFL i に配置された施設で休憩する場合、その車両 j は時間 t から u_i ステップ後の隣接ノード $l_{i,j}$ に移動することで制約式が満たされる構造になっている。また、次の制約

$$z_{i,t}^j - y_{m_{i,j},t-1}^j \leq 0, \forall i \in P_j, \forall j \in J, \forall t \in \bar{T}, \quad (3.13)$$

は、貨物車両 j が時間 t において PFL i に配置された施設で休憩を開始する場合、直前の時間 $t-1$ にその車両 j が隣接するノードに存在しなければならないことを意味している。なお、Eq. 3.13 における $m_{i,j}$ は貨物車両 j が走行する経路に存在するノード i の直前に存在する隣接ノードを意味している。

車両が施設で休憩できることを保証する制約を

$$\sum_t^{t+u_i} y_{i,t}^j + M(1 - z_{i,t}^j) \geq u_i, \forall i \in \bar{P}_j, \forall j \in J, \forall t \in \bar{T}, \quad (3.14)$$

のように定義する。Eq. 3.14 において、PFL $i \in P_j$ に配置された施設を貨物車両 j が利用する場合、左辺第2項が0となり制約が有効になる。一方、車両が施設を利用しない場合、左辺第2項は十分大きな定数 M となり、この制約は無効になる。制約が有効になった場合、左辺第1項は PFL $i \in \bar{P}_j$ に配置された施設を利用する時間数となるため、Eq. 3.14 は妥当である。

施設が存在しないノードに車両が滞在できないことを示す制約は

$$\sum_{t \in T} y_{i,t}^j \leq 1, \forall j \in J, \forall i \in I_j \setminus \bar{P}_j, \quad (3.15)$$

$$\sum_{t \in T} y_{i,t}^j \leq Mx_i + 1, \forall j \in J, \forall i \in \bar{P}_j, \quad (3.16)$$

と表現できる。Eqs. 3.15, 3.16 の制約における左辺は貨物車両 j がノード i にとどまった時間数を表現している。そのため、Eq. 3.15 は PFL でないノード $i \in I_j \setminus P_j$ で

はとどまる時間数を1以下に制約していることが分かる。また, Eq. 3.16 は施設が PFL $i \in \bar{P}_j$ に配置された場合, 制約式を無効にすることで任意の時間だけそのノードにとどまれるような構造になっている。

次の制約

$$\sum_{t \in T} z_{i,t}^j \leq x_i, \forall j \in J, \forall i \in \bar{P}_j, \quad (3.17)$$

は PFL i において施設が配置されていない場合, 貨物車両 j は休憩を開始できないことを保証する。PFL $i \in \bar{P}_j$ に施設が配置されない場合, Eq. 3.17 は $x_i = 0$ となることにより, $\sum_{t \in T} z_{i,t}^j$ が0になるよう制約している。

貨物車両 j の起点終点に関する施設配置を禁止する制約を

$$\sum_{t \in T} z_{i,t}^j \leq 0, \forall j \in J, \forall i \in \{o_j, d_j\}, \quad (3.18)$$

と定義する。また, 次の制約

$$z_{i,t}^j \leq 0, \forall j \in J, \forall i \in \bar{P}_j, \forall t \in \{t | t + u_i > |T|, t \in T\}, \quad (3.19)$$

は, それぞれ貨物車両 j が与えられた時間ステップ, すなわち $|T|$ を超えて休憩できないことを意味する。また,

$$y_{o_j, a_j}^j \geq 1, \forall j \in J, \quad (3.20)$$

は車両が出発時刻 a_j に起点 o_j を出発することを保証している。RALMTD における決定変数の0-1制約は

$$x_i, z_{i,t}^j \in \{0, 1\}, \forall i \in P, \forall j \in J, \forall t \in T, \quad (3.21)$$

$$y_{i,t}^j \in \{0, 1\}, \forall i \in I, \forall j \in J, \forall t \in T. \quad (3.22)$$

と定義される。

3.3.3 各種問題の複雑性

第3.3.1項および第3.3.2項で提案したRALMとRALMTDはどちらもLSCMの拡張と言える。LSCMは全ての決定変数が0-1整数変数であり, LSCMによって定式化されるLSCPは0-1整数計画問題と呼ばれる。一般に0-1整数計画問題は多項

Table 3.1: The number of variables by the models

Model	The number of variables
LSCM	$ I $
RALM	$ I $
RALMTD	$ P + J P T + J I T $

式時間で最適解を得ることができないクラス NP 困難に分類される。RALM および RALMTD によって定式化される問題も同様に 0-1 整数計画 でありクラス NP 困難に分類される。近年ハードウェアやソルバーの性能向上に伴い、解くことができる 0-1 整数計画問題の規模も大きくなっている一方、問題の規模が大きくなりすぎると現実的な時間で最適解を得ることは難しくなる。

ここで LSCM, RALM, RALMTD によって定式化される問題が持つ変数の数を Table 3.1 に示す。

0-1 整数計画問題を解く難しさを決定変数の数のみで論じることはできないが、RALMTD で定式化した問題は LSCM 及び RALM によって定式化された問題を内包しているため、これら3つの問題の難易度を論じるうえでは決定変数と制約式の数が重要といえる。Table 3.1 からわかる通り RALMTD は PFL の集合 P に加え時間の集合 T と時間依存の車両位置の集合 I を考慮する必要があるため、決定変数及び制約式の数が LSCM と RALM に比べて大幅に増える。また、これらの集合は全てネットワーク規模が大きくなればなるほどその大きさも莫大に増えていく。このような理由から RALMTD は LSCM といった従来の手法やその単純な拡張である RALM に比べ計算コストが大きくなることが予想される。

また、RALMTD では決定変数の数が増えるだけでなく、変数にかかる係数も LSCM や RALM と異なる。特に最適化問題において big-M 法で用いられるような巨大な数は計算を不安定にすることが知られている [63]。そのため、RALMTD により問題を定式化する場合には、このような定数を適切に定める必要がある。

3.4 数値実験

数値実験では小規模ネットワークを用いて RALMTD に対する予備実験を行いモデルの挙動を確認する。さらに日本の関東地方の幹線道路ネットワークを例に RALM と RALMTD を適用して評価する。実験に用いた PC のスペックは Apple® M1 chip@ 3.2GHz, 16GB RAM, running macOS™ Big Sur version 11.4 であり、最適化ソルバー




Fig. 3.1: (a) Small network consisted of 25 nodes (b) Divided network by time steps based on (a).

は Gurobi Optimizer™ version 9.1 を用いた。

3.4.1 小規模仮想ネットワークを用いた予備実験

RALMを小規模な仮想ネットワークに適用する。Fig. 3.1-(a)はSimchi-Leviら [64]によって作成されたネットワークである。ノードとエッジ上に振られた番号はそれぞれIDとコストである。実験にはすべてのエッジコストを時間と仮定し、単位時間1ごとに分割したFig. 3.1-(b)を使用する。Fig. 3.1-(a)および(b)のノードIDは対応している。Fig. 3.1-(a)に示すネットワークはノード数25、エッジは数43である。Fig. 3.1-(b)に示すネットワークはノード数180、エッジ数は198である。エッジは双方向である。ネットワークの描画にはKamada *et al.* [65]により提案されたアルゴリズムを用いた。

実験のための諸条件を整理する。PFLはFig. 3.1-(a)の25ノードとする。車両数 $|J|$ は10台として車両 j が走行する I_j はランダムに与えられた起点集点間の最短経路とする。車両 j の休憩回数 r_j は $r_j = 2, \forall j \in J$ とし、各パラメータは $u_i = 3, \forall i \in P$ および $a_j = 1, b_j = 3 \cdot r_j, \forall j \in J$ とする。

Fig. 3.2は施設配置点と時間ステップ1から6までの車両の動きを示している。図中の五角形は施設が配置された点を示しており、配置された施設数は5か所であった。また、黒丸は車両の位置を示しており、その中の数字はそのノードにいる車両




Fig. 3.2: Location of facilities and movement locus of vehicles.

の数を示している. $t = 3$ では2か所で3台の車両が休憩を開始している. $t = 5$ で休憩を終え $t = 6$ で隣接ノードに移動していることから $t = 6$ 時点で3台の車両はバッファを3ステップだけ消費していることが分かる.

Fig. 3.3 はある車両の起点終点間の移動軌跡を示しており, 黒枠の円は休憩したステップ数を表している. Fig. 3.3 に示した車両は移動中2か所の施設配置点でそれぞれ3ステップ休憩している. これらの結果から RALMTD は諸条件を満たしつつ施設配置点と各車両の輸送スケジュールを与えることが確認できた.

3.4.2 RALMTD の評価

長距離貨物輸送車を仮定して, 関東地方の幹線道路ネットワークに基づいて生成した Fig. 3.4-(a) および (b) に示す仮想道路ネットワークを用いた実験を行う. Fig. 3.4-(a) はエッジとノードのみを記載しており, Fig. 3.4-(b) は各エッジを通過する貨物車両の台数を色濃度により表現している. 抜き出した領域は $[34.88-37.00^\circ \text{ N}, 139.00-$

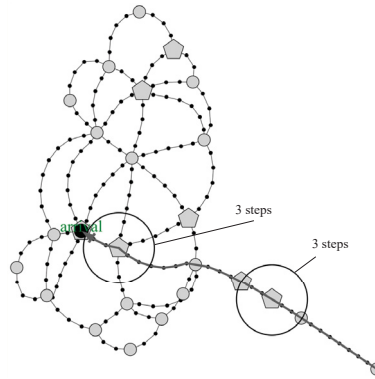


Fig. 3.3: Example of movement locus.

141.00° E] であり，規模は約 182.64 [km] × 236.00 [km] である．生のデータではノード数が多く，現実的な時間で問題を解くことは難しい．広範囲の道路ネットワークを対象に施設配置を行う場合，狭い範囲にノードが集中しているノード群（例えばジャンクション）は集約して一つのノードとみなすことでデータ量を削減できる．Fig. 3.4 に示した道路ネットワークは Fig. 3.5 のようにノード間の距離が 1000 [m] 以内のノード同士を集約して生成したものであり，ノード数 332，エッジ数 735 である．

RALM と RALMTD を Fig. 3.4 の道路ネットワークに適用し，それぞれの性能を評価する．まず，実験を行うための諸条件を整理する．1 単位時間に貨物輸送車が移動できる距離は 1000 [m] と仮定し Fig. 3.4 に示した道路ネットワークの全エッジを 1000 [m] ごとに分割する．分割前と分割後のノードをそれぞれ P と I とみなす．なお， $|P| = 332$ ， $|I| = 1381$ である．車両数 $|J| = 100$ として車両 j が走行する $|I_j|$ はランダムに与えられた O-D 間の最短経路とする．車両 j の走行時間は $|I_j|$ ステップであり，車両 j の休憩回数 r_j は $r_j = \lceil |I_j| / 120 \rceil$ ， $\forall j \in J$ で与えられる．これは 120 ステップ以内に一度休憩することを意味する．各パラメータは $u_i = 15$ ， $\forall i \in P$ および $a_j = 1$ ， $b_j = 15 \cdot r_j$ ， $\forall j \in J$ とする．なお， $b_j = 15, 30$ となった車両の割合はそれぞれ 97%，3% であった．

Fig. 3.6-(a) および (b) はそれぞれ RALM と RALMTD において $c_i = 100$ ， $\forall i \in I$ を用いて得られた結果である．施設配置箇所は五角形のノードで示している．RALM と RALMTD で配置された施設数はどちらも 9 であった．どちらのモデルも車両がよく通るノードに施設を配置できている一方，その分布は大きく異なっている．RALM ではどの施設も次数 3 以上のノード，すなわち交差点に配置されているが，RALMTD では必ずしもそうではない．これは時間を考慮しない場合，経路が集中しやすい交

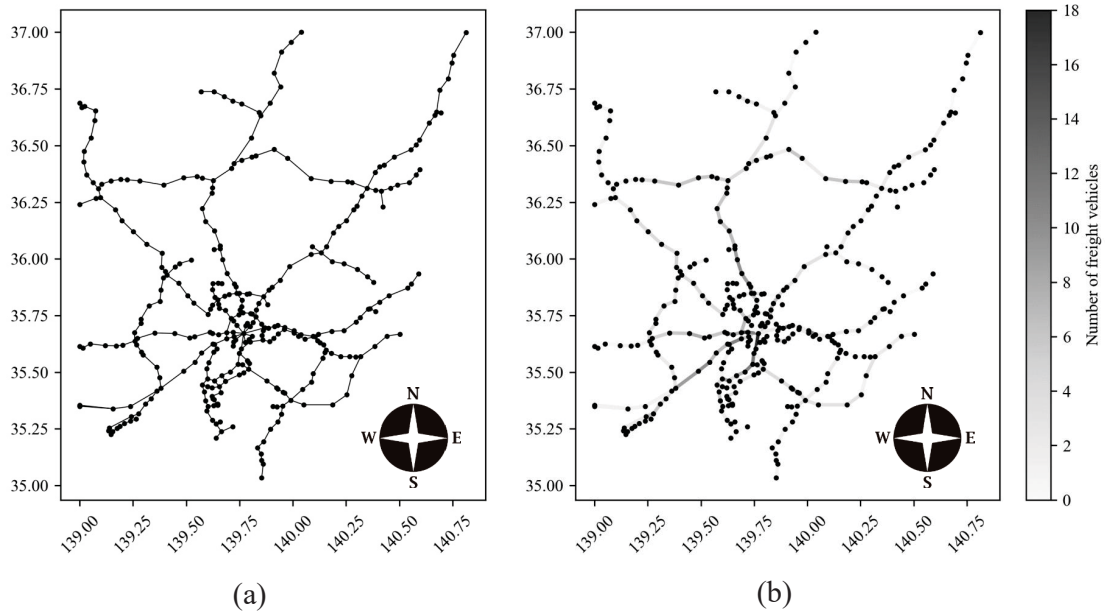


Fig. 3.4: Network instance based on highway network around Tokyo, Japan. (a) Nodes and edges. (b) Including color depth expressing the number of freight vehicles.




Fig. 3.5: Aggregation method.

差点に施設を配置したほうが多くの車両を捕捉できるためである。一方、車両の時間移動を考えるとある交差点を同じ時間に複数の車両が通ることはそれほど多くない。つまり、Fig. 3.6から、RALMTDはむやみに交差点に施設を配置するのではなく、車両の時間移動に合わせて施設を適切に配置していることが見て取れる。このことから、RALMTDはLSCMと同じ構造を持つRALMと比較して現実に近いモデルとなっていると考えられる。

Fig. 3.7はRALMTDの施設容量を変えて得られた配置である。黒いノードはPFLを示し、五角形の中の数字は最大利用量を示している。容量が小さくなるごとに配置される施設数が増えており、施設の最大利用量も分散されていくことが見て取れる。Fig. 3.7において、施設の容量にかかわらず道路ネットワークの外側ではほぼ同

じ配置となっている一方、施設を利用する車両台数が異なっている。Fig. 3.4 より、各車両が通る経路は起点終点間の最短経路が採用されており、中心部のノードを通過する車両数が多く存在することがわかる。そのため、施設容量が十分大きい場合には中心部に配置された施設によって多くの車両需要がカバーされることで、外側に配置された施設の需要が減少している。これにより、外側の施設の配置が同様でもカバーされる車両数が異なるという現象が起きると考えられる。これは、対象の道路ネットワーク全体の施設の供給能力のバランスを取る際に、施設容量が役に立つを果たすことを示している。すなわちパラメータ c_i を調整することにより、単純に車両の競合を考慮するのみならず、全ての施設の供給能力のバランスを調整することが可能となる。

Table 3.2 は容量パラメータごとの計算時間、目的関数値を示している。RALM との前方互換性を示すため、常に容量制約 (Eq. 3.9) が満たされる $c_i = 100$ を採用した。容量 $c_i = 6$ まで最適値に変化がなかったため、その他の c_i を 3-7 に設定した。また、消費可能時間は $u_i = 6, 9, 12, 15$ を採用した。消費可能時間 u_i を減少させることは、各貨物車両の休憩回数を増加させることに相当する。そのため、 u_i が減少すれば必要な施設の数が増加することが予想される。

RALMTD は PFL の容量が十分大きい場合には RALM と同じ目的関数値が得られている。容量が小さくなると必要な施設数は増加していき、各施設の最大利用量も全体に分散されていく一方、計算時間は RALM に比べ非常に大きく、また施設容量が小さくなると増加していく。これは施設容量が小さくなると実行可能解の空間が小さくなること、RALMTD が RALM に比べモデルの構造が複雑であること、Table 3.1 に示した通り RALMTD における変数の数が RALM に比べてはるかに多いことが原因であると考えられる。

消費可能時間 u_i においても、目的関数値について同様の傾向が確認された。特に $u_i = 6$ および $u_i = 9, 12, u_i = 15$ でそれぞれ明らかな目的関数の違いが確認できる。ここで u_i の各値における車両の必要な休憩回数に着目する。バッファが $b_j = 15$ となる車両は $u_i = 6$ および $u_i = 9, 12, u_i = 15$ のときそれぞれ 13 回休憩する必要がある。 $b_j = 15$ である車両の割合は本節冒頭に述べた通り、全車両の 97% である。したがって、目的関数値の増加は休憩回数に大きく影響されることが確認できる。

計算時間に関しては、 $u_i = 15$ および $u_i = 6, 9, 12$ の間で増加の傾向が確認されたが、 $u_i = 6$ および $u_i = 9, u_i = 12$ 間では顕著な傾向は確認できなかった。

これらの結果から RALMTD はパラメータ設定によって、施設数とその供給能力のバランスを制御できることが確認できた。また、計算コストがかかる一方、得ら

Table 3.2: Objective values and computation time by capacity and expendable time of facilities.

Model	Capacity (c_i)	Objective value	Expendable time (u_i)	Computation time (sec)
RALMTD	3	6	30	26075.98
		9	20	12263.98
		12	20	25829.67
		15	11	9947.59
	4	6	29	14630.68
		9	19	8641.96
		12	19	19915.92
		15	10	2103.83
	5	6	29	1861.87
		9	19	1699.73
		12	19	2530.52
		15	10	979.58
	6	6	29	4896.96
		9	19	3476.14
		12	19	1765.70
		15	9	980.37
	7	6	29	4079.36
		9	19	1509.94
		12	19	1393.81
		15	9	1060.65
100	6	29	1609.64	
	9	19	1646.02	
	12	19	2206.23	
	15	9	816.78	
RALM	-	-	9	0.01

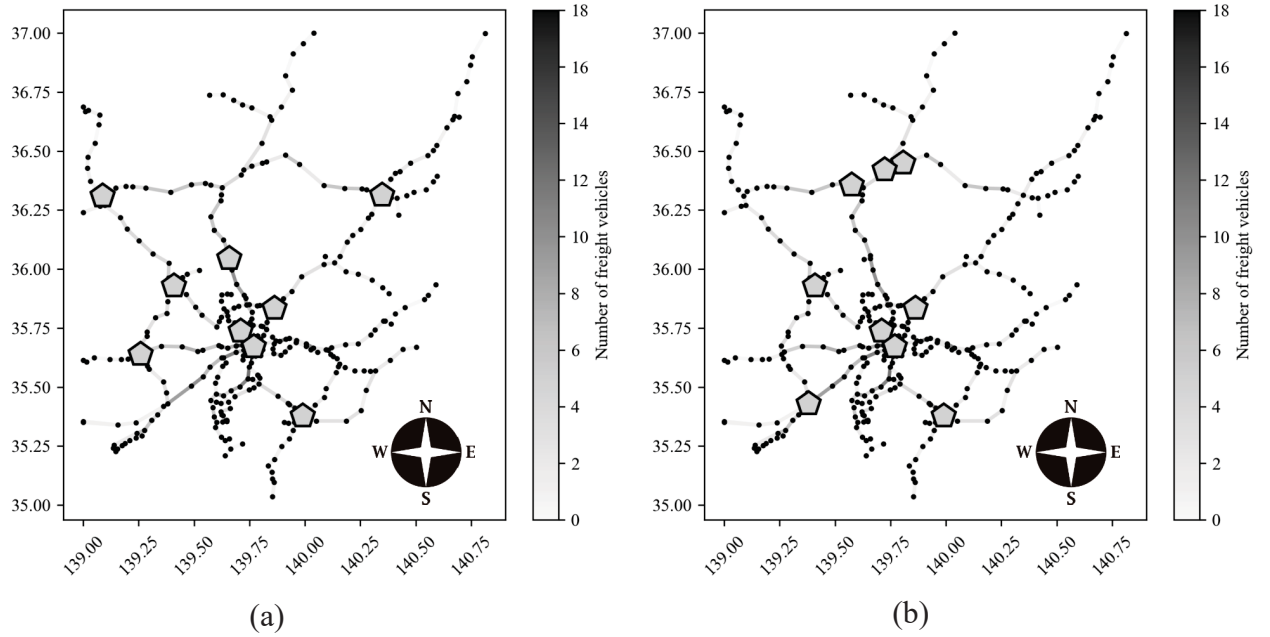


Fig. 3.6: Optimal location. (a) RALM; (b) RALMTD with $c_i = 100, \forall i \in I$.

れる結果が持つ情報量ではRALMに対して上位互換性を持っていることを明らかにした.

3.5 結言

貨物輸送車を個体, 貨物輸送者が持つバッファを時間駆動する需要とみなして施設配置と輸送スケジュールを同時に与えるRALMTDを提案した. RALMTDは施設という局所的な点で二次元道路ネットワーク上を移動する個体の相互作用を予測し, 施設の配置を決める一種のMASである. 予備実験では簡単な仮想道路ネットワークを用いてその挙動の正しさを確認した. 東京周辺の高速道路ネットワークに基づいて生成した道路ネットワークを用いた実験では, 施設容量を変化させることで施設配置箇所や計算時間の観点からRALMTDを評価した. RALMTDはLSCMと同一の構造を持つRALMに比べ大幅に計算コストがかかるが, RALMでは考慮することができなかった需要の時間的競合を加味し, 貨物輸送車の輸送スケジュールを提供できることを示した.

VRPに代表される従来の輸送スケジューリング問題では車両が走行する経路に着目されていた. 一方, 本研究の対象である長距離輸送トラックにおける輸送スケジューリング問題では, 車両がいつどこを走行するか, という事のみならず, 車両




Fig. 3.7: Location of facilities and the maximum number of freight vehicles by each capacity.

がどの施設をどれくらい利用するのか、さらにその施設はどこに配置すると良いのか、という点も考慮しなければならない。本研究で提案したRALMTDはVRPなどの輸送スケジューリング問題では考慮できなかった、施設の配置、時間依存の車両位置、施設利用における競合などの制約を同時に満たす解を求めることができる。さらにRALMTDは、長距離トラックの経路や施設利用を考慮した既存研究では考慮できなかった、複数車両に対する輸送スケジュールの作成及び競合の考慮が可能になった。RALMTDにより配置された施設と輸送スケジュールは、渋滞や事故につながる路上駐車の高頻度を削減し、道路の運用効率を向上が可能であることを示唆している。

ここまで示した結果より、RALMTDは整数変数を扱うことができ制約条件により詳細な条件を組み込めることから複雑性は高いといえる。また、RALMTDは得られた解に最適性が保証される点から、確率論的アプローチによるMASシミュ

レータに対して解の質という観点で優位性があるといえる。一方で、膨大な計算コストを要すること、個体の移動に1次元的な制約があることなどから、確率論的アプローチによるMASシミュレータに対して完全な優位性があるとは言い難い。また、個体を取りうる行動はパラメータにより規定されるが、より現実的にはパラメータには不確実性を考慮すべきである。本章で取り扱った問題においては、制約条件に不確実性を考慮することで実現可能であるがそのような問題は整数二次錐計画問題に分類される。しかし、整数二次錐計画問題も整数計画問題と同様にNP困難であることから [66] 計算コストの問題が依然として残る。

これらの点から、多数のシナリオに対する効果を検証するために試行錯誤的な解の探索が必要な場合においては、確率論的アプローチによるMASシミュレータに対して優位性は低いといえる。

4 機械学習モデルによる高速なシナリオ選定のための枠組み

第3章で提案し、整数計画法により定式化されたMASの数理モデルは、入力に対して一意的に出力が定まり施策の最適性を保証するが、膨大な計算コストにより入力に対する複雑性が担保されにくいなどの弱点があった。

そこで、最適化手法の一つである機械学習を用いて、複雑性を有する大規模な空間を想定した社会において高速に多数の入力構成に対する出力を予測するための枠組みを提案する。具体的には、社会に対して検証したい多数の施策の中から、効果的な施策を選定するための枠組みを、第2章でレビューしたMASシミュレータと機械学習モデルの一つであるSVRを用いて実現する。また、提案した枠組みにより構築したSVRモデルの予測精度と学習用データセットにおける出力の収束性に着目し、その関係について検証を行った。

4.1 緒言

COVID-19の感染に伴い、感染症拡大に対する予測手法に関する研究は盛んに行われている [27, 67–72]。感染症が蔓延する社会においては、感染リスク低下に寄与する政策や感染防止策などによる感染抑制のための戦略が求められる。また、社会情勢は刻々と変化することから、感染拡大を制御する戦略は迅速に決定されなければならない。

SIRモデルは感染症伝搬をシミュレーションする決定論的手法としてよく知られており、感染状態と回復状態の変化を微分方程式で表現するモデルである [11]。SIRモデルは感染状態を暴露 (Exposed) 状態と発症 (Infectivity) 状態に分別するSIERモデルや死亡 (Dead) 状態を含むSIERDモデル、ワクチン接種を考慮したSIRVDモデルなど拡張されている [8–10]。これらのモデルは、微分方程式を数値計算により解くことで高速に計算することができる一方、新たな状態や条件をモデルに導入するためには微分方程式を再定式化しなければならないことから、感染予防対策に対する詳細な諸条件を組み込むことは困難である。また、微分方程式によって表現されるSIRモデルやその拡張モデルは感染力を一つのパラメータを用いて表現する。このとき、用いられるパラメータはウイルス本来の感染力を表すものではなく、小規模な視点ではマスクの着用やソーシャルディスタンスの確保、大規模な視点ではロックダウンや自宅待機命令などの感染予防対策などの効果を含んだ感染力を表現

する。このように、微分方程式による SIR モデルやその拡張モデルに代表される決定論的手法では、様々な対策を一つのパラメータに集約していることから、詳細な感染予防対策を考慮してシミュレーションを行うことができない。

このことから、Farooqa *et al.* [9] は SIRVD モデル、すなわち決定論的手法に置けるモデルパラメータの予測精度を向上させるための、適応型深層学習モデルを用いた枠組みを提案している。提案された枠組みはモデルパラメータの学習とモデルの更新が同時に行われる。また、Farooqa *et al.* は感染力を表すパラメータをロックダウンの有無により分けることで、予測性能を現実近づけている。一方で、Farooqa *et al.* により提案された枠組みでは、現実世界の特定地域で実際に実施された数ある感染対策の組み合わせにより一意に決まるシナリオしか学習することができない。さらに、様々な要素が複雑に絡み合って決定される感染力が1次元のパラメータに集約されるため、現実世界では実施されたことのない感染予防対策の組み合わせを検証することは困難といえる。

MAS は仮想空間内に複数のエージェントを配置し、エージェントの行動に対して具体的な制約を与えることで社会全体の動きをシミュレーションする確率論的手法を用いた枠組みである。MAS によるシミュレーションはエージェントの行動により発生するイベントや個別のエージェントの状態を容易に与えることが可能であることから、決定論的手法に比べてより柔軟に社会動態を分析することが可能である。このような理由から、感染予防対策の効果検証に対しても盛んに利用されている [27,69,71–75]。一方で、確率論的手法であるがゆえに一度のシミュレーションでは外れ値の影響を排除できないため、同一条件による複数のシミュレーション出力（例えば感染者の総数）を平均化しないと結果が安定しない。また、大規模な仮想空間に対して多くのエージェントを与えると計算コストが顕著に増加する。例えば Omae *et al.* [72] は 45 日間、999 人の感染症拡大シミュレーションにおいて、1 シナリオに対して 300 回のシミュレーションを行い出力を平均化しているが、汎用計算機 (Intel®Core™i5-8500@ 3.00GHz, 8GB RAM) を用いた 1 シナリオあたりの計算時間は 12 時間であることが報告されている。このように、複数の感染予防対策の組み合わせにより決まる多くのシナリオをスクリーニングする目的で MAS を利用することは計算時間の点から適切とは言えない。

計算コストとモデルの再現性に対する問題を解消すべく Hirose *et al.* は MAS と微分方程式 (Differential equation) を組み合わせたハイブリッド手法である MADE (Multi-agent and differential equation) を提案している [76]。MADE は感染者の総数を早期に推定することを目的として提案されており、MAS により感染拡大の初期段階を

シミュレーションし、その後 MAS により得られた情報をもとに SEIR モデルを用いて感染症拡大シミュレーションを行う手法である。具体的には、時刻 t における MAS に基づくシミュレーションの感染状態別エージェント数に基づいて、感染率などの SEIR モデルにおけるパラメータを推定する。MAS によるシミュレーションは感染イベントの増加によりシミュレーション中盤から大きな計算コストを要するため、MADE では中盤から終盤にかけてシミュレーション手法を MAS から SEIR モデルに切り替えることで計算コストの削減を図っている。しかし、シミュレーション中盤以降に用いられる SEIR モデルは決定論的手法であることから、感染者数が増加する中盤以降にロックダウンや自宅待機命令などといった施策を実施する場合、MADE はそれを考慮することができない。

本研究では、決定論的手法および確率論的手法の限界を克服するため、機械学習モデルを用いて MAS に基づくシミュレーションに対する感染予防対策などの諸条件を高速にスクリーニングするための枠組みを構築する。機械学習モデルのデータセットは MAS によって生成され、シミュレーションの初期条件や感染予防対策に関する諸条件が入力として与えられ、感染者の総数を出力する。このように MAS と機械学習モデルを組み合わせる手法は MAS に対する代替モデルとして Lamperti *et al.* により提案されている [25,26]。また、Angione *et al.* は Lamperti *et al.* により提案された枠組みに対して、複数の機械学習モデルの予測精度を比較検証している [24]。しかしこれらの研究は MAS から一意に出力が得られることを前提としており、出力に不確実性を持つような MAS は想定されていない。また、これらの研究は機械学習モデルと MAS を組み合わせるといった基本的なアイデアを提供しているものであり、精度向上や入力に対するロバスト性などについて十分な検討がされていない。

そこで本研究では、不確実性を内在する MAS として Omae *et al.* によって開発された MAS に基づくシミュレータ [27,71] を採用し、複数のシナリオを入力として持つデータセットを生成した。生成したデータセットを用いて機械学習 (ML: machine learning) モデルを学習させることで、MAS の不確実性を考慮した高速スクリーニングのための枠組みである MAS-ML を構築する。機械学習モデルには SVR を採用する。SVR は非線形回帰を行うことが可能なサポートベクターマシンの一種であり、盛んに研究されている [77-82]。SVR はデータセットが大きすぎなければ現実的な時間で他の回帰手法に比べて高い精度の予測を行うことができる。MAS-ML は MAS によるデータセット生成やデータセットの学習には時間がかかるものの、一度データセットを生成してしまえば SVR が持つ特長を生かし MAS のシミュレーション結果を高速かつ高精度に予測することが可能である。このように、MAS-ML は感

染予防対策が必要となる前にあらかじめ学習済みのモデルを用意しておくことで、多くのシナリオに対する総感染者数の見積もりに関するスクリーニングを簡略化することができる。ただし、本研究で提案する MAS-ML は MAS ベースのシミュレーション終了時の感染者の総数を予測するものであり、MAS によるシミュレーションで得られた感染拡大過程に関する出力は行わない点に注意する。

MAS-ML の性能をオリジナルの MAS や本研究と同様の目的で提案された既存手法と数値実験により比較し、MAS-ML の優位性を示した。また、MAS-ML により学習されたデータセットでは想定されていない入出力に対して、MAS-ML により生成したモデルの挙動を確認した。COVID-19 のパンデミック下で有効な対策とされる自宅待機命令に関するパラメータに対して感度分析を行い、MAS-ML の検証を行った [83–85]。実験の結果、MAS-ML は元の MAS によるシミュレーションの出力が学習データの範囲外であったとしても、正確に予測できることが確認された。さらに、既存手法との比較においては、MAS-ML が推定精度と計算コストの両面において優れていることを実証した。加えて、コロナ禍における自宅待機命令に関する道の入力に対して感度分析を行い、MAS-ML は直感的に正しい出力を与えられることが確認された。また、これらの結果から高精度な MAS-ML を構築するためのデータセット生成に関する指針について考察した。MAS-ML は複雑な入力を与えることが可能であり、一度データセットを生成、学習してしまえば高速に多くのシナリオをスクリーニングできることを示した。

4.2 先行研究

Hirose [76] により提案された MADE は確率論的手法のみを用いた枠組みに比べてより少ない計算コストで、決定論的手法に比べて詳細な感染予防対策を検証可能である、という点で本研究と類似の目的を持っている。そこで本節では、MADE の具体的な手法に着目してレビューする。

MADE の基本的なアイデアは、感染症拡大の初期段階のみを詳細な感染予防対策を組み込める MAS を用いてシミュレーションすることである。MADE は MAS によるシミュレーションで得られた感染者数に基づいて、微分方程式で表現される SEIR モデルのパラメータを推定する。このとき用いられる SEIR モデルは次の微分方程

式により記述できる.

$$\frac{dS(t)}{dt} = -\lambda S(t)I(t), \quad (4.1)$$

$$\frac{dE(t)}{dt} = \lambda S(t)I(t) - \sigma E(t), \quad (4.2)$$

$$\frac{dI(t)}{dt} = \sigma E(t) - \gamma I(t), \quad (4.3)$$

$$\frac{dR(t)}{dt} = \gamma I(t), \quad (4.4)$$

なお, S, E, I, R は第2章と同様にそれぞれ感受性者 (susceptible), 感染暴露者 (exposed), 感染者 (infectious), 回復者 (recovered) を表す. なお, 今後それぞれの状態は英語表記の頭文字を取って S 状態のように呼ぶこととする. また, λ, σ, γ はそれぞれ感染率, 発症率, 除去率を表す. 人口の合計は保存される. すなわち, $S(t) + E(t) + I(t) + R(t) = \text{const}, \forall t$ である.

MADE は MAS によるシミュレーションで得られた時間 t および $t+1$ における各状態の個体数を用いて, 時間 t におけるパラメータ λ, σ, γ の近似値をそれぞれ差分方程式

$$\lambda(t) = \frac{S(t) - S(t+1)}{S(t)I(t)}, \quad (4.5)$$

$$\sigma(t) = \frac{\{E(t) - E(t+1)\} + \{S(t) - S(t+1)\}}{E(t)}, \quad (4.6)$$

$$\gamma(t) = \frac{R(t+1) - R(t)}{I(t)}. \quad (4.7)$$

により求める. ただし, Eqs. 4.1–4.4 における時間 t は連続であるが, Eqs. 4.5–4.7 における時間 t は離散である点に注意する. MADE ではシミュレーション手法を MAS から微分方程式に切り替える時間 t を connecting time と呼ぶ.

MADE は MAS により得られたパラメータを定数として SEIR モデル (Eqs. 4.1–4.4) を解くことにより, 感染者数の推定を高速に行うことが可能である. 一方で, MADE は MAS によるシミュレーションの後, すなわち connecting time t 以降にロックダウンや自宅待機命令などの施策が実施された場合, パラメータ (Eqs. 4.5)–(4.7) にはその影響が加味されない点に問題がある.

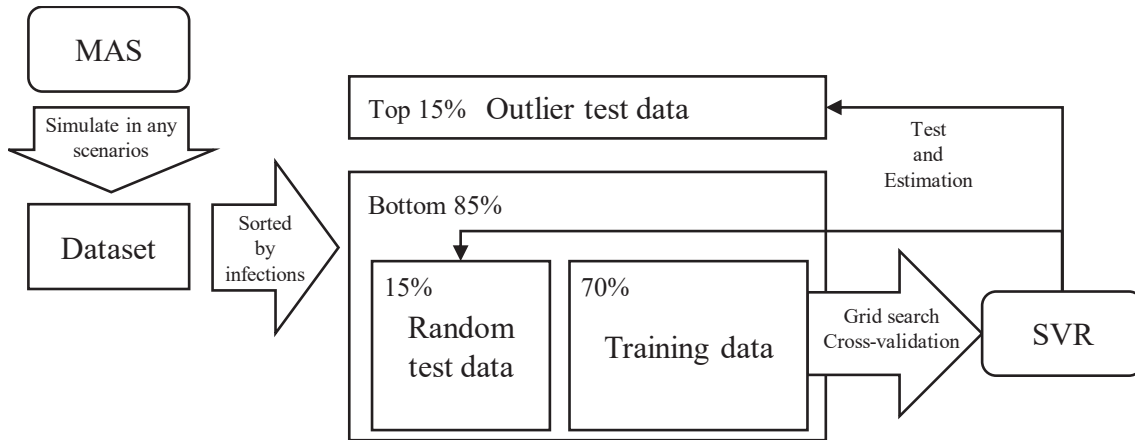


Fig. 4.1: Diagram of the MAS-ML framework.

4.3 シナリオ選定のための枠組み

4.3.1 枠組みの概要

MAS-ML は、複数の入力とその入力構成に対する MAS によるシミュレーションの出力をデータセットとして、機械学習モデルに学習させる枠組みである。MAS は入力に関して詳細な制約を考慮することが可能であり、その MAS によってデータセットを一度生成してしまえば、MAS-ML は多くのシナリオを高速にスクリーニングすることが可能となる。

ここで MAS により集めたデータセットを学習させる機械学習モデルについて考える。SVR は回帰分析手法の一つであり、実測値と推定値との誤差項に加え、正則化項を最小化することにより過学習を防ぐことができる。また、SVR はカーネルトリックを用いることで非線形回帰を行うことができる点が大きな長である。SVR は教師データ数を n とすると $n \times n$ サイズのグラム行列を計算する必要があり、大量の教師データを処理するには向かない。しかし、本研究で提案する手法においては、MAS の計算コストの都合上 SVR で扱いきれないような数の教師データが用意されるとは考えにくい。また、グラム行列の近似化手法や高速な学習アルゴリズムは多くの研究により報告されており [86–88]、扱える教師データの数も大きくなっている。そこで本研究では、機械学習モデルとして SVR を採用し、本枠組みで構築した機械学習モデルを MAS-ML モデルと呼ぶ。Fig. 4.1 は MAS-ML の概念図を示している。なお、MAS-ML は MAS によりデータセットを生成し、そのデータセットを用いて SVR に学習させ、MAS に基づくシミュレーションの出力を予測する枠組みである点に注意する。ただし、機械学習モデルとして SVR を採用することは必

Table 4.1: Advantages and disadvantages of each simulation method.

	Analytical expression	MAS-based simulation	MAS-ML model
Input flexibility	×	○	○
Computational cost	○	×	○
Detailed output	△	○	×

○… Strong, △… Normal, ×… Weak

須ではなく、本枠組みは MAS が適用可能な事例であれば幅広く応用が可能である。

ここで MAS に基づくシミュレーション、微分方程式による SEIR モデル、MAS-ML の特長を Table 4.1 にまとめる。

4.3.2 感染症拡大を表現する MAS シミュレータ

本研究では感染症拡大に関する複数のシナリオを作成する。それらのシナリオに対応する入力構成とその入力構成に対する出力のデータセットを、大前らが開発した MAS に基づくシミュレータ [27, 71]（以後、MAS シミュレータと呼ぶ）を用いて生成する。なお本項で説明する MAS シミュレータは第2章で紹介したものとはパラメータなどいくつか重要な点で相違点があるため、一部説明が重複する。

今回利用する MAS に基づくシミュレータ [27, 71] は第2章において紹介したものと同様であり、従来の SEIR モデルと同様にエージェントに Susceptible, Exposed, Infectious, Recovered, Dead の状態を持たせる。また、各状態からある状態への遷移は第2章に示した Fig. 2.1 と同様である。なお、E 状態、すなわち感染はしているが発症していないエージェントが S 状態のエージェントへの感染能力があるかについては本来議論が必要であるが、第2章に示したと同様、感染能力をあるものとして扱う。また一般的には R 状態から S 状態への遷移、すなわち感染者が回復し再度感受性者になることを考えるが、本研究ではシミュレーション期間を 28 日と短期間に設定することからこの遷移は考慮しない。

大前らの MAS には 24 個の入力パラメータが存在し、本研究では各パラメータを Table 4.2 のように設定する。各世帯には会社員、主婦、学生という属性を持った 3 人のエージェントが住んでいるものと仮定する。そのため、世帯数が 250 であればシミュレーション空間内の人口は 750 人となる。また、各エージェントは属性ごとに外出確率や外出時刻、外出先での滞在時間が異なる。感染イベントは S 状態のエージェントと I もしくは E 状態のエージェントとの距離がある値以下になった場合に発生する。その際、S 状態のエージェントが E 状態に遷移する確率が “Infection

Table 4.2: Parameters of the MAS-based simulator for infectious disease transmission.

Parameters	Values
Simulation period	29 [days]
Houses	Refer to Table 4.3
Initial symptomatic agents	10 [people]
Trip prob. (workers)	99.0–100 [%]
Trip prob. (homemakers)	50.0–100 [%]
Trip prob. (students)	99.0–100 [%]
Departure time (workers)	8:30:00 ± 1:30:00
Departure time (homemakers)	10:30:00 ± 1:30:00
Departure time (students)	8:30:00 ± 1:30:00
Stay time outside (workers)	6:00:00–8:00:00
Stay time outside (homemakers)	0:10:00–0:30:00
Stay time outside (students)	5:00:00–6:00:00
Companies	10 [locations]
Stores	10 [locations]
Schools	10 [locations]
Infection prob.	Refer to Table 4.3
Prob. of hospital visiting	60.0 [%]
Capacity of isolation wards	Refer to Table 4.3
Fatality rate (Non hospitalization)	10.0 [%]
Fatality rate (hospitalization)	1.0 [%]
Start cond. (stay-at-home)	Refer to Table 4.3
Removal cond. (stay at home)	10 [people]
Reduced level of trip prob.	Refer to Table 4.3
Maximum SSN size	25 [people]

Table 4.3: Input configuration parameters of the ML training dataset.

Parameters	A	B	C
Houses [unit]	250	500	750
Infection prob. [%]	0.03	0.06	0.09
Reduced trip prob. levels [%]	30	60	90
Capacity of isolation ward [bed]	0	5	10
Start cond. (stay-at-home) [people]	75	150	225

probability”となる。自宅待機命令は感染者数が“start condition”に達した際に発令される。また、感染者数が“removal condition”以下になると自宅待機命令が解除される。自宅待機命令が発令されると外出確率は“Reduced level of trip probability”だけ減少する。感染イベントはエージェント同士の距離により発生するが、会社や店、学校での感染イベントでは同じ座標にエージェントが密集する場合、非現実的な状況が発生する。そこで大前らはそのような座標ではいくつかの Small scale network (SSN) を生成しそれぞれ別の空間として感染イベントを発生させる工夫をしている。その他パラメータの詳細や MAS シミュレータの仕様については文献 [27,71] を参照されたい。

大前らの MAS シミュレータは 24 個の入力パラメータが存在するが、これらすべてを変化させデータセットを作成することは計算時間の観点から現実的ではない。そこで本研究では 24 個のパラメータのうち Table 4.3 に示す 5 個のパラメータに着目し、これをデータセットの入力部分とする。これら 5 個のパラメータの全組み合わせ、すなわち $3^5 = 243$ 個のシナリオを作成し、それぞれ MAS シミュレータによりシミュレーションすることでデータセットを生成する。なお、MAS は感染リスクなどの乱数依存のイベントが存在する場合、パラメータ設定が同じでもシミュレーションごとに異なる結果が得られる。本研究では乱数による外れ値の影響を小さくするため、各シナリオごとに 25 個の乱数シードを用いてシミュレーションを行い、その平均値をデータセットの出力部として用いる。そのため、シナリオ数と乱数シード数の積、すなわち $243 \cdot 25 = 6,075$ 回分のシミュレーション結果をデータセットの生成に使用する。

4.3.3 Support vector regression

次のような回帰式を考える.

$$f(\mathbf{x}; \mathbf{w}, b) = \langle \mathbf{w}, \phi(\mathbf{x}) \rangle + b. \quad (4.8)$$

ここで ϕ は入力空間 X の特徴量空間 \mathcal{Z} への非線形写像 $\phi: X \mapsto \mathcal{Z}$ であり, $\langle \cdot, \cdot \rangle$ は内積を意味する. 以降 $f(\mathbf{x}; \mathbf{w}, b)$ は $f(\mathbf{x})$ と表記する. SVR において, パラメータ \mathbf{w} , b は次の評価関数を最小化することにより得られる.

$$\frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i \in N} \max(0, |y_i - f(\mathbf{x}_i)| - \varepsilon). \quad (4.9)$$

ただし, y_i は観測データ i の出力であり, $N = \{1, 2, \dots, n\}$ である. Eq. 4.9 の第1項は過学習を防ぐための正則化項, 第2項は実測値と推定値との差の絶対値で与えられる誤差項である. なお C は誤差項の重み, ε は誤差に対する不感帯を決める定数であり, どちらもハイパーパラメータである. パラメータ ε を導入することで ε 以下の誤差は無視されるため, これによりノイズに強いモデルとなる.

Eq. 4.9 はスラック変数 ξ_i, ξ_i^* を導入することで次のような最適化問題に書き換えることができる.

$$\text{Minimize } \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i \in N} (\xi_i + \xi_i^*), \quad (4.10)$$

$$\text{subject to } y_i - f(\mathbf{x}_i) \leq \varepsilon + \xi_i, \forall i \in N, \quad (4.11)$$

$$-y_i + f(\mathbf{x}_i) \leq \varepsilon + \xi_i^*, \forall i \in N, \quad (4.12)$$

$$\xi_i, \xi_i^* \geq 0, \forall i \in N. \quad (4.13)$$

この最適化問題 (Eqs. 4.10–4.13) に対するラグランジュ関数を Karush-Kuhn-Tucker 条件を用いて整理すると回帰式 (Eq. 4.8) は次のような形で表せる.

$$f(\mathbf{x}) = \sum_{i \in N} (\alpha_i - \alpha_i^*) \langle \phi(\mathbf{x}_i), \phi(\mathbf{x}) \rangle + b. \quad (4.14)$$

ここで α_i, α_i^* はラグランジュ乗数であり, 問題 (Eqs. 4.10–4.13) に対する双対問題を解くことにより得られる. また非線形写像の内積 $\langle \phi(\mathbf{x}_i), \phi(\mathbf{x}) \rangle$ によって決まるカー

ネル関数を次のように定義する.

$$k(\mathbf{x}_i, \mathbf{x}) = \langle \phi(\mathbf{x}_i), \phi(\mathbf{x}) \rangle. \quad (4.15)$$

すると Eq. 4.14 は Eq. 4.15 を用いて次のように書き換えられる.

$$f(\mathbf{x}) = \sum_{i \in N} (\alpha_i - \alpha_i^*) k(\mathbf{x}_i, \mathbf{x}) + b. \quad (4.16)$$

このように Eq. 4.14 の内積をカーネル関数に置き換えることで非線形写像 $\phi(\mathbf{x})$ を直接求める必要がなくなる. 多くの場合, SVR におけるカーネル関数には Eq. 4.17 に示す Radial basis function (RBF) カーネルが用いられる.

$$k(\mathbf{x}_i, \mathbf{x}) = \exp(-\gamma \|\mathbf{x}_i - \mathbf{x}\|^2). \quad (4.17)$$

RBF カーネルを与えることで Eq. 4.16 は非線形の回帰が可能となり, SVR の性能を飛躍的に向上させる. Eq. 4.17 右辺の γ はハイパーパラメータであり, その値が小さいほど一つの教師データが与える影響の範囲が大きくなる.

4.4 数値実験

4.4.1 実験方法

本実験では Intel®Core™i5-8500@ 3.00GHz, 8GB RAM が搭載された汎用計算機を用いる.

4.4.1.1 MAS-ML の検証

ここでは MAS により得られたデータを用いて教師データとテストデータに分割し SVR を構築, 検証する方法を述べる. 今回用意したデータセットでは MAS における 5 つのパラメータを可変とし, 243 個のシナリオを用意した. なお, MAS の結果は感染確率などの事象を含む場合, 乱数依存で結果がその都度変わってしまう. そこで, 外れ値の影響を小さくするため各シナリオにおいて乱数シードを変更しながら 25 個の結果を取得し, その平均値をそのシナリオのシミュレーション結果として採用している.

今回の実験に利用するデータセットは乱数による影響を排除しているため, データセットに存在する出力の範囲内の値が正解になるような入力であれば高い精度で予測できることが予想される. 一方, 範囲外の値が正解になるような入力を与えら

れた場合にはこの限りではない。そのため、MASにより得られたデータセットを用いて構築したSVRは、入力に対する真の出力がデータセットにおける出力の範囲内である場合とそうでない場合でその精度が大きく変わる可能性がある。そこで本研究では元のデータにおいて、感染者数が多いデータ（これを外れ値テストデータと呼ぶ）とランダムサンプリングしたテストデータの2種類を用意する。これら2種類のテストデータを除いたデータを教師データとしてSVRを構築する。ここで、任意の教師データ、ランダムサンプリングテストデータ、外れ値テストデータそれぞれの出力 $y, y_{\text{test}^{\text{rs}}}, y_{\text{test}^{\text{ol}}}$ には以下のような関係がある。

$$y_{\text{train}}, y_{\text{test}^{\text{rs}}} < y_{\text{test}^{\text{ol}}}$$

本研究では、教師データ70%、ランダムサンプリングテストデータ15%、外れ値テストデータ15%としてSVRのモデル構築および評価を行う。外れ値テストデータはデータ全体を出力、すなわち感染者数が大きいデータ上位15%を抽出している。またランダムサンプリングテストデータをデータ全体の下位85%から抽出する際には、教師データとの有意差が出ないように注意する必要がある。本実験において、教師データ群とランダムサンプリングテストデータ群の出力データ、すなわち感染者数をMann-WhitneyのU検定を用いて検定した結果有意差は認められなかった ($p \approx 0.862 > 0.05$)。

評価には以下の式で表される決定係数を用いる。

$$R^2 = 1 - \frac{\sum_{i \in N} (y_i - f(\mathbf{x}_i))^2}{\sum_{i \in N} (y_i - \bar{y})^2}. \quad (4.18)$$

4.4.1.2 MADE との比較

本研究の優位性を明らかにするため、MAS-MLと高速感染シミュレータに関する既存手法であるMADE [76]の比較実験を行う。MAS-MLとMADEは第4.4.1.1に示したMASデータセットを使って、MASによるシミュレーション終了時の総感染者数を予測する。各手法の予測結果はEq 4.18に示した決定係数により評価される。

MADEはシミュレーション手法をMASから微分方程式に切り替える接続時間 t [day]によりその精度が大きく変わる可能性がある。そこで、MADEにおける接続時間 t [day]を1–28 [days]の間で推移させてその予測精度を評価する。

なお、[76]で提案されたMADEにおけるSEIR modelでは、S状態の個体はI状態の個体との接触でしか感染しないものとしている。一方、本研究に用いるMAS [27,71]はE状態の個体からの感染を発生させているため、MADEにおけるEqs. 4.1, 4.2を

次のように再定式化する.

$$\frac{dS(t)}{dt} = -\lambda S(t)I(t) - \lambda S(t)E(t), \quad (4.19)$$

$$\frac{dE(t)}{dt} = \lambda S(t)I(t) + \lambda S(t)E(t) - \sigma E(t). \quad (4.20)$$

また, MAS [27, 71] における死亡者は回復者とみなして, 微分方程式のパラメータが計算される.

4.4.1.3 自宅待機命令に対する感度分析

新型コロナウイルスの蔓延以降, 緊急事態宣言による人流削減が感染者数削減に大きく寄与することが世界中で報告されている [83–85]. また, MAS が外出自粛制限の効果検証に有効であることは複数の研究により報告されている [71, 89]. そこで, MAS-ML が感染予防対策のスクリーニング手法として有効であるか検証するため, その一例として MAS に組み込まれた外出自粛制限の効果を再現できるか, 実験する.

第 4.4.1.1 における実験では MAS によるデータセットを教師データとテストデータに分割する. 一方, 本実験は未知の入力に対して MAS-ML による外出自粛効果を確認することが目的であるため, MAS-ML の精度検証を行う必要はない. そこで高精度な MAS-ML モデルを構築するため, ここでは MAS によるデータセットをすべて教師データとして SVR に学習させる. さらに構築した MAS-ML は Table 4.3 における二つのパラメータ “Reduced trip prob levels” および “Start condition (stay-at-home)” について感度分析を行う.

4.4.2 ハイパーパラメータチューニング

ここでは SVR におけるハイパーパラメータ, すなわち C, ϵ, γ を定める. SVR におけるハイパーパラメータの調整は一般的に Grid Search と Cross Validation を組み合わせた手法 (GS+CV) が用いられる. GS+CV による手法は網羅的にパラメータ空間を探索するため教師データの数が大きい場合には多大な計算コストがかかることから, GS+CV に比べて効率的になるべく良いパラメータを探索する手法は Kaneko *et al.* により提案されている [90]. 一方, 今回用意したデータセットは 243 個と比較的少なく探索すべきパラメータ空間が小さいため, GS+CV によりハイパーパラメータを決定する. Fig. 4.2 に GS+CV の概念図を示す. なお各ハイパーパラメータの候

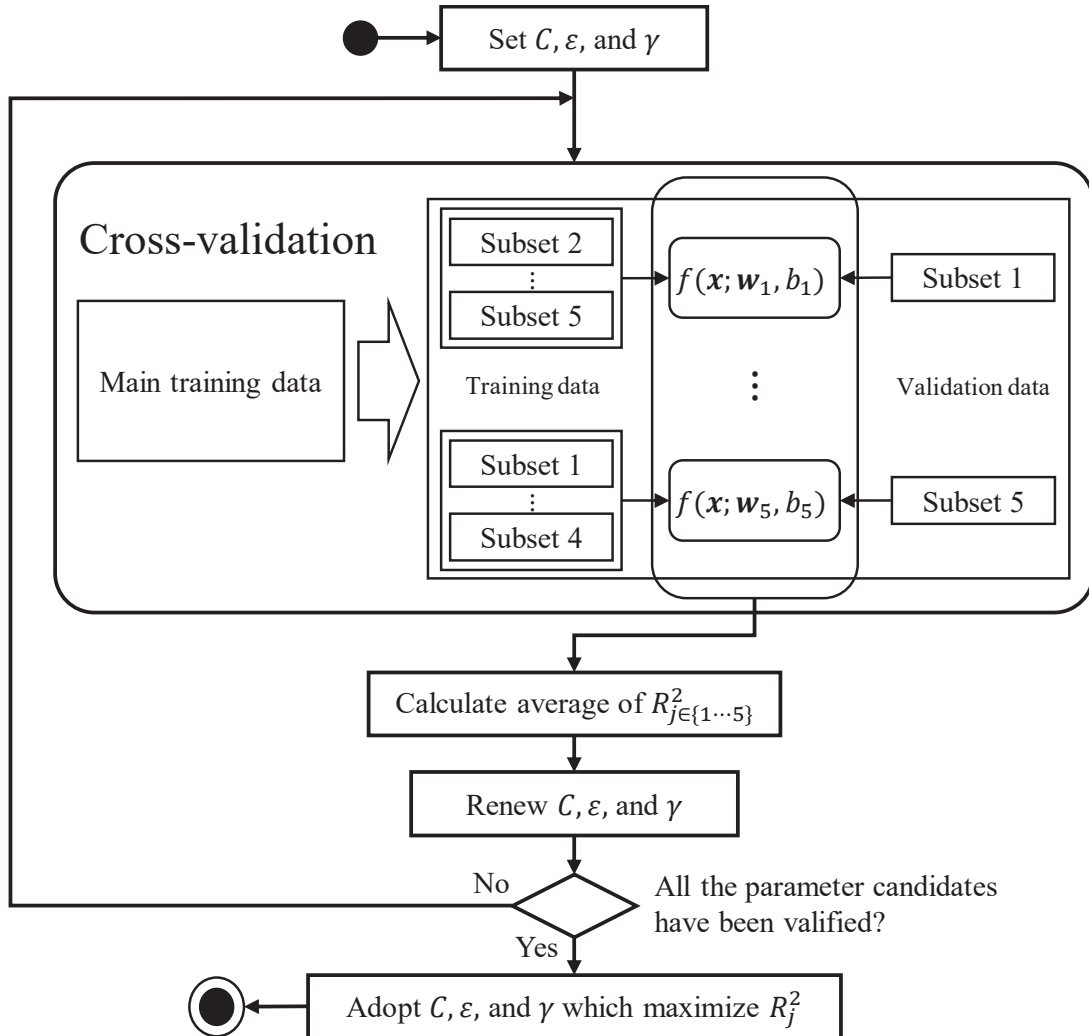


Fig. 4.2: Flowchart of hyperparameter tuning.

補は次のとおりである.

$$\begin{aligned}
 C &\in \{2^0, 2^1, \dots, 2^{10}\}, \\
 \varepsilon &\in \{2^{-10}, 2^{-9}, \dots, 2^{-1}\}, \\
 \gamma &\in \{2^{-10}, 2^{-9}, \dots, 2^{10}\}.
 \end{aligned}$$

CV の Fold 数は 5 として、検証用のデータは教師データの中からランダムに抽出されるものとする。さらに、選択されたハイパーパラメータにより構築されたモデルの評価は、Eq. 4.18 決定係数 R^2 により行い、最も R^2 が大きいハイパーパラメータの組み合わせを採用する。

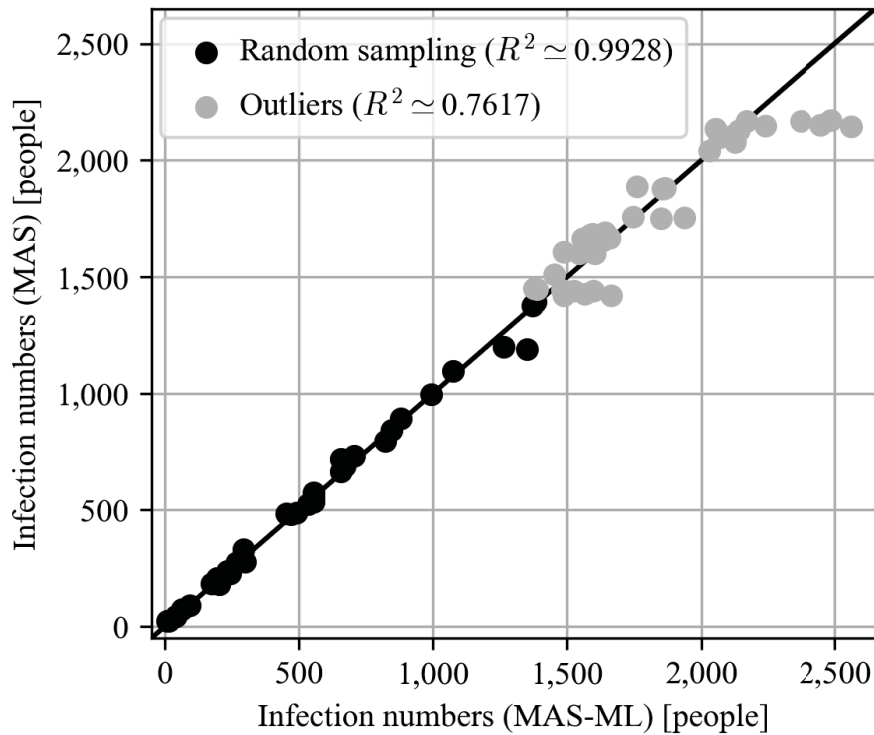


Fig. 4.3: Prediction results for random sampling and outlier test dataset.

4.4.3 結果と考察: MAS-ML の検証

第 4.4.1 項までに準備したデータセットを学習させた MAS-ML モデルの評価を行う。SVR におけるハイパーパラメータは第 4.4.2 項に基づいてチューニングを行い得られた $C = 2^7, \epsilon = 2^{-9}, \gamma = 2^{-3}$ を用いた。また、各データセットについて、学習済みの MAS-ML モデルを用いて MAS シミュレータで得られた総感染者数を予測した。

教師データを入力とした場合、決定係数は 0.9999 となり正確に予測できることを確認した。今回用意したデータセットは MAS で作成しており、データセットの出力は MAS のパラメータによって決まる。感染イベントなどの確率依存イベントは存在するが、複数の乱数シードを用いて平均化している。このことから教師データには入力と出力に顕著な傾向が存在しており、それにより正確な推定ができたものと考えられる。

次にランダムサンプリングテストデータ、外れ値テストデータを入力して予測した結果を確認する。予測結果を Fig. 4.3 に示す。縦軸が推定値、横軸が実測値である。ランダムサンプリングテストデータでは教師データと同様高い精度で予測でき




Fig. 4.4: Determination coefficients obtained for different numbers of random seeds. When a large number of random seeds are used for averaging, the randomness is removed and the determination coefficients become stable and have high values.

ており、これは教師データで決定係数が高い理由と同じである。

外れ値テストデータを入力とした場合、高い精度で予測できているもののランダムサンプリングテストデータに比べると予測精度が落ちている。出力範囲 $y_{\text{test.ol}} < 2000$ においては概ね正しく評価できている一方、出力範囲 $y_{\text{test.ol}} \geq 2000$ においては過剰に感染者数を評価している。すなわち、本研究で構築したSVRでは大きく教師データの出力範囲から外れる場合には正しく感染者数を評価できない可能性がある。このことからMASを用いて教師データを生成する場合には、あらかじめ想定されるおおよその出力範囲を見積っておくことが重要といえる。

Fig. 4.3 に示した結果は25個の乱数シードの結果を平均して教師データとした。各乱数シードにおける結果は乱数依存なので平均化に用いる乱数シード数が少なければ少ないほど精度も悪くなると考えられる。そこで乱数シード数を1ずつ増やしていき、訓練データ、ランダムサンプリングテストデータ、外れ値テストデータを予測させたときの決定係数の推移を観察する。乱数シード数に対する決定係数の推




Fig. 4.5: Averages and standard deviations of the MAS-based simulation computation time for varying population scale and infection rate configurations. Color depth indicates time length; standard deviation values are shown in brackets.

移を Fig. 4.4 に示す。縦軸は決定係数，横軸は乱数シード数であり，教師データ，ランダムサンプリングテストデータ，外れ値テストデータに対してプロットしている。

訓練データとランダムサンプリングテストデータはシード数が少ないうちから高い精度を出しており，特にシード数 10 からはほぼ 1.0 で推移している。外れ値テストデータに対する予測ではシード数が少ないと決定係数が低い一方，シード数が 9 を超えると 0.75 以上で安定している。すなわち，あらかじめ出力の範囲がわかっている場合には，平均化に用いるシード数は少なくとも問題ないが，出力の範囲を外れた予測を行う場合には十分なデータ数を用意し，平均化する必要があることがわかる。また，出力範囲がわからない場合には十分な乱数シードを用意し出力を平均化しておくことで，入力に対するロバスト性が向上する。

ここで MAS シミュレータと MAS-ML モデルの計算時間に焦点を当てる。Fig. 4.5 は人口規模と感染確率を変えた場合の計算時間の変化を示す。これらのパラメータを選択した理由は特に計算時間への影響が大きいためである。各マスの数値は人口と感染確率以外のすべてのパラメータと 25 個の乱数シードで得られた結果の平均計算時間であり，マスの色はその大きさを表している。また，カッコ内の数値は標準偏差である。

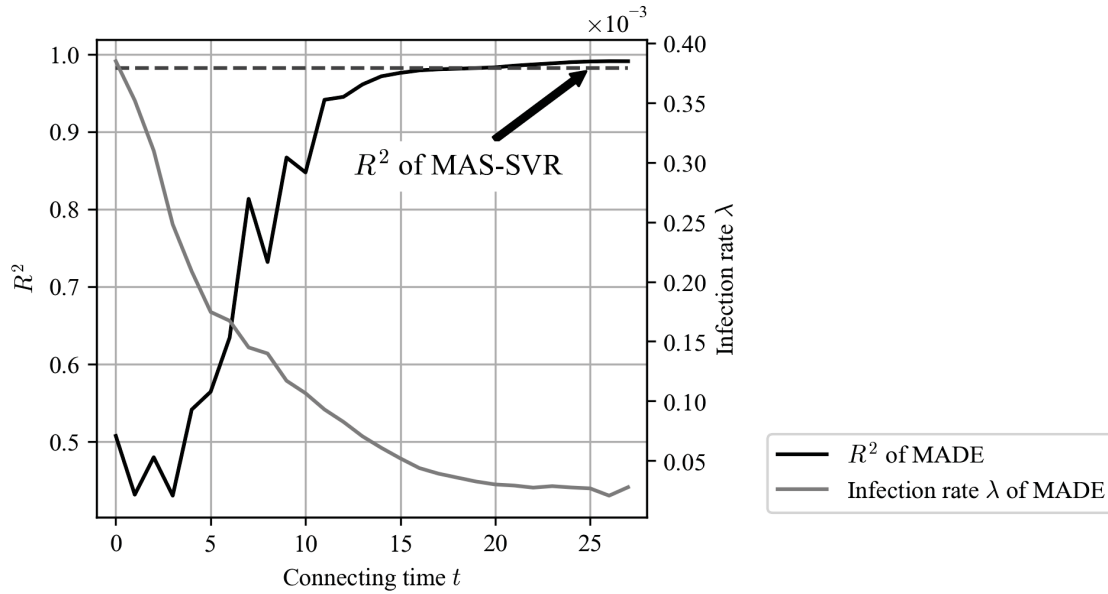


Fig. 4.6: Determination coefficient R^2 transition of MADE for connecting time t . If the simulation method is switched at the early time t , MADE excessively estimates the infection rate λ and the prediction accuracy decreases. As the computation costs by MAS increase if time t is large, this trend indicates that MADE has a trade-off structure.

Fig. 4.5 から明らかなようにどちらのパラメータも大きくなると同じような傾向で計算時間も大きくなることが確認できる。さらにパラメータの組み合わせによっては 1 回のシミュレーションに数十時間かかる場合もあり、このことから MAS がスクリーニングに向いていないことがわかる。なお、ここまで示した学習済みの SVR モデルを用いて得たすべての結果において計算時間は 1 秒未満であった。

MAS-ML は MAS によるシミュレーション結果のみを予測する手法であり、シミュレーション開始から終了までの過程を見ることはできないが、MAS-ML によりシナリオのスクリーニングをすることで、詳細に検証すべきシナリオは大まかに決定することができる。検証すべきシナリオが定まれば、そのパラメータを用いて MAS により詳細な検証を行うことができる。そのため、MAS-ML と従来の MAS を組み合わせて使うことで、正確な検証を短時間で示唆される。

本研究では感染症伝搬シミュレーションを例にとり MAS-ML モデルの構築と検証を行ったが、MAS を適用できる事例であれば同様に MAS-ML は適用可能である。

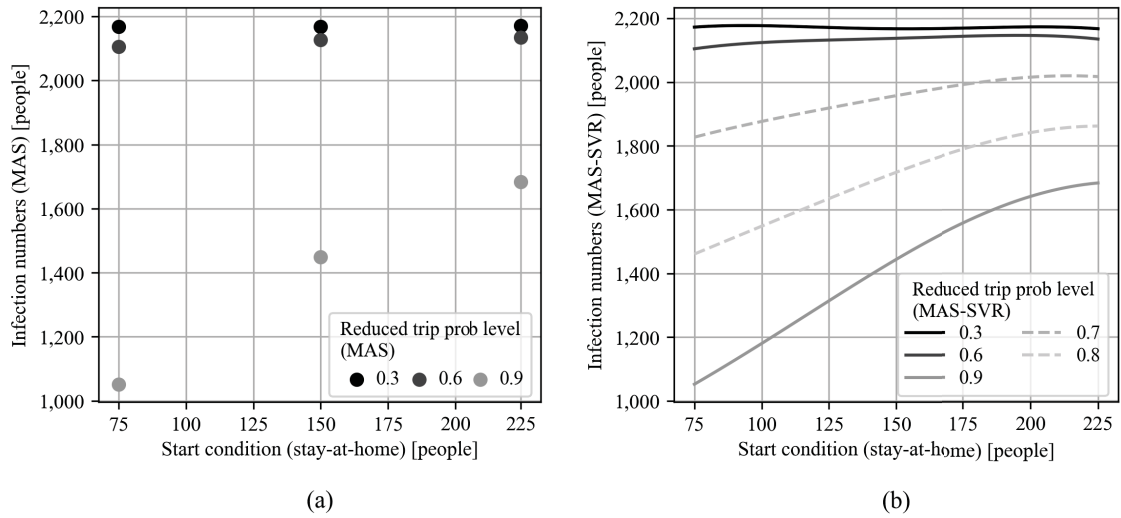


Fig. 4.7: Transition of the number of infected individuals by “reduced trip probability levels” under the “start condition” of stay-at-home. Prediction by (a) MAS and (b) MAS-ML. This implies that MAS-ML can predict the number of infected individuals who are intuitively correct for inputs that do not exist in the train dataset.

4.4.4 結果と考察: MADE との比較

MAS-ML と MADE をすべてのテストデータ (ランダムテストデータおよび外れ値テストデータ) を用いて感染者数を予測させ、その推定精度を比較する。

Fig. 4.6 は MADE における接続時間 t を変化させたときの MADE の決定係数 (4.18) と接続時間 t 時点で推定された MADE における感染力 λ の推移を示している。第1縦軸を決定係数、第2縦軸を感染力、横軸を接続時間としている。なお、黒い破線は教師データを学習させた MAS-ML モデルで全テストデータを予測させたときの決定係数 $R^2 \approx 0.9819$ である。

Fig. 4.6 に示す通り、本実験においてはシミュレーション期間の終盤 (約 71%地点) まで MADE が MAS-ML の予測精度を上回ることがなかった。MAS はシミュレーションの途中から緊急事態宣言や病床数などの感染予防策を考慮できる。しかし、MADE は MAS によるシミュレーションを打ち切った時間 t 時点で感染者数に時間依存の感染予防効果が反映されていないと、感染力 λ を推定することはできない。Fig. 4.6 における感染力の推移を見ても MAS によるシミュレーションを早期に打ち切った場合には、MADE は過剰に感染力 λ を見積もっていることがわかる。シミュレーション中盤以降では、MADE における感染力 λ に MAS における緊急事態宣言等の効果が反映されるため予測精度が向上するものの、これでは Table 4.1 に示

したMASのデメリットである計算コストの問題を解決できない。このように既存手法であるMADEには計算コストと予測精度の間にトレードオフの関係がある。一方で、本研究で提案したMAS-MLはMASで考慮される感染予防策による感染者数削減効果も含めて学習することができるため、高精度に感染者数を推定することが可能であることに加え、計算コストもMADEに比べ大幅に小さい。

4.4.5 結果と考察: 自宅待機命令に対する感度分析

この実験では高精度なMAS-MLモデルを構築するため、MASによるデータセットをすべて教師データとしてSVRに学習させた。ハイパーパラメータ C, ϵ, γ は第4.4.2項と同様の手法で探索した結果 $C = 2^5, \epsilon = 2^{-10}, \gamma = 2^{-3}$ であった。

Fig. 4.7-(a) および (b) における縦軸は感染者数、横軸は自宅待機命令の開始条件である。Fig. 4.7-(a) はSVRを用いて緊急事態宣言の開始タイミングを75–225人の間で1人刻みで変化させ予測させたときの感染者数の推移を外出人数削減率ごとに示している。また、Fig. 4.7-(b) はMASは緊急事態宣言の開始タイミング75, 150, 225人で実際に得られた感染者数をプロットしている。

Fig. 4.7-(a) および (b) において、外出削減率0.3では感染者数はほとんど一定である。また、外出削減率0.3および0.6においては感染者数の推移に大きな違いはないが、0.6および0.9では大きく異なる。この間の傾向を確認するため外出削減率0.7および0.8とした場合のSVRの予測結果の推移を破線で示している。

Fig. 4.7-(a) および (b) よりMAS-MLはMASで得られた結果とほぼ同じ傾向で予測することができることが確認できる。特にMASにデータが存在しない外出削減率0.7および0.8においても直感に反さない予測結果が得られている。さらにMAS-MLはMASに比べて計算コストが大幅に小さいことから、感染予防対策の効果検証に有効であるといえる。

4.5 結言

感染症の伝搬シミュレーションを例に不確実性を内在するMASによりシミュレーション結果のデータセットを作成し機械学習モデルに学習させることで、高速にシミュレーション結果を推定するMAS-MLを提案した。機械学習とMASを組み合わせた基本的な枠組みはすでにLamperti *et al.* により提案されていたが[25, 26], MASがもつ不確実性や入力に対するロバスト性に対する検証が不十分であった。そこで本章ではMAS-MLの構築だけでなく、不確実性が出力に及ぼす影響の度合いや教師データの作成方法による予測精度への影響を調査した。

実験では、MASにより得られたデータセットを教師データ範囲内データと外れ値データの2種類に分け、それぞれをMAS-SVRで構築したモデルに予測させた。その結果、MAS-MLモデルが教師範囲内データでは非常に高い精度($R^2 = 0.9928$)でMASの結果を予測できることを確認した。また、外れ値データであっても1シナリオあたりの乱数シード数を増やすことで高精度($R^2 = 0.7617$)にMASの結果を予測できることが確認された。MAS-MLは一度データセットを作成すればMASと比較して非常に少ない計算コストでその結果を予測できる。例えばMASに基づくシミュレーションで10時間以上かかる計算がMAS-MLモデルでは1秒以下で出力を得ることができた。このことから、MAS-MLモデルはMASにおける複数のシナリオをスクリーニングするような場合に有効であることが示された。さらに、感染者数の高速推定に関する既存手法であるMADE [76]が計算コストと予測精度の間にトレードオフであることを示し、MAS-MLモデルと比較することで本研究の優位性を確認した。最後にコロナ禍における感染症拡大防止に有効であるとされる自宅待機命令について、MAS-MLモデルの感度分析を行った。その結果、教師データに存在しない未知の入力パラメータに対する予測が直感に反さないことを示し、実運用におけるMAS-MLの有用性が示唆された。

MAS-MLはMASに基づいたシミュレーションの出力を予測する枠組みであるため、出力に対するスクリーニングにより得られた入力構成を用いて再度MASにより詳細に検証することで、有効にMASと組み合わせることが可能である。本研究では感染症伝搬シミュレーションを例にとったが、MAS-MLはMASが適用できる事例であれば容易に応用できるため、波及性は高い。

5 小規模空間に対するシミュレーション

第4章までにレビューおよび提案した手法は大規模な空間に対するシミュレーションが対象であった。一方で、社会シミュレーションに複雑性を持たせる場合には小規模な空間で起こるイベントの影響を加味することが好ましい。それにより、より厳密に施策の効果を確認することが可能となる。

そこで、本章では大規模な空間に組み込むことを前提とした小規模な空間に対するシミュレーション手法を提案する。本章では、小規模な空間の対象としてある地域に点在する飲食店舗程度の規模を仮定する。すなわち、ここでいう大規模な空間とは居住区や商業地帯、工業地帯を含む地域、小規模な空間とは大規模な空間に点在する施設程度の規模と仮定している。

また、小規模な空間において多数の試行により出力をある程度収束させる必要があるような対象を仮定する。具体的には、第2章同様 COVID-19 流行禍における社会を仮定する。COVID-19 流行禍において、感染症拡大の主な原因は屋内におけるクラスターでの感染とされていることから、特に感染が多く報告される飲食店舗を対象としてシミュレーションを行う。また、実験ではシステムが介在しないような飲食店舗の営業と、感染症拡大を予防する目的を持ったシステムを導入した場合の営業を比較する。前者に対するシミュレーションでは、飲食店舗利用者の行動パターンに不確実性が介在するため、入力に対する出力の一意性は保証されない。一方で、後者ではあるルールに基づき利用者の行動を制限することにより、不確実性を排除することで一意性を保証する。

5.1 緒言

2019年に発見された新型コロナウイルス COVID-19 は中国の武漢から世界中に広がり、2020年3月11日には世界保健機構によりパンデミックが宣言された [91]。日本においては2020年1月に国内で初の感染者が確認されて以降感染者数は増加しつづけて2021年9月現在では第5波の渦中であり、さらなる感染拡大を防ぐため新しい生活様式の徹底が求められている [92,93]。

COVID-19の感染は散発的に発生する場合より、クラスターでの感染拡大が問題となっている [94]。特にクラスターは屋内で発生しやすいことが多数報告されている [95]。外食産業においては、これまで飲食を伴う施設においてクラスターが複数確認されていることから、2021年9月現在までに4度の緊急事態宣言により飲食店の

営業時間の制限や酒類の提供禁止措置などを執ることで感染拡大を防いでいる [96]. このような措置は世界各地でも見られその効果も期待できるが [97,98], 外食産業への経済的ダメージも深刻である [99,100].

緊急事態宣言解除後の営業においては, 経済活動を再び制限しないよう感染リスクを低下させるような感染予防対策が重要になる. 例えば外食業の事業継続のためのガイドライン [101] では, 衛生管理や店内の消毒, 従業員の健康観察, 物理的距離の確保などの感染予防対策が提示されている. 特に物理的距離の確保については, Chu *et al.* [102] により感染リスクを低下させる効果があることが報告されている. 一方, むやみに距離を取らせるばかりでは店舗の収容能力を低下させ収益を出せなくなってしまう.

収益の最大化や店舗運用の効率化を目的とした飲食店の運用手法はこれまで多くの研究で検討されている [103–105]. しかし, 感染症が蔓延した現在のような社会では収益を追求するだけでなく, 感染リスクの抑制も考慮して飲食店の運用を行わなければならない.

COVID-19の感染リスク削減を目的として, 施設内の物理的距離を確保しつつ, 施設の収容能力を確保する座席レイアウトを効率的に探す手法は国内外で検討されている. Banon *et al.* [106] は飲食店や教室, 劇場, 輸送媒体の室内などにおいて, 最低限の物理的距離を保ちつつ施設の収容能力を最大化する座席配置を行う手法を提案している. Salari *et al.* [107] は航空機を対象に乗客同士の距離や座席と通路との距離に着目した配置モデルを提案している. 小平 [108] は与えられた空間にできるだけ多くの座席を配置する手法に加え, すでに座席の配置が与えられている場合にはできるだけ長い物理的距離を確保する座席配置を求める手法を提案している.

これらの研究のように物理的距離を考慮した座席の初期レイアウトを検討することは重要であるが, さらなる感染リスク低下の効果を期待するには, 営業時間内における適切な座席割当が求められる. 小さな収益損失で適切な物理的距離を確保するには, 刻々と変わる混雑状況などに合わせて適切に座席の割り当てを行うことが望ましいが, 現実的には人間が手動で様々な制約を考慮しつつ割り当てることは難しい. そのため, 現実の飲食店ではあらかじめ静的な座席表を作成し, 着席可能な座席を顧客に選択させる方法が取られていることが多いように思われる. 感染症が蔓延しているような社会情勢では, 店舗の混雑状況に応じた動的な座席割当手法が求められる.

このような理由から, 本章では感染リスクの増加を抑制し収益を減少させない数理的な座席割当モデルを提案する. 具体的には, 飲食店を対象に感染リスクを店舗

の状況に応じて適切に抑制することが可能となる。提案モデルは感染リスクを抑制するだけでなく、感染リスクと収益の調整を単一のパラメータにより行う。また、従来の手法のように静的に着席可能な座席を与えるのではなく、ガイドラインで推奨されている条件を満すような座席割当を店舗の状況に応じて動的に決定するモデルを設計する。

提案モデルの有効性を示すため、仮想の飲食店を対象にシミュレーションを行う。このシミュレーションでは提案したモデルによる座席の割り当てが、システムや人間が顧客誘導に介入しない座席割当手法に比べて店舗の営業開始から終了までの累積感染リスクの増加を効果的に抑えることができることを示す。また、店舗運営者が調整可能なパラメータにより、店舗の収益損失を抑えつつ累積感染リスクを削減できることを示す。

5.2 飲食店における感染リスク

本研究で提案するモデルでは、顧客の到着ごとに店舗全体の営業終了時点における感染リスクを抑えるような座席の配置を決定する。このとき、感染リスクをどのように定義するかによって良い座席の割り当て方は大きく変わる。Chu *et al.* は COVID-19 の人同士の相対的な感染リスクは距離が 1[m] 離れるごとに約 1/2 に低下すると報告している [102]。そこで本研究では、まず顧客同士の距離が 1[m] のときそれぞれが受ける感染リスクを 1 とする。なお、ここで定義する感染リスクは確率をあらわすものではなく、顧客同士の距離に対する相対的な感染リスクである点に注意する。さらに、座席番号を要素とする集合 N の要素 i, j 間の距離を d_{ij} [m] としたとき、 i に着席した顧客が j から受ける感染リスクを

$$r_{ij} = \begin{cases} 1/2^{d_{ij}-1} & , d_{ij} > 0, \\ 0 & , d_{ij} = 0, \end{cases}$$

とする。なお、 $d_{ij} = 0$ のとき $i = j$ であり、各座席には 1 人しか座れないものとする。ある時間における店舗全体の感染リスクを、店内にいる全ての顧客が持つ感染リスクの総和とみなし、次のように定義する。

$$R_t = \sum_{i,j \in N} r_{ij} x_i^t x_j^t, \forall t \in T. \quad (5.1)$$

なお、 T は時間ステップ $t \in \mathbb{N}$ を要素とする集合である。また、

$$x_i^t = \begin{cases} 1: \text{顧客が時間ステップ } t \text{ に座席 } i \text{ を利用する,} \\ 0: \text{その他,} \end{cases}$$

である。Eq. 5.1 で表される感染リスク R_t は、時間ステップ t において店内にいる顧客の位置関係によって得られる。

一方、感染リスクは人同士が同じ空間にいる時間が長ければ長いほど被感染リスクが二次関数的に増加することが Hu *et al.* により示唆されている [109]。つまり、単純に R_t の時間についての総和を店舗全体の営業終了時点における累積感染リスクとすることは適切ではない。すなわち、営業開始から終了までの累積感染リスクを評価する場合には時間効果を考慮する必要がある。そこで時間効果を考慮した累積感染リスクを時間に対して二次関数的に増加すると仮定し、

$$R = \sum_{t \in T} \sum_{i, j \in \mathbb{N}} (b_{ij}^t)^2 r_{ij}, \quad (5.2)$$

と定義する。なお、定数 b_{ij}^t は時間ステップ t において、座席 i, j に着席する客が共有している時間ステップ数を表す。すなわち、

$$b_{ij}^t = x_i^t x_j^t \sum_{\tau_{ij}^t \leq \tau \leq t} x_i^\tau x_j^\tau,$$

である。ここで τ_{ij}^t は時間ステップ t において座席 i, j に着席する顧客のペアが同時に座り始めた時間ステップである。すなわち $y_{ij}^\tau = x_i^\tau x_j^\tau$ として、時間ステップ $t-1$ までに座席 i, j に着席していた顧客が同時に座り始めた時間ステップの集合を

$$T_{ij}^t = \{\tau \in T \mid y_{ij}^\tau = 1, y_{ij}^{\tau-1} = 0, 1 < \tau < t\},$$

としたとき、

$$\tau_{ij}^t = \begin{cases} \max T_{ij}^t & , T_{ij}^t \neq \emptyset \\ t & , T_{ij}^t = \emptyset \end{cases}$$

と定まる。これにより、定数 b_{ij}^t は顧客の入れ替わりを考慮した顧客同士が共有する時間ステップ数に対する重みとみなすことができる。累積感染リスク R は営業時間

が終了してから計算されることから、店舗の運用方法を評価するための指標とみなせる。

本来であれば累積感染リスク R を最小化するような戦略が好ましいが、個々の顧客がどれだけの時間座席を占有するかは未知であることから、 R を直接最小化することは難しい。そのため、ある顧客を座席 i に誘導する場合には、座席 i でその顧客が着席済みの顧客から受ける次の感染リスクの最大値

$$r_{\max} = \max_{j \in N_{\text{occupied}}} r_{ij}, \quad (5.3)$$

が最小となるような座席を選択することが好ましい。ここで、 N_{occupied} は顧客がすでに着席している座席番号を要素とする集合である。これにより、たとえ顧客同士の共有する時間が長くなったとしても累積感染リスク R を効果的に抑制できる可能性がある。

なお、 r_{\max} が最小となるような座席候補が複数存在する場合、着席済みの顧客との位置関係により R_t はどの座席候補でも同一とは限らない。そこで、このような場合には R_t が最も小さくなる座席を候補の中から選択することで、店舗全体の感染リスクの増加を抑制させることが可能となる。

5.3 感染リスクの増加を抑える座席割当モデル

5.3.1 感染リスクを抑制するパラメータ θ

5.3.1.1 パラメータ θ の概要

本研究で提案する座席割当モデル（以下、提案モデル）において、店舗の感染リスク R_t は単一のパラメータにより調整される。ここで感染リスクを抑制するパラメータを $\theta \in [0, 1]$ とする。パラメータ θ を感染リスク R_t の閾値とみなし、各時間ステップで閾値を超えないような座席配置を探すことで感染リスクを抑制する。なお、感染リスク R_t が距離から算出される全顧客が持つ感染リスクの総和であるが、パラメータ θ に合わせるため正規化した感染リスク \tilde{R}_t を

$$\tilde{R}_t = \frac{\sum_{i,j \in N} r_{ij} x_i^t x_j^t}{f_{\text{worst}}^*}, \quad \forall t \in T, \quad (5.4)$$

として、パラメータ θ との比較に用いる。 f_{worst}^* は運用する店舗における最悪感染リスクであり、対象店舗において利用客数が最大容量に達している、かつ全顧客の感染リスクの総和が最大となる値と定義する。このことから、 $\theta = 1$ のとき感染リスク

に対する制約は存在しないことと同義であることがわかる。

なお、パラメータ θ は時間ステップ t における感染リスク R_t を抑制する値であり、営業終了後に計算される累積感染リスク R を直接制限するものではない点に注意する。

5.3.1.2 最悪感染リスクの算出

店舗における最悪感染リスク f_{worst}^* は利用客数が店舗の最大容量となっていれば常に同じとは限らない。最大容量に達していても顧客の位置関係によって感染リスクの大きさは変わるため、単純に最悪感染リスクを求めることは難しい。そこで最悪感染リスクを求める問題を、感染リスクを最大化する顧客の位置関係を決定する最適化問題 P_{worst} として定式化する。この最適化問題 P_{worst} は座席間の距離をペナルティとみなし、そのペナルティを最小化する 0-1 整数計画問題とみなすことができる。筆者らは同様の問題を教育機関における時間割編成問題に応用し、その有用性を確認している [31]。 P_{worst} は 0-1 整数計画問題とみなすことができ、次のように定式化される。

$$P_{\text{worst}} : \text{Maximize } f_{\text{worst}} = \sum_{i \in N} \sum_{j \in N} r_{ij} x_i x_j, \quad (5.5)$$

$$\text{subject to } x_i + x_j \leq 1, \quad \forall (i, j) \in E, \quad (5.6)$$

$$x_i \in \{0, 1\}, \quad \forall i \in N.$$

ここで、 x_i は決定変数であり、次のように定義する。

$$x_i = \begin{cases} 1: \text{顧客が座席 } i \text{ を利用している,} \\ 0: \text{その他.} \end{cases}$$

さらに、集合 E は同時に利用することのできない二つの座席 (i, j) を要素とする集合であり、次のように定義する。

$$E = \{(i, j) \mid \text{座席 } i \text{ と } j \text{ は同時に利用できない}\}.$$

また、 P_{worst} の最適値を f_{worst}^* とする。

目的関数 (Eq. 5.5) は感染リスク最大化を意味しており、制約式 (Eq. 5.6) は座席 i と j が同時使用禁止のとき、どちらかにしか顧客を配置できないことを意味している。なお、Eq. 5.5 は見やすさを優先しバイナリ変数同士の積をそのまま表現してい

る。このままだと目的関数 (Eq. 5.5) は非線形であるが、中間変数 y_{ij} を用いて

$$y_{ij} - x_i - x_j \geq -1, \quad \forall i, j \in N, \quad (5.7)$$

$$x_i - y_{ij} \geq 0, \quad \forall i, j \in N, \quad (5.8)$$

$$x_j - y_{ij} \geq 0, \quad \forall i, j \in N, \quad (5.9)$$

$$y_{ij} \in \{0, 1\}, \quad \forall i, j \in N, \quad (5.10)$$

とすることで線形化可能である。実際の計算には Eqs. 5.7–5.10 を用いている。

5.3.2 座席割当手法

5.3.2.1 提案モデル

ここまでに定義した感染リスクや各種パラメータを用いて、営業終了時の店舗全体の感染リスクを抑制するための座席割当アルゴリズムについて説明する。顧客の座席誘導は空席である座席集合 $N_{\text{empty}} \subseteq N$ の中から、誘導される顧客が受ける最大の感染リスク r_{max} が最小になるような座席に着席させることが好ましい。つまり顧客の配置は、すでに店内にいる顧客と新たに配置する顧客との最小距離が最大になるように決定すればよい。そうすることで、たとえ顧客同士が共有する時間が長くなったとしても、累積感染リスク R を効果的に抑制できる可能性がある。このとき、 r_{max} が最小になるような座席が複数存在する場合には感染リスク \tilde{R}_t が小さくなる座席を選択する。なお、たとえ最大感染リスクが最小になるとしても、配置した際に得られる感染リスク \tilde{R}_t が、店舗が設定するパラメータ θ を超えている場合には配置してはいけない。これにより、提案モデルは累積感染リスク R を抑制しつつ、単一のパラメータ θ により感染リスクと収益の調整を行うことができる。

これらの条件を満たす座席割当アルゴリズムを Algorithm 1 に示す。なお、入力と出力における $\mathbf{x}^t \in \{0, 1\}^n$ は時間ステップ t における変数 $x_i^t, \forall i \in N$ を要素とするベクトルであり、 $n = |N|$ とする。

Algorithm 1 提案モデルにおける座席割当アルゴリズム

Require: $\mathbf{x}^{t-1} \in \{0, 1\}^n$: 1ステップ前の着席配置, m : 到着人数, f_{worst}^* : 最悪感染リスク, N : 座席集合, θ : 感染リスクの閾値

Ensure: $\mathbf{x}^t \in \{0, 1\}^n$: 顧客投入後の着席配置, c : 配置できた人数

function CALC_RISK(i, \mathbf{x})

$x_i \leftarrow 1$

return $\sum_{k,l \in N} r_{kl} x_k x_l$

end function

Initialization :

$c \leftarrow 0$ # カウンタ

$N_{\text{occupied}} \leftarrow \{i \in N | x_i^{t-1} = 1\}$

$N_{\text{empty}} \leftarrow N \setminus N_{\text{occupied}}$

$\mathbf{x}^t \leftarrow \mathbf{x}^{t-1}$

LOOP Process

while $c < m$ **do**

$r_{\text{minmax}} \leftarrow \infty$ # 最大感染リスクの最小値

$s \leftarrow -1$ # 最大感染リスクが最小になる座席番号

$R'_t \leftarrow \infty$

for $i \in N_{\text{empty}}$ **do**

$\text{risk}_i \leftarrow \text{CALC_RISK}(i, \mathbf{x}^t)$ # 感染リスクの算出

$r_{\text{max}} \leftarrow \max_{j \in N_{\text{occupied}}, (i,j) \notin E} r_{ij}$

if $r_{\text{max}} < r_{\text{minmax}}$ **then**

$r_{\text{minmax}} \leftarrow r_{\text{max}}$

$s \leftarrow i$

$R'_t \leftarrow \text{risk}_i$

else if $r_{\text{max}} = r_{\text{minmax}}$ & $\text{risk}_i < R'_t$ **then**

$s \leftarrow i$

$R'_t \leftarrow \text{risk}_i$

end if

end for

$R_t \leftarrow \text{CALC_RISK}(s, \mathbf{x}^t)$

$\tilde{R}_t = R_t / f_{\text{worst}}^*$

if $\tilde{R}_t \leq \theta$ & $s > -1$ **then**

$x_s^t \leftarrow 1$

else

break

end if

$N_{\text{occupied}} \leftarrow N_{\text{occupied}} \cup \{s\}$

$N_{\text{empty}} \leftarrow N_{\text{empty}} \setminus \{s\}$

$c++$

end while

5.3.2.2 顧客誘導に人間の意思決定が介在しないモデル

ここでは提案モデルを評価するために、対立手法として座席の割り当てに人間やシステムが介在しないモデル（以下、介在なしモデル）における座席割当アルゴリズムを用意する。日本フードサービス協会によるガイドラインによると、店内における顧客同士の位置関係においては、できるだけ1[m]以上の間隔を空ける、適度なスペースを空ける、斜めでの着席、真正面は避ける等といった工夫を施すことが推奨されている [101]。現実の飲食店においては、このガイドラインに従いあらかじめ着席できない席を決め、それらの席にその旨を記載した紙を貼っておくという対策を取ることが多いと思われる。顧客はそのように決められた着席可能な座席の集合 N_{empty} の中から自由に席を選んでいるのが現状である。

介在なしモデルは、あらかじめガイドラインに従った座席表を生成し、着席可能な座席の中から一様乱数に基づいて選ばれた座席に顧客を着席させる、という単純なアルゴリズムにする。このとき、新規顧客はあえてすでに着席している顧客の近くに座らないことが予想される。そこで着席済みの顧客からの距離が顧客が心理的に確保したい距離 h [m] より大きい座席集合 $N_h \subseteq N_{\text{empty}}$ を生成し、 $N_h = \emptyset$ とならない限り新規顧客は N_h から座席を選択するものと仮定する。 $N_h = \emptyset$ となった場合、距離 h を1[m] ずつ小さくしていき $h = 1$ [m] となるか $N_h \neq \emptyset$ となるまで N_h の計算と判定を繰り返す。それでもなお $N_h = \emptyset$ となる場合、新規顧客は着席済みの顧客との距離が1[m] 以内だったとしても、 N_{empty} から選択した座席を選択するものとする。具体的なアルゴリズムを Algorithm 2 に示す。

Algorithm 2 介在なしモデルにおける座席割当アルゴリズム

Require: $\mathbf{x}^{t-1} \in \{0, 1\}^n$: 1 ステップ前の着席配置, m : 到着人数, h : 確保すべき距離 [m], N : 座席集合

Ensure: $\mathbf{x}^t \in \{0, 1\}^n$: 顧客投入後の着席配置, c : 配置できた人数

Initialization :

$c \leftarrow 0$ # カウンタ

$N_{\text{occupied}} \leftarrow \{i \in N | x_i^{t-1} = 1\}$

$N_{\text{empty}} \leftarrow N \setminus N_{\text{occupied}}$

$\mathbf{x}^t \leftarrow \mathbf{x}^{t-1}$

LOOP Process

while $c < m$ **do**

if $N_{\text{empty}} = \emptyset$ **then**

 break

end if

$N_h = \emptyset$

$h' = h$

while $h' > 1 \mid N_h = \emptyset$ **do**

for $i \in N_{\text{empty}}$ **do**

 # 座席 i から距離 h' 以内で着席済みの座席集合

$L = \{j \in N | r_{ij} \geq 1/2^{h'-1}, x_j^t = 1, i \neq j\}$

 # 集合 L が空集合であれば座席 i から
 距離 h' 以内に顧客はいない

if $L = \emptyset$ **then**

$N_h \leftarrow N_h \cup \{i\}$

end if

end for

$h' --$

end while

if $N_h \neq \emptyset$ **then**

$s \leftarrow \text{random}(N_h)$

else

$s \leftarrow \text{random}(N_{\text{empty}})$

end if

$x_s^t \leftarrow 1$

$N_{\text{occupied}} \leftarrow N_{\text{occupied}} \cup \{s\}$

$N_{\text{empty}} \leftarrow N_{\text{empty}} \setminus \{s\}$

$c++$

end while

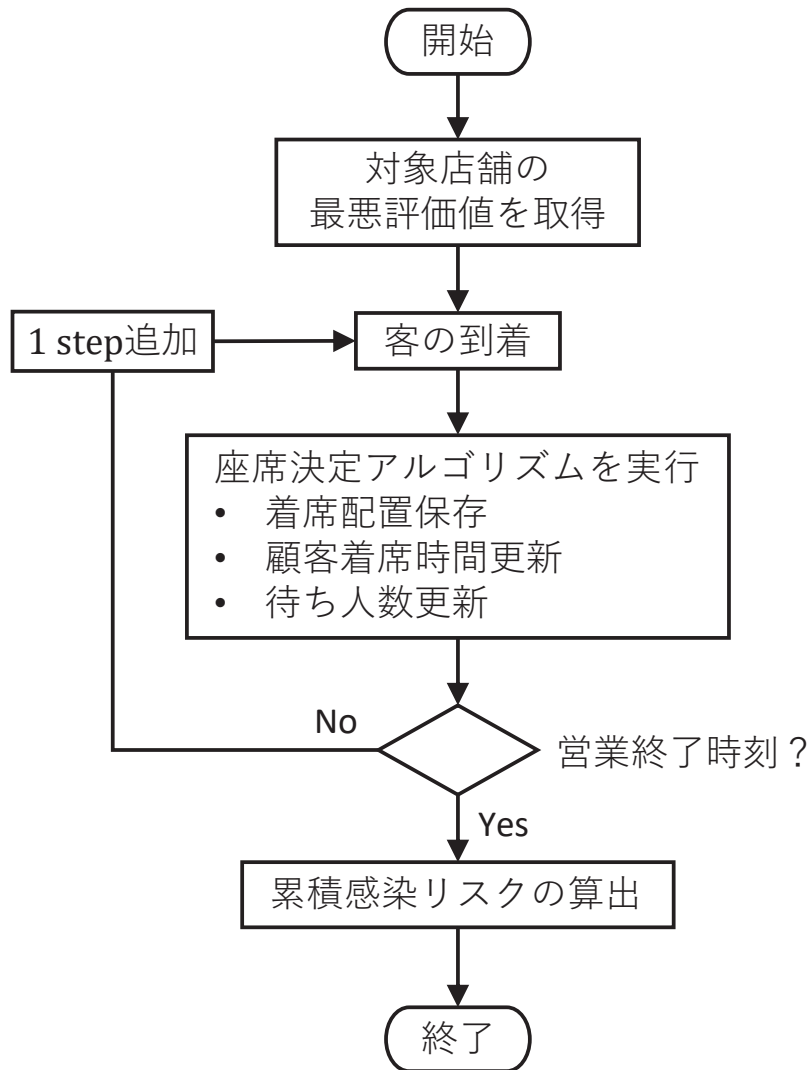


Fig. 5.1: Flowchart of the proposed model

5.3.3 提案モデルのフローチャート

までに提案した手法の流れを整理するため提案モデルのシミュレーションに関するフローチャートを Fig. 5.1 にまとめる。一連の流れは営業開始時刻から終了時刻までとし1ステップあたりの時間幅は任意であり、営業終了時刻の判定後条件に当てはまる場合に時間が進められる。なお、ここではシミュレーションを前提とした説明のため顧客の到着から営業終了判定までを1ステップとしているが、実際の店舗運営では顧客の投入ごとにフローが進む点に注意する。店舗運営前にはその店舗における問題 P_{worst} を解くことによって最悪感染リスク f_{worst}^* を算出する。1ステップでの流れについて説明する。まずステップ開始時点で到着済みの顧客を店舗に投入




Fig. 5.2: Seating chart on the virtual restaurant

し, Algorithm 1 によって座席配置を決定し, 各顧客の着席時間を更新する. また制約により配置できなかった顧客を待ち人数に加える. このとき得られた時間ステップ t における座席配置 \mathbf{x}^t と顧客同士が共有している時間ステップ数 $b_{ij}^t, \forall i, j \in N$ は累積感染リスク R の算出に必要なため, 保存する. 1ステップ終了後, 営業終了時刻に達している場合シミュレーションを終了し, そうでなければ1ステップ追加し一連の流れを繰り返す.

なお, 介在なしモデルは Fig. 5.1 における“対象店舗の最悪評価値の取得”を除いたフローチャートに従う.

5.4 数値実験

5.4.1 実験の目的と概要

ここでは仮想の飲食店を対象に提案モデルと介在なし割当モデルをそれぞれ適用し, 1日の営業をシミュレーションする. 両モデルを累積感染リスク R と利用者数を用いて定量的に評価する.

実験に用いる仮想の飲食店における座席表を Fig. 5.2 に示す. 空白のマスがそれぞれ座席となっており, 隣接する4座席を1ボックスとしてボックス数は16, 座席数は64である. 縦軸横軸の単位は1[m]とする.

提案モデルにおいて着席可能な座席の位置関係には, 外食産業におけるガイドラ




Fig. 5.3: Static seating chart used on non-interventional model

イン [101] を参考に必ず $1[m]$ を超える間隔を取るような制約を与える。この制約を Fig. 5.2 の座席表に適用すると隣および正面での着席は許可されず、同じボックスにおいては対角状にしか座れない。また、同時帯に着席できる人数は1ボックスあたり2人であり、店舗内では32人が最大容量となる。介在なしモデルでも同様の条件で静的な着席表を与えるが、静的に与える場合最大容量時には最も理想的な形で着席表を作成することが自然である。そのため、介在なしモデルにおける静的な着席表は Fig. 5.3 のように与える。なお、Fig. 5.3 において、黒く塗りつぶされたマスが着席可能な席である。また、提案モデルにおいては各時間帯における店舗内の状況に応じて、動的に着席させる席を決定するため (Algorithm 1)、店舗の利用者数が最大容量に達した場合必ずしも Fig. 5.3 のような着席表になるとは限らない。

ここからは実験の諸条件について説明する。シミュレーションは1ステップを15分として10時間 (40ステップ) 行う。1ステップごとに到着する顧客数 m は一定とする。なお、感染リスクは混雑状況により大きく変動することから、1ステップごとに到着する顧客数 m を数パターン用意して、シミュレーションを行う。具体的には1ステップごとに到着する顧客数に対して $m = 1, \dots, 8$ の8パターンを用意し、それぞれシミュレーションを行う。1人あたりが店舗を利用する時間もすべて一定とし、本実験では利用時間を60分 (4ステップ) と定める。

パラメータ θ の感度を検証するため、提案モデルでは感染リスクを抑制するパラ

メータ θ を0.05刻みで変動させる。なお、パラメータ θ の感度検証においては、介在なしモデルにおける着席済みの顧客との任意の距離を $h = 2[\text{m}]$ とする。Fig. 5.3の座席表において、着席済みの顧客と2[m]を超えた距離を取ることは、同一ボックス内に座らないことと同義である。また、介在なしモデルでは座席の配置を一定の制約の下でランダムに決定するため、シードを変更して同条件のシミュレーションを100回行い、評価値はその平均値を用いる。なお、試行回数は1度のシミュレーションにかかる時間や検証すべきパラメータの組み合わせ数を鑑み、一つのパラメータの組み合わせあたり100回とした。以後介在なしモデルにおいて累積感染リスクという場合、100回の平均値であることに注意する。パラメータ θ の感度検証のためのシミュレーションは、介在なしモデルでは到着人数を変動させ各到着人数で100回行うため $8 \times 100 = 800$ 回、提案モデルでは到着人数とパラメータ θ をそれぞれ変動させるため $8 \times 20 = 160$ 回行われる。

介在なしモデルは着席済みの顧客と確保したい距離 h の値によってその性能が大きく変化する可能性がある。そこで距離 h について、 $h = 1, 2, 3$ として値を変動させ、提案モデルと性能を比較する。なお、対象とする空間の仕様上 $h > 3$ は意味を持たない。また、パラメータ θ の感度検証と同様にそれぞれシードを変更して100回のシミュレーションを行いその平均値を評価値とする。

最後に提案したモデルが直感的に正しいか定性的に検証するため、店舗内の座席使用状況を時系列で描画し観察する。

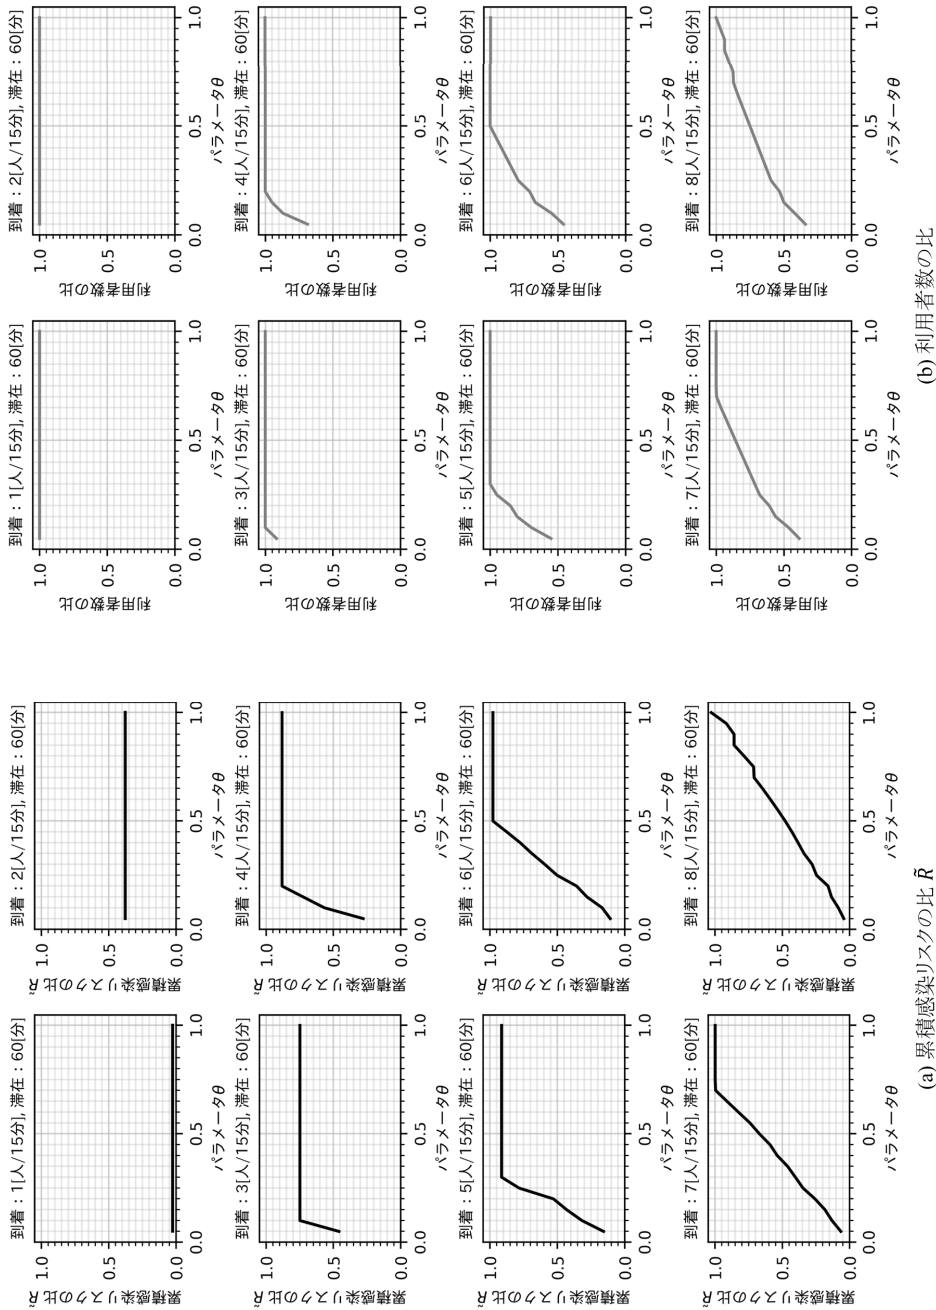


Fig. 5.4: Transition of cumulative infection risk ratio and the number of users ratio by parameter θ

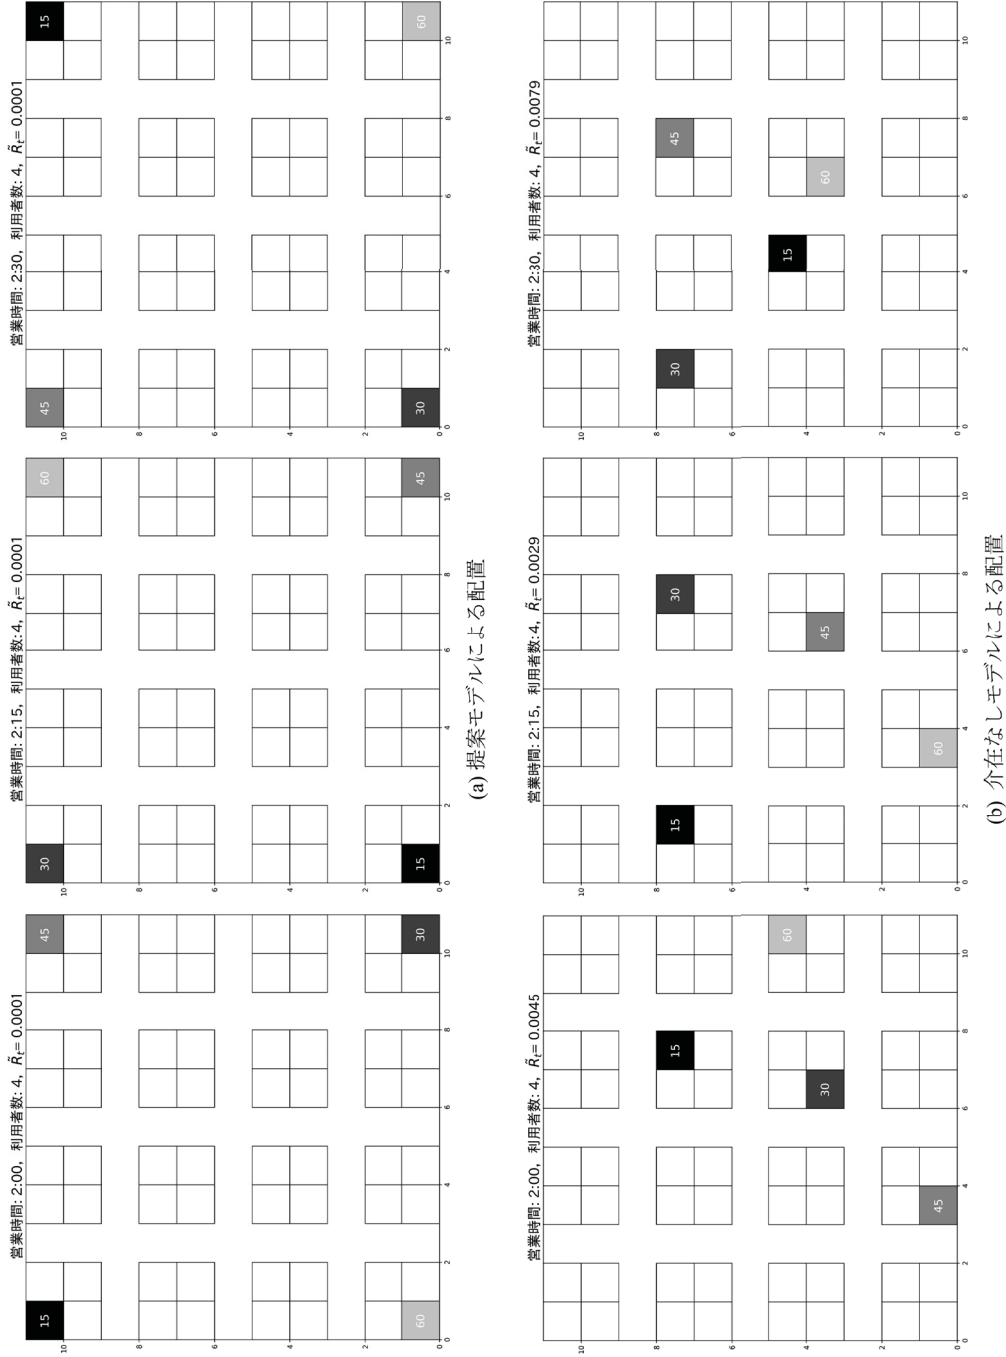


Fig. 5.5: Comparison of simulation by (a) proposed model and (b) non-interventional model if one customer arrivals for a step (parameter $\theta = 1.00$ and extracted results until two steps elapsed from 2:00)

Table 5.1: Standard deviation σ of cumulative infection risk ratio obtained by the non-interventional model (100 trials)

到着人数	1	2	3	4	5	6	7	8
$h = 1$	0.193	0.090	0.047	0.038	0.024	0.016	0.010	0.002
$h = 2$	0.174	0.082	0.037	0.035	0.023	0.014	0.010	0.001
$h = 3$	0.115	0.062	0.035	0.029	0.021	0.016	0.009	0.001

5.4.2 結果と考察

得られた結果を Fig. 5.4 に示す. Fig. 5.4-(a) は横軸にパラメータ θ , 縦軸に累積感染リスクを取ったグラフを到着人数ごとに描画している. なお, ここで示す \tilde{R} は介在なしモデルの評価値を 1 として算出した, 介在なしモデルと提案モデルとの累積感染リスクの比である. 黒線は各パラメータ θ における累積感染リスクの比を示す. Fig. 5.4-(b) は (a) における縦軸を利用者数の比に置き換えたものである. 介在なしモデルの 100 回のシミュレーションにおける累積感染リスクの平均を 1 としたときの標準偏差 σ は Table 5.1 の通りである.

Fig. 5.4(a)(b) どちらも介在なしモデルにより得られた結果を 1 としていることから, 提案モデルの値は相対的な累積感染リスク削減効果および店舗利用率を示していることがわかる. 例えば提案モデルの累積感染リスクが 0.8 であれば介在なしモデルに比べてリスクが 0.8 倍であることを示す. なお, 各グラフではパラメータ θ ごとにシミュレーションを行っており, 累積感染リスクの比 \tilde{R} はシミュレーション終了後に計算される点に注意する. また, パラメータ θ は時間ステップ t における感染リスク \tilde{R}_t を制限する指標であり, Fig. 5.4-(a) における累積感染リスク R を直接制限するものではないことにも注意する.

到着人数が 1 ステップあたり 1 人のとき, 提案モデルにおける累積感染リスクはパラメータの値にかかわらず介在なしモデルに比べて約 0.03 倍であった. Fig. 5.5 に示した図は到着人数 1 ステップあたり 1 人として得られた営業開始後 2:00 から 2:30 までの提案モデルと介在なしモデルのシミュレーション結果の一例である. なお, 提案モデルにおいて $\theta = 1.00$ である. 座席の着席状況はマスの色で示しており, 新規顧客を黒で表し, 色の濃さで滞在時間を表している. また, マス内の数字は滞在時間を表しており, 例えば “30” であれば 30 分滞在していることを示している. なお, Fig. 5.5-(b) は介在なしモデルを 100 回シミュレーションしたうちの一例であることに注意する. Fig. 5.5 から提案モデルでは新規顧客の最大感染リスクを最小

化することにより、介在なしモデルに比べて大幅に感染リスク R_t を抑制していることがわかる。一方、利用者数はパラメータの値にかかわらず提案モデルと介在なしモデルで一致している。つまり、提案モデルは到着人数が1ステップあたり1人のとき、利用者数を低下させることなく累積感染リスクを約0.03倍にすることが確認できた。なお、パラメータ θ の値が累積感染リスクおよび利用者数に影響しないのは、店舗の利用人数が少なすぎるために常に十分低い感染リスク \tilde{R}_t を保てたためである。到着人数が1ステップあたり2人の場合も同様の傾向がみられた。

到着人数が1ステップあたり3人の場合、パラメータ θ が0.10–1.00の間では利用者数を低下させることなく累積感染リスクを介在なしモデルの約0.75倍にすることができている一方、 $\theta = 0.05$ では利用者数が介在なしモデルの約0.92倍に低下している。これは、 $\theta = 0.05$ では要求される感染リスク \tilde{R}_t の上限が極端に小さくなり、利用者数を絞ることによって感染リスク \tilde{R}_t を低下させることで制約を満たしているためである。1ステップあたりの到着人数が3人以上の場合では同様の傾向が確認でき、到着人数が大きくなるほど累積感染リスクと利用者数に対するパラメータ θ の感度が高くなっている。これは到着人数が多くなるごとに店内の感染リスク \tilde{R}_t が増加していくため、パラメータ θ の影響を受けやすくなっているためである。このことから提案モデルではパラメータ θ により、適切に店舗全体の累積感染リスクを抑制できていることが確認できた。

さらに、Table 5.1 より、パラメータ θ の全ての範囲において、提案モデルの累積感染リスクが到着人数が1ステップあたり5人までの場合には介在なしモデルの累積感染リスク $R - 3\sigma$ 以下、6人の場合には $R - \sigma$ 以下、7人の場合には R 以下となっていることが確認できた。一方、Fig. 5.4-(a) から到着人数が1ステップあたり8人の場合では、 $\theta = 1.00$ のとき、提案モデルの累積感染リスクが介在なしモデルをわずかに上回っていることがわかる。これは、1ステップあたり8人では、ある時間から常に利用客数が最大容量に達しており、介在なしモデルでは最大容量状態の中で一番感染リスク \tilde{R}_t が小さくなる座席表を用いているためである。すなわち、提案モデルは店内に空席があるような状況では大きな効果が期待できる一方、常に最大容量に達している状態ではあまり有効でないことがわかる。ただし、常に最大容量に達する状況ではそもそも解の選択肢がほぼないため、そのような場合において提案モデルが有効でない事は大きな問題ではないと考えられる。

Fig. 5.4 より、いかなる到着人数でも累積感染リスクの低下に比べて利用者数の低下が緩やかになっていることわかる。このことから提案モデルを導入することで、店舗の収益減少を抑えつつ感染リスクの削減効果が期待できることが確認できた。




Fig. 5.6: An instance of restaurant operation with the proposed model ($\theta = 0.40$, arrivals by one step: 6, extracted until 6 steps)




Fig. 5.7: An instance of restaurant operation with the non-interventional model (arrivals by one step: 6, extracted until 6 steps)

Fig. 5.6, 5.7 は座席配置を定性的に評価するため、それぞれ提案モデルと介在なしモデルによるシミュレーション結果の一例を示したものである。それぞれ1ステップあたりの到着人数を6人とし、営業開始から6ステップ分を可視化している。提案モデルによる結果ではパラメータ $\theta = 0.40$ としている。マスの色や数字の意味は Fig. 5.5 と同様である。また、Fig. 5.7 は Fig. 5.5-(b) と同様、介在なしモデルを100回シミュレーションしたうちの一例であることを注意する。

Fig. 5.6 に示した提案モデルによる配置結果において、シミュレーション開始直後を見ると、各顧客の間隔を広くとっており感染リスク \tilde{R}_i の増加を抑えていることが確認できる。店内が混み始めてからも可能な限り同じボックスには着席させないように新規顧客の座席を決定していることが見て取れる。感染リスク \tilde{R}_i は全時間帯で設定したパラメータ $\theta = 0.40$ を下回っており、適切に感染リスクをコントロールしている。Fig. 5.7 に示した介在なしモデルによる結果ではパラメータ θ による感染リスク抑制の効果がないため、感染リスク \tilde{R}_i が $\theta = 0.40$ を上回っても顧客数を制限していないことが見て取れる。また、提案モデルはパラメータ θ による顧客数の制限が行われていない営業時間 0:00–0:45 においても、提案モデルで得られた配置結果における感染リスク \tilde{R}_i が常に介在なしモデルを下回っていることが確認できる。

ここで Table 5.2 にパラメータ $\theta = 1.00$ における提案モデルと顧客が確保したい距離 h を変化させた場合の介在なしモデルとの累積感染リスクの比 \tilde{R} を示す。Table 5.2 はパラメータ h が十分大きくても、提案モデルの性能が介在なしモデルより良いか、同程度であることを示している。また、Table 5.1 より、すべての距離 h について、提案モデルの累積感染リスクが到着人数が5人までの場合介在なしモデルの累積感染リスク $R - 3\sigma$ 以下、6人の場合 $R - \sigma$ 以下、7人の場合 R 以下となっていることが確認できた。これは、たとえ顧客が他の顧客との距離を最大限確保したいという心理が働いたとしても、提案モデルにより座席誘導を行った方が店舗全体の感染リスクを抑制できる可能性があることを示している。この傾向は $\theta = 0.05-0.95$ においても確認された。なお、 $h = 1, 3$ においても $h = 2$ の場合と同様に、到着人数が1ステップあたり8人の場合で提案モデルの累積感染リスクが介在なしモデルに比べて高くなる傾向が確認されたが、先に述べたように実用上大きな問題ではないと考えられる。

ここまで述べたすべての傾向は1ステップあたり到着人数8人かつ $\theta = 1.00$ を除くすべてのシミュレーションで確認することができた。このことから提案モデルは飲食店における感染リスクを低下させる手法として有効であり、パラメータ θ によって感染リスクと収益を調整できることが示された。

Table 5.2: Ratio of outputs obtained by the proposed model with parameter $\theta = 1.00$ and the non-interventional model by distance parameter h

到着人数	1	2	3	4	5	6	7	8
$h = 1$	0.021	0.298	0.608	0.746	0.868	0.958	0.995	1.023
$h = 2$	0.026	0.377	0.748	0.880	0.913	0.977	0.997	1.026
$h = 3$	0.057	0.690	0.856	0.912	0.921	0.980	1.000	1.027

5.5 結言

本研究では COVID-19 が蔓延している社会において、飲食を伴う施設を想定し店舗の状況に合わせてユーザが単一のパラメータで感染リスクと収益を調整できる座席割当モデルを提案した。数値実験では提案したモデルを仮定の飲食店に適用し、パラメータ θ を調整することで収益減少を抑えつつ効果的に感染リスクを抑制することが確認できた。さらに、パラメータ $\theta = 1.00$ においては、常に店内の利用客数が最大容量となるような場合を除いて、提案したモデルは介在なしモデルと同じ利用者数で感染リスクのみ減少させることが Fig. 5.4 より確認された。また、介在なしモデルにおける心理的に確保したい距離 h を十分大きくしても、提案モデルの方が感染リスクを効果的に抑制することが確認できた。

本章では飲食店舗という大規模空間内に点在する小規模空間をシミュレーション対象としている。現実の飲食店舗では多くの場合顧客の配置に不確実性が内在するが、提案したアルゴリズムにより顧客の行動を制御することで不確実性は排除できる。すなわち提案したアルゴリズムを大規模空間内に組み込むことができれば、社会シミュレーションに対する不確実性を増大させることなく、複雑性を向上させることが可能となる。

6 大規模空間に対する小規模シミュレータ導入のための地域分類

第5章で提案した小規模空間に対する決定論的アプローチによるシミュレータは不確実性の影響を排除しており、大規模空間への導入が期待できる。そこで、小規模シミュレータを大規模空間に導入するための地域分類手法を調査し、その有効性を検証する。

6.1 緒言

2019年12月以降、新型コロナウイルス感染症の流行により人々の生活様式や行動形態は大きく変化した。2021年現在、日本においてはこれまで4回の緊急事態宣言により、人々の行動を制限してきた[96]。また、感染予防対策のために人々が集まりやすい、いわゆる密な環境をなるべく避けることが政府により推奨されている[93]。一方、駅や公共機関、商業施設によっては十分な周知や対策が行われていないために密になってしまう可能性がある。そのため、密になりやすく感染イベントが起きやすいことやその度合いがあらかじめ判明していれば、その施設においてどのような感染予防対策をどの程度行えばいいかを見積もることができる。さらに、その情報を行政などの公共機関が公表すれば人々は密になりやすい場所を避けることができる。特に、新型コロナウイルス感染症はクラスターでの感染が多く報告されていることから[94]、人が集まりやすい施設の属性や性質、密集の度合いなどを見積もることが必要である。

特定の地域に対して人口や施設の分布を推定する研究は人々の行動圏分析などを行う目的で多く行われている。佐藤ら[110]は熊本県中心部における回遊調査データに対してカーネル密度推定を適用し回遊行動圏を分析している。湯本ら[111]は石川県金沢市の中心市街地を対象として、市民の移動軌跡データを昼間と夜間に分析対象を分けてカーネル密度推定を用いた行動圏域分析を行っている。また、佐藤ら[112]は回遊調査データに対してカーネル密度推定を用いた時空間分析を行っている。新型コロナウイルス感染症の感染予防対策を人々の行動圏分析により与える研究は特定の地域を対象としてKato[113]やRex *et al.*[114]により報告されている。

これらの研究は特定の地域における行動圏分析を行い、それぞれの地域に分類して必要な感染予防対策を提案している。これらの研究で対象となっていない地域における感染予防対策の提案は、その地域の特性を考慮して行う必要がある。

Table 6.1: Overview of Narashino city

項目	値
人口 (2020 年度)	176,197 [人]
面積	20.27 [km ²]
人口密度	8,692.50 [人/km ²]

本研究では 2021 年 9 月の千葉県習志野市を分析対象とする。習志野市には駅や商業施設、教育機関など多様な施設が多く存在しているため、施設の種別ごとに相対的な人口密集率を見積もることが重要である。具体的には、2次元平面上に対してカーネル密度推定を用いて人口分布の推定を行い、その結果から人々が多く密集する施設を割り出し、習志野市における新型コロナウイルス感染症の拡大を防ぐための感染予防対策について分析し一定の示唆を得ることを目的とする。

実験では 2021 年 9 月の流動人口データを用いて分析対象を平日と休日の 2 種類に分け、それぞれどのような施設に人々が集まりやすいのか、検証する。また、カーネル密度推定により得られた人口に対する確率分布を視覚化することで定性的に人々が集まりやすい施設を推定した。また、各施設の相対的な人口密集率を定量的に評価した。実験の結果、感染症の感染拡大を防ぐには、企業オフィスや教育機関への出勤、出校や大型の商業施設の営業を制限することが効果的であることが示唆された。

6.2 分析手法

6.2.1 対象地域の概要と利用データ

本研究では千葉県の北西部に位置する習志野市を対象として分析を行う。習志野市の概要を Table 6.1 に示す [115, 116]。

分析には株式会社 Agoop [117] より提供されているスマートフォンの利用者の位置情報をもとに作成された 2021 年 9 月の習志野市におけるポイント型流動人口データを用いる。なお、データは 1 分単位で取得される。本研究で行う分析では人々がいつどこにどれだけいるのかを推定し評価するため、測定誤差が大きいデータを含めると正しい評価が行えなくなることから、そのようなデータは除外する必要がある。また、人々が自動車や公共交通機関を用いて移動しているようなデータを分析対象とすると道路上や線路上に分布が集中してしまうため、移動速度が大きいデータについても除外する必要がある。加えて、今回利用するポイント型データは特定

の携帯キャリアを利用するユーザーの位置情報のみを取得したものである。このような理由から選定して残ったポイント型データのみを用いると空間に対して現実と比べ人口分布が疎になってしまうため、推定手法を用いずに分析を行うことは不十分である。そこで本研究では選定されたポイントデータを用いて習志野市全体の人口分布を、緯度経度を入力とし密度推定手法により見積もり、その結果から密になりやすい施設の属性や密集度合などを検証する。習志野市の人口に対する真の確率分布は特定できないため、本研究ではノンパラメトリックな手法であるカーネル密度推定を用いて人口分布を推定する。

6.2.2 カーネル密度推定

カーネル密度推定 [118, 119] とは、 D 次元空間上で確率密度を求めたいデータ点 \mathbf{x} の推定密度を

$$\hat{f}(\mathbf{x}) = \frac{1}{n} \sum_{i=1}^n \frac{1}{h^D} k\left(\frac{\mathbf{x} - \mathbf{x}_i}{h}\right) \quad (6.1)$$

として求める手法である。なお、 n は観測されたデータ数、 $k(\cdot)$ はカーネル関数であり、例えば次のような関数

$$k(\mathbf{u}) = \begin{cases} 1 & : |\mathbf{u}_i| \leq 1/2, (i = 1, 2, \dots, D), \\ 0 & : \text{otherwise,} \end{cases} \quad (6.2)$$

を与えると、Eq. 6.1 における $\sum_{i=1}^n k((\mathbf{x} - \mathbf{x}_i)/h)$ は h を一辺の長さとする超立方体の領域 \mathcal{R} に含まれるデータ点の総数とみなすことができ、特に h はバンド幅と呼ばれる。なお、詳細は割愛するが Eq. 6.1 は領域 \mathcal{R} の体積が h^D であることを利用している。Eq. 6.2 のようなカーネル関数を与えると立方体の縁で不連続であるため、滑らかな推定モデルを求める場合には滑らかなカーネル関数を与える必要がある。そのためカーネル密度推定におけるカーネル関数には平均 $\boldsymbol{\mu} = \mathbf{0}$ 、分散共分散行列 $\Sigma = I$ のガウス関数

$$k(\mathbf{u}, \Sigma) = \frac{1}{(\sqrt{2\pi})^D} \exp\left(-\frac{\|\mathbf{u}\|^2}{2}\right), \quad (6.3)$$

が用いられることが多い。なお、 $\mathbf{0}$ および I はそれぞれ D 次元の零ベクトルと単位行列である。Eq. 6.3 のカーネル関数を Eq. 6.1 に適用すると D 次元空間における推

定密度

$$\hat{f}(\mathbf{x}) = \frac{1}{n} \sum_{i=1}^n \frac{1}{(2\pi h^2)^{\frac{D}{2}}} \exp\left(-\frac{\|\mathbf{x} - \mathbf{x}_i\|^2}{2h^2}\right), \quad (6.4)$$

が得られる。本研究においては2次元平面上における人口分布を推定することから Eq. 6.4 に $D = 2$ を代入し、

$$\hat{f}(\mathbf{x}) = \frac{1}{n} \sum_{i=1}^n \frac{1}{(2\pi h^2)} \exp\left(-\frac{\|\mathbf{x} - \mathbf{x}_i\|^2}{2h^2}\right), \quad (6.5)$$

を用いる。Eq. 6.5 において、バンド幅 h は平滑化パラメータの役割をもち、小さすぎるとノイズに過敏に反応し、大きすぎると過剰な平滑化を行ってしまうことから適切に設定することが求められる。また、より厳密には Eq. 6.5 において、二つのバンド幅 h_x, h_y を決める必要があるが、本研究では2次元ユークリッド空間を対象としていることから $h = h_x = h_y$ とした。

6.2.3 対数尤度 Cross validation

真の確率密度関数 $f(\mathbf{x})$ ，推定された確率密度関数を $\hat{f}(\mathbf{x})$ としたときこれらの尤度に基づく距離は

$$I_{KL}(f\|\hat{f}) = \int f(\mathbf{x}) \log \frac{f(\mathbf{x})}{\hat{f}(\mathbf{x})} d\mathbf{x}, \quad (6.6)$$

で定義される Kullback-Leibler (KL) 情報量を用いて表現することができる。ここで Eq. 6.6 は次のようにみなすことができる。

$$I_{KL}(f\|\hat{f}) = E_f \left[\log \frac{f(\mathbf{x})}{\hat{f}(\mathbf{x})} \right] = E_f [\log f(\mathbf{x})] - E_f [\log \hat{f}(\mathbf{x})]. \quad (6.7)$$

なお、 $E_f[\cdot]$ は f に関する期待値である。また、KL 情報量は次の完備性

$$I_{KL}(f\|\hat{f}) = 0 \Leftrightarrow f = \hat{f}, \quad (6.8)$$

を満たすことから、 \hat{f} を真の確率密度関数 f に近づけるには KL 情報量を最小化すればよいことがわかる。なお、KL 情報量は距離の公理のうち非負性と完備性しか満たさないことから、厳密には距離でない点に注意する。

Eq. 6.7 の第1項は \hat{f} によらず一定であるため、KL 情報量を最小化するには第2

項を最大化すればよい. 一方, Eq. 6.7 の第 2 項は

$$E_f[\log \hat{f}(\mathbf{x})] = \int f(x) \log \hat{f}(\mathbf{x}) dx, \quad (6.9)$$

であり, $f(\mathbf{x})$ は未知であるため, Eq. 6.9 を次のように置き換える.

$$E_f[\log \hat{f}(\mathbf{x}_i)] \approx \frac{1}{n} \sum_{i=1}^n \log \hat{f}_{-i}(\mathbf{x}_i). \quad (6.10)$$

なお, $\hat{f}_{-i}(\mathbf{x}_i)$ は標本 $\{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\}$ の中から無作為に抽出したサンプル \mathbf{x}_i を除いて推定した確率密度関数

$$\hat{f}_{-i}(\mathbf{x}_i) = \frac{1}{n-1} \sum_{j=1, j \neq i}^n \frac{1}{2\pi h^2} \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{2h^2}\right). \quad (6.11)$$

であり, このように対数尤度によりパラメータを求める手法を対数尤度 Cross validation(CV) と呼ぶ [120].

ここまでの議論からバンド幅 h は Eq. 6.10 を最大化するものを選べばよいことがわかる. 一方, 解析的に Eq. 6.10 を最大化する h を求めることは難しいため, 一般的には Grid-search(GS) により h を選択する.

6.3 数値実験

6.3.1 実験方法

実験では国土交通省により提供されている千葉県習志野市の行政区域データをメッシュ状に細分化し, 人口分布を推定する. メッシュサイズは 0 に近似させることが理想であるが, 計算コストの観点から, 習志野市の北東端, 南東端, 南西端, 北西端を頂点とする長方形を $500 \times 500 = 250,000$ 個のメッシュに区切り, そのうち習志野市に属する 94,227 個のメッシュの中心をデータ点として Eq. 6.5 を用いて確率密度を推定する. 各メッシュの面積は約 222[m²] である. なお, 習志野市の境界に存在するメッシュには近隣の市町村が含まれている場合があるため, メッシュ面積の総和は Table 6.1 に示す面積とは一致しない点に注意する. 実験に用いるデータは 2021 年 9 月分のデータであるが, 人々の行動は曜日や特定の期間により変容するため, 分析対象を次の二つに分ける.

(A) 2021 年 9 月 20 日以降の平日 (10:00–15:00)

(B) 2021 年 9 月 1 日以降の休日 (10:00–15:00)

ここで平日とは祝日を除く月–金曜日のことであり、休日はそれ以外である。また、9 月中旬ごろまでは一般的に大学が夏休み期間であるため、分析対象 (A) を 9 月 20 日以降としている。また、2021 年 9 月末まで緊急事態宣言期間であったことから、夜間の流動人口は少ないものと考え分析対象を昼間に限定した。分析対象 (A) と (B) の日数はそれぞれ計 9 日間と 8 日間である。

ポイント型データについては第 6.2.1 項で述べた通り、測定誤差の大きいデータと移動速度が大きいデータを除外する。測定誤差と移動速度の閾値はそれぞれ 100 [m] と 10 [km/h] とする。各データには日ごとに ID が割り当てられているが、分析対象となる 10:00–15:00 の間に存在するすべての座標を観測データとして用いると過剰に人口を見積もる可能性があるため、最後に取得された座標を観測データとする。このような条件と除外基準をもとに選定した観測データ数の 1 日平均は分析対象 (A) および (B) でそれぞれ約 1,622 個と 1,714 個であった。

これらの観測データについて Eq. 6.5 を用いて日にち s における確率密度 $\hat{f}_s(\mathbf{x})$ を推定し、それらの平均を分析対象における確率密度の推定値とする。すなわち、

$$\bar{f}(\mathbf{x}) = \frac{1}{|S|} \sum_{s \in S} \hat{f}_s(\mathbf{x}), \quad (6.12)$$

を推定値として用いる。記号 S は日にちの集合である。なお、Eq. 6.5 により得られた日にち s における確率密度 $\hat{f}_s(\mathbf{x})$ の全データ点についての総和が習志野市の人口になるように、次のような操作をする。

$$\hat{f}(\mathbf{x}) = \frac{N}{\sum_{i=1}^n \hat{f}(\mathbf{x}_i)} \hat{f}(\mathbf{x}). \quad (6.13)$$

ここで、 N は Table 6.1 に示した習志野市の人口である。

6.3.2 バンド幅 h の決定

カーネル密度推定においてはバンド幅 h を適切に設定する必要がある。本研究では第 6.2.3 項で紹介した対数尤度 CV と GS によりバンド幅 h を決定する。なお、第 6.3.1 項で述べた通り最終的な分析対象の確率密度推定値は日にちごとの確率密度 $\hat{f}_s(\mathbf{x})$ を計算する必要がある。そのため各分析対象において $|S|$ 個のバンド幅

第 6 章 大規模空間に対する小規模シミュレータ導入のための地域分類



Fig. 6.1: Estimation result for target A using Eq. 6.5 ($h_s = 2^{-11}, \forall s \in S$)

$h_s (s = 1, 2, \dots, |S|)$ を求める。バンド幅 h_s の探索候補は

$$h_s \in \{2^{-20}, 2^{-19}, \dots, 2^0\}, \quad (6.14)$$

とする。バンド幅これらの探索候補に対して尤度 CV を用いて GS を行った結果、すべての日にち s において、バンド幅は $h_s = 2^{-11}$ となった。

6.3.3 実験結果と考察

第 6.3.2 項までに準備したデータおよびパラメータを用いて、千葉県習志野市における人口分布の分析を行う。まず、分析対象 (A) に対して Eq. 6.5 を用いて推定された人口分布を Fig. 6.1 に示す。Fig. 6.1 における色の濃さは単位面積あたりの人口を示している。なお、視覚的に見やすくするため、単位面積あたりの人口 45 人を色濃度の最大値としている。このままでは定性的な分析が行いにくいいため、単位面積あたりの人口が 10 人以上であるメッシュのみを描画した図を Fig. 6.2 に示す。Fig. 6.2 における白点は人口が極大となる点を示しており、カッコ内の数値は四捨五入された人口の代表値を示している。また、一部白点がプロットされていない箇所がある。これらのエリアは自動車の渋滞や集合住宅が存在することにより人口分布が大きく

第6章 大規模空間に対する小規模シミュレータ導入のための地域分類

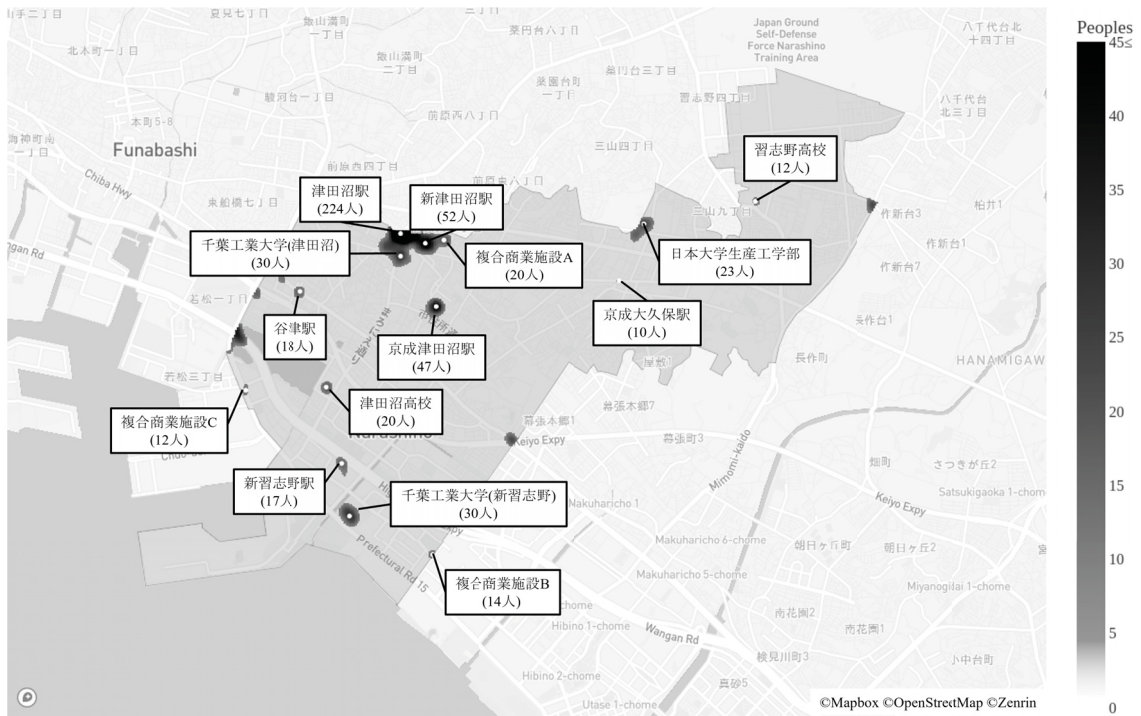


Fig. 6.2: Classification of densely populated areas for target A (numerical values in brackets are representative value)

なったと考えられる。そのような人口密集エリアでは感染イベントは起こりにくいと考えられるため、分析対象から除外した。また、複合商業施設には人口が大きい順にアルファベットを振っている。

Fig. 6.2を見ると駅と教育機関に人々が密集していることがわかる。駅周辺にはオフィスが点在しており、分析対象が平日の流動人口データを集めたものであるため、この結果は直感とも一致する。

Fig. 6.3と6.4には分析対象(B)における人口分布の推定結果を示す。図中の記号や色の濃淡が持つ意味はFig. 6.1および6.2と同様である。Fig. 6.3, 4より分析対象(B)では分析対象(A)と同様に駅において人口が密集しやすいことが確認できる。これは駅周辺には商業施設が多く存在し交通の起点にもなることが要因である。一方で分析対象(A)では教育機関に集中していた人口密集が解消され、逆に多くの複合商業施設に人口が集中していることがわかる。分析対象(B)は休日における流動人口データであることからこの結果も直感と一致する。

次に各施設の相対的な人口密集率について結果を示す。Fig. 6.5は分析対象(A)および(B)における各施設の相対的な人口密集率をヒートマップで示している。各マス

第6章 大規模空間に対する小規模シミュレータ導入のための地域分類



Fig. 6.3: Estimation result for target B using Eq. 6.5 ($h_s = 2^{-11}, \forall s \in S$)

中の数字は行に対する列の人口密集率であり，例えば Fig. 6.5 (A) の左下における 22.26 という数値は津田沼駅の代表点における人口が京成大久保駅の 22.26 倍であることを示している．なお，各施設の代表点は Fig. 6.2 および 6.4 に示した極大点を示す白点であり，白点における単位メッシュに存在する人口を代表値としている．また，色の濃淡は視覚的なわかりやすさを優先し，対数をとっていることから厳密ではない点に注意する．

Fig. 6.5 に示した分析対象 (A) における結果に着目すると，平日においては人口密集率が高い施設のほとんどが駅と教育機関であり，このような施設では感染イベントが発生しやすいことが推測される．一方で Fig. 6.5 の分析対象 (B) における結果に着目すると休日における人口密集エリアはすべて駅と複合商業施設であることがわかる．特に平日に比べ複合商業施設の人口密集率が大きくなっていることも見て取れる．

これらの結果から，新型コロナウイルス感染症のような伝染病が蔓延している社会においては，緊急事態宣言等の政策により人々の動きを止め，リモートワークやリモート授業の推奨，商業施設の営業規制などを積極的に行うことが重要であると考えられる．また，人口密集率が大きかった駅周辺の施設や複合商業施設には飲食

第6章 大規模空間に対する小規模シミュレータ導入のための地域分類

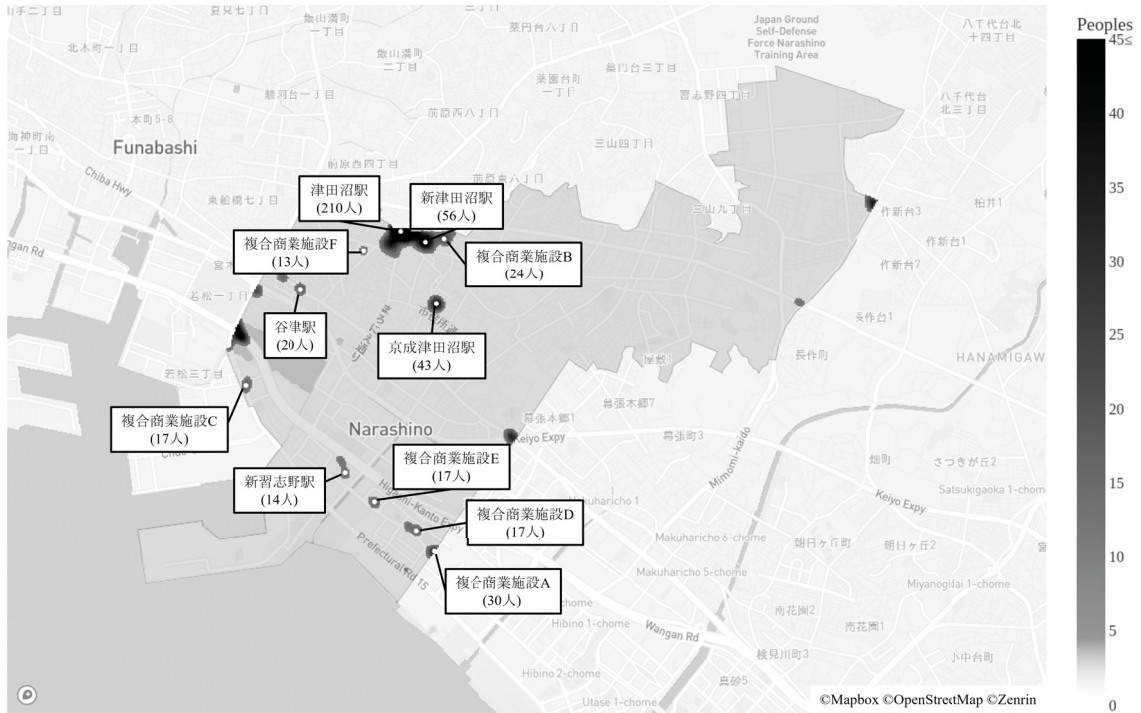


Fig. 6.4: Classification of densely populated areas for target B (numerical values in brackets are representative value)

店舗が多数含まれている。そのため、本研究で紹介した地域分類手法は、前章で提案した小規模空間に対する決定論的アプローチによるシミュレータの導入のための手法として利用可能である。

6.4 結言

本研究では千葉県習志野市を対象として、カーネル密度推定を用いた人口分布の推定を平日と休日に分けて行った。また得られた推定結果をもとに伝染病の感染イベントが起きやすい施設を推測し分析した。その結果、平日においては駅周辺の施設と教育機関、休日においては駅周辺の施設と複合商業施設に人口が多く分布することが判明した。伝染病の感染イベントを発生させないためには、これらの施設の利用を強く制限するような感染予防対策が有効であることが示唆された。また、駅周辺の施設や複合商業施設には飲食店舗が多く含まれていることから、前章で提案した小規模シミュレータを導入する地域を分類するために本手法は有効であることが示唆された。

	1.00	0.23	0.21	0.14	0.14	0.10	0.09	0.08	0.08	0.06	0.05	0.05	0.04
津田沼駅	1.00	0.23	0.21	0.14	0.14	0.10	0.09	0.08	0.08	0.06	0.05	0.05	0.04
新津田沼駅	4.32	1.00	0.90	0.59	0.58	0.45	0.39	0.38	0.35	0.33	0.27	0.23	0.22
京成津田沼	4.78	1.11	1.00	0.65	0.65	0.50	0.43	0.43	0.39	0.36	0.30	0.25	0.24
千葉工業大学(津田沼)	7.36	1.70	1.54	1.00	1.00	0.77	0.66	0.65	0.60	0.56	0.46	0.39	0.38
千葉工業大学(新習志野)	7.39	1.71	1.55	1.00	1.00	0.77	0.66	0.66	0.60	0.56	0.46	0.39	0.38
日本大学生産工学部	9.58	2.22	2.01	1.30	1.30	1.00	0.85	0.85	0.78	0.73	0.60	0.51	0.49
津田沼高校	11.22	2.60	2.35	1.52	1.52	1.17	1.00	1.00	0.91	0.85	0.70	0.59	0.57
複合商業施設A	11.24	2.60	2.35	1.53	1.52	1.17	1.00	1.00	0.91	0.85	0.70	0.59	0.58
谷津駅	12.33	2.85	2.58	1.68	1.67	1.29	1.10	1.10	1.00	0.94	0.77	0.65	0.63
新習志野駅	13.18	3.05	2.76	1.79	1.78	1.38	1.17	1.17	1.07	1.00	0.82	0.70	0.68
複合商業施設B	16.01	3.71	3.35	2.18	2.17	1.67	1.43	1.43	1.30	1.22	1.00	0.85	0.82
複合商業施設C	18.91	4.38	3.96	2.57	2.56	1.97	1.69	1.68	1.53	1.44	1.18	1.00	0.97
習志野高校	19.52	4.52	4.09	2.65	2.64	2.04	1.74	1.74	1.58	1.48	1.22	1.03	1.00
京成大久保駅	22.26	5.15	4.66	3.03	3.01	2.32	1.98	1.98	1.81	1.69	1.39	1.18	1.14
津田沼駅	1.00	0.27	0.20	0.14	0.14	0.12	0.09	0.08	0.08	0.07	0.06	0.06	0.06
新津田沼駅	3.77	1.00	0.76	0.54	0.44	0.35	0.31	0.31	0.30	0.26	0.23	0.23	0.23
京成津田沼駅	4.94	1.31	1.00	0.71	0.57	0.46	0.40	0.40	0.40	0.34	0.30	0.30	0.30
複合商業施設A	6.93	1.84	1.40	1.00	0.80	0.65	0.57	0.57	0.56	0.48	0.42	0.42	0.42
複合商業施設B	8.63	2.29	1.75	1.25	1.00	0.80	0.71	0.70	0.69	0.59	0.53	0.53	0.53
谷津駅	10.73	2.84	2.17	1.55	1.24	1.00	0.88	0.88	0.86	0.74	0.66	0.66	0.66
複合商業施設C	12.21	3.24	2.47	1.76	1.42	1.14	1.00	1.00	0.98	0.84	0.75	0.75	0.75
複合商業施設D	12.25	3.25	2.48	1.77	1.42	1.14	1.00	1.00	0.98	0.84	0.75	0.75	0.75
複合商業施設E	12.46	3.30	2.52	1.80	1.44	1.16	1.02	1.02	1.00	0.86	0.76	0.76	0.76
新習志野駅	14.53	3.85	2.94	2.10	1.68	1.35	1.19	1.19	1.17	1.00	0.89	0.89	0.89
複合商業施設F	16.32	4.33	3.31	2.36	1.89	1.52	1.34	1.33	1.31	1.12	1.00	1.00	1.00

(A) 平日

(B) 休日

Fig. 6.5: Ratio of relative densely population in each facility for target A and B. Note that the numerical value in cells is ratio of column entry for row entry.

7 結論

7.1 本研究の貢献

本研究の社会科学およびシミュレーション分野における貢献を以下に示す。

- 社会シミュレーションに対する確率論的な手法である Multi-agent システムによるシミュレーターについて、その信頼性を古典的な手法と比較することにより検証し、また不確実性により発生する従来手法の弱点を示した(第2章).
- MAS を整数計画問題として定式化することにより、複雑な入力に対して一意的に出力が定まる大規模な空間における決定論的シミュレーションを可能とした(第3章).
- 社会動向の予測を目的とした不確実性を内在するシミュレーションにおいて、不確実性を内在する MAS と機械学習モデルを用いた多数の施策効果を高速かつ高精度に推定する枠組みを構築し、さらにその精度を向上させるための指針を示した(第4章).
- 第4章で対象とした空間に点在する小規模な空間におけるシミュレーション手法を構築し、大規模な空間への導入のための分類手法を検証することで、社会シミュレーションの精度向上の可能性を示した(第5章, 第6章).

一方で本研究では、上記成果を統合した枠組みの構築には至っていない。すなわち、小規模な空間を含む大規模な空間における社会シミュレーションモデルの構築と、構築されたモデルへの MAS-ML 適用が実現されていない。前者に関しては第6章で利用したカーネル密度推定による地域分類結果をもとに、該当地域に対して感染イベントを付与することが考えられる。該当地域に対しては地域特性に合わせて、感染事象などの発生確率を与える関数を組み込むことでより詳細な社会シミュレーション手法の構築が期待できる。特に第5章で提案した小規模空間に対する MAS シミュレーションに対して第4章で提案した MAS-ML を適用することで、大規模空間が内包する小規模空間における事象を高速かつ高精度に組み込むことが可能となる。

また、第4章で構築した MAS-ML ではデータセット構築に多大な計算コストを要する点を解決できていない。さらに本研究で採用した機械学習モデルである SVR はデータセット構築後、新たにデータセットが追加される場合には再学習をする必要

がある。これらの問題点の解決には Ma *et al.* により提案されている accurate on-line SVR (AOSVR) の応用が期待できる [121]。AOSVR は学習済みモデルに対してデータセットの追加および削除を逐次行うことが可能であり、再学習の必要がない。また、AOSVR を応用することでデータセット構築と並行して学習済みモデルの予測精度を向上させることが可能になり、上述の問題を解決できる可能性がある。

社会という複雑系の行く末を高精度に予測することは持続可能な人間社会の構築において非常に重要である。本研究ではそのような社会構築に必要な基礎的な手法の整理とそれらが抱える問題点の解決に取り組み成果をあげた。一方で上述のよう課題を解決することは、社会科学およびシミュレーション分野の発展に寄与しさらには豊かな人間社会の構築を可能とするものであることから、今後も積極的に研究を進めていく必要がある。

7.2 総括

本研究では人間が構成する複雑系シミュレーションにおける、入力に対する複雑性とその出力の収束性に着目し、現実的に応用可能な社会シミュレーション手法の構築を行った。そのために、まず従来確率論的アプローチによる社会シミュレーション手法である MAS についてレビューし、その信頼性の検証と不確実性により発生する外れ値の影響を示した。それにより、社会シミュレーションは大規模な空間において自律した多数の個体による相互作用を再現する複雑系シミュレーションであることから、不確実性を取り除くために多数回のシミュレーション施行により出力を一定程度収束させることの重要性を明らかにした。そのような従来手法の弱点克服のため、複雑性を保ちつつ一意的に出力を得ることのできる、決定論的な MAS を整数計画問題により構築した。整数計画問題に対して最適性の保証がある厳密解法を適用した場合、評価関数の最適値には一意性が保証され、従来手法のように出力の収束性を考慮する必要がない。そのため、提案した整数計画問題として定式化した MAS を用いた手法により、入力条件さえ定まれば一度の試行で実用的な出力を得ることが可能になった。さらに、大規模な空間を対象とする社会シミュレーションにおいて、計算コストの観点から考慮されない小規模な空間におけるシミュレーション手法を決定論的アプローチにより構築した。構築した小規模な空間におけるシミュレーション手法を大規模な空間に導入する場合に必要な地域分類手法について検証した。

ここまで構築した決定論的アプローチによるシミュレーション手法は、従来の

MASによる手法の弱点を克服するものであったが、多数の入力構成、すなわちシナリオに対する試行錯誤的な検証は計算コストの観点から困難であった。そこで、最後に従来の確率論的アプローチによるMASと決定論的アプローチであるSVRを組み合わせることで、複雑性を有しつつ入力に対してロバストで高速に多数の施策に対するスクリーニングを行うことのできる機械学習モデルを構築した。さらに、確率論的アプローチによるMASの出力に対する収束性に着目し、提案した枠組みにより構築したモデルの推定精度を向上させるための指針を示した。最後に提案した枠組みは感染症が蔓延した社会を想定したが、複雑系シミュレーションが適用可能な分野であれば応用が容易である。このことから本研究で得られた成果は様々な研究分野に対して波及性するものと考えられる。

謝辞

本研究の遂行にあたり、多くの御指導御協力を賜りました日本大学生産工学部 豊谷純教授に心より感謝申し上げます。

本論文の審査において、御指導を賜りました日本大学生産工学部 水上祐治教授ならびに三友信夫教授に深く感謝申し上げます。

本論文の審査に加え、これまでの研究遂行においても多くの御指導御協力賜りました東京都市大学 高橋弘毅教授に深甚なる感謝を申し上げます。

本研究の遂行にあたり、活発な議論の中で多くの御教示賜りました日本大学生産工学部 大前佑斗専任講師に心より感謝申し上げます。

これまでの研究遂行にあたり、多くの御指導御教示を賜りましたサレジオ工業高等専門学校 島川陽一教授、法政大学 五島洋行教授に深甚なる感謝申し上げます。

共同研究者の皆様には、活発な議論のなかで多くの御教示を賜りました。感謝申し上げます。

最後にこれまで私の人生を温かく見守り辛抱強く御支援して下さった両親、兄弟、なによりそばで支え続けてくれた妻藍と愛猫クロに深く敬意を表するとともに、心より感謝申し上げます。

Bibliography

- [1] A. Drogoul, J. Ferber: “Multi-agent simulation as a tool for modeling societies: Application to social differentiation in ant colonies”, in *Artificial Social Systems*, ser. *Lecture Notes in Computer Science*, C. Castelfranchi, E. Werner, Eds., pp.2–23, Berlin, Heidelberg (1994)
- [2] J. M. Epstein, R. Axtell: *Growing Artificial Societies: Social Science from the Bottom Up*, Brookings Institution Press, google-Books-ID: xXvelSs2caQC (1996-10) (in En)
- [3] T. Klaus: “Social Science Simulation — Origins, Prospects, Purposes”, in *Simulating Social Phenomena*, ser. *Lecture Notes in Economics and Mathematical Systems*, R. Conte, R. Hegselmann, P. Terna, Eds., pp.41–54, Berlin, Heidelberg (1997)
- [4] H. Van Dyke Parunak, R. Savit, R. L. Riolo: “Agent-based modeling vs. equation-based modeling: A case study and users’ guide”, in *Multi-agent Systems and Agent-based Simulation*, ser. *Lecture Notes in Computer Science*, J. S. Sichman, R. Conte, N. Gilbert, Eds., pp.10–25, Berlin, Heidelberg (1998)
- [5] N. Gilbert, T. Klaus: *Simulation For The Social Scientist*, McGraw-Hill Education (UK), google-Books-ID: fBlaulpmNowC (2005-2) (in En)
- [6] D. Helbing, P. Molnár: “Social force model for pedestrian dynamics”, *Physical Review E*, Vol.51, No.5, pp.4282–4286 (1995-5)
- [7] M. Moussaïd, N. Perozo, S. Garnier, D. Helbing, G. Theraulaz: “The Walking Behaviour of Pedestrian Social Groups and Its Impact on Crowd Dynamics”, *PLOS ONE*, Vol.5, No.4, p.e10047 (2010-4)
- [8] J. L. Aron, I. B. Schwartz: “Seasonality and period-doubling bifurcations in an epidemic model”, *Journal of Theoretical Biology*, Vol.110, No.4, pp.665–679 (1984)
- [9] J. Farooqa, M. A. Bazaz: “A novel adaptive deep learning model of Covid-19 with focus on mortality reduction strategies”, *Chaos, Solitons and Fractals*, Vol.138, p.110148 (2020)

- [10] I. Korolev: “Identification and estimation of the SEIRD epidemic model for COVID-19”, *Journal of Econometrics*, Vol.220, No.1, pp.63–85 (2021)
- [11] W. O. Kermack, A. G. McKendrick: “A contribution to the mathematical theory of epidemics”, in Proceedings of the Royal of London. Society A, Containing Papers of a Mathematical and Physical Character, Vol.115, No.772, pp.700–721 (1927-8)
- [12] G. Dantzig, R. Fulkerson, S. Johnson: “Solution of a large-scale traveling-salesman problem”, *Journal of the Operations Research Society of America*, Vol.2, No.4, pp.393–410 (1954-11)
- [13] G. B. Dantzig, J. H. Ramser: “The truck dispatching problem”, *Management Science*, Vol.6, No.1, pp.80–91 (1959-10)
- [14] G. Clarke, J. W. Wright: “Scheduling of vehicles from a central depot to a number of delivery points”, *Operations Research*, Vol.12, No.4, pp.568–581 (1964)
- [15] J. Bramel, D. Simchi-Levi: The logic of logistics: theory, algorithms, and applications for logistics management, ser. Springer series in operations research, Springer, oCLC: 441715956 (1997) (in Eng)
- [16] R. Church, C. ReVelle: “The maximal covering location problem”, *Papers of the Regional Science Association*, Vol.32, No.1, pp.101–118 (1974-12)
- [17] S. L. Hakimi: “Optimum locations of switching centers and the absolute centers and medians of a graph”, *Operations Research*, Vol.12, No.3, pp.450–459 (1964)
- [18] C. ReVelle, C. Toregas, L. Falkson: “Applications of the location set-covering problem”, *Geographical Analysis*, Vol.8, No.1, pp.65–76 (1976)
- [19] C. Li, I. E. Grossmann: “A review of stochastic programming methods for optimization of process systems under uncertainty”, *Frontiers in Chemical Engineering*, Vol.2 (2021)
- [20] M. S. Lobo, L. Vandenberghe, S. Boyd, H. Lebret: “Applications of second-order cone programming”, *Linear Algebra and its Applications*, Vol.284, No.1, pp.193–228 (1998-11)

- [21] M. I. Jordan, T. M. Mitchell: “Machine learning: Trends, perspectives, and prospects”, *Science*, Vol.349, No.6245, pp.255–260 (2015-7)
- [22] M. Hindman: “Building better models: Prediction, replication, and machine learning in the social sciences”, *The ANNALS of the American Academy of Political and Social Science*, Vol.659, No.1, pp.48–62 (2015-5)
- [23] A. O’Hagan: “Bayesian analysis of computer code outputs: A tutorial”, *Reliability Engineering & System Safety*, Vol.91, No.10, pp.1290–1300 (2006-10)
- [24] C. Angione, E. Silverman, E. Yaneske: “Using machine learning as a surrogate model for agent-based simulations”, *PLOS ONE*, Vol.17, No.2, p.e0263150 (2022-2)
- [25] F. Lamperti, A. Roventini, A. Sani: “Agent-Based Model Calibration using Machine Learning Surrogates”, Tech. Rep. (2017-4) arXiv:1703.10639 [q-fin] type: article.
- [26] F. Lamperti, A. Roventini, A. Sani: “Agent-based model calibration using machine learning surrogates”, *Journal of Economic Dynamics and Control*, Vol.90, pp.366–389 (2018-5)
- [27] Y. Omae, Y. Kakimoto, J. Toyotani, K. Hara, Y. Gon, H. Takahashi: “Reliability of multi-agent based infection simulator with parameters of isolation wards”, *ICIC Express Letters, Part B: Applications*, Vol.12, No.6, pp.577–586 (2021)
- [28] Y. Kakimoto, Y. Shimakawa, H. Takahashi: “Optimal location model of electric vehicle charging facility based on the flow-capturing location-allocation model –Case study by using the data of road network of Bangkok, Thailand”, *Journal of Computations and Modelling*, Vol.8, No.2, pp.111–136 (2018)
- [29] Y. Kakimoto, Y. Shimakawa: “Rest-area location model for time-driven demands to the expend buffer time of freight vehicles”, *International Journal of Innovative Computing, Information and Control* (2022)
- [30] Y. Kakimoto, Y. Omae, J. Toyotani, H. Takahashi, Y. Kakimoto, Y. Omae, J. Toyotani, H. Takahashi: “Fast screening framework for infection control

- scenario identification”, *Mathematical Biosciences and Engineering*, Vol.19, No.12, pp.12 316–12 333 (2022)
- [31] 柿本 陽平, 高橋 弘毅, 島川 陽一: “制約充足問題を線形計画法で解く場合の制約条件の緩和とその評価”, *日本経営工学会論文誌*, Vol.66, No.4, pp.348–354 (2016)
- [32] 柿本 陽平, 大前 佑斗, 豊谷 純, 原 一之, 高橋 弘毅: “COVID-19 の感染リスクを考慮した飲食店における着座管理モデル”, *信学技報*, Vol.121, No.97, pp.17–21 (2021)
- [33] 柿本 陽平, 大前 佑斗, 豊谷 純: “千葉県習志野市における新型コロナウイルス感染予防対策のための人口密集エリアの推定と分類”, *日本情報ディレクトリ学会誌*, Vol.20, No.1, pp.81–88 (2022)
- [34] Y. Omae, J. Toyotani, K. Hara, H. Takahashi: “A prediction method for viral disease outbreak using a multi-agent simulation including capacity limitation for isolation wards and stay-at-home orders”, *Journal of Japan Society for Fuzzy Theory and Intelligent Informatics*, Vol.32, No.6, pp.998–1007 (2020)
- [35] W. LAM, N. ZHONG, W. TAN: “Overview on SARS in Asia and the World”, *Respirology (Carlton, Vic.)*, Vol.8, No.Suppl 1, pp.S2–S5 (2003-11)
- [36] T. P. Velavan, C. G. Meyer: “The COVID-19 epidemic”, *Tropical medicine & international health: TM & IH*, Vol.25, No.3, pp.278–280 (2020-3)
- [37] B. Prasse, M. A. Achterberg, L. Ma, P. Van Mieghem: “Network-inference-based prediction of the COVID-19 epidemic outbreak in the Chinese province Hubei”, *Applied Network Science*, Vol.5, No.1, p.35 (2020)
- [38] Q. Yang, C. Yi, A. Vajdi, L. W. Cohnstaedt, H. Wu, X. Guo, C. M. Scoglio: “Short-term forecasts and long-term mitigation evaluations for the COVID-19 epidemic in Hubei Province, China”, *Infectious Disease Modelling*, Vol.5, pp.563–574 (2020)
- [39] M. A. Achterberg, B. Prasse, L. Ma, S. Trajanovski, M. Kitsak, P. Van Mieghem: “Comparing the accuracy of several network-based COVID-19 prediction algorithms”, *International Journal of Forecasting*, Vol.38, No.2, pp.489–504 (2022-4)

- [40] Z. Liu, P. Magal, G. Webb: “Predicting the number of reported and unreported cases for the COVID-19 epidemics in China, South Korea, Italy, France, Germany and United Kingdom”, *Journal of Theoretical Biology*, Vol.509, p.110501 (2021-1)
- [41] H.-F. Huo, Q. Yang, H. Xiang: “Dynamics of an edge-based SEIR model for sexually transmitted diseases”, *Mathematical biosciences and engineering: MBE*, Vol.17, No.1, pp.669–699 (2019-10)
- [42] A. Smirnova, L. deCamp, G. Chowell: “Forecasting epidemics through nonparametric estimation of time-dependent transmission rates using the SEIR model”, *Bulletin of Mathematical Biology*, Vol.81, No.11, pp.4343–4365 (2019-11)
- [43] Y. A. Kuznetsov, C. Piccardi: “Bifurcation analysis of periodic SEIR and SIR epidemic models”, *Journal of Mathematical Biology*, Vol.32, No.2, pp.109–121 (1994-1)
- [44] M. De la Sen, A. Ibeas, s. Alonso-Quesada, R. Nistal: “On the time-optimal vaccination control for an seir epidemic model with eventual modelling errors”, *International Journal of Innovative Computing, Information and Control*, Vol.15, No.1, pp.163–187 (2019-2)
- [45] Z. Yang, Z. Zeng, K. Wang, S.-S. Wong, W. Liang, M. Zanin, P. Liu, X. Cao, Z. Gao, Z. Mai, J. Liang, X. Liu, S. Li, Y. Li, F. Ye, W. Guan, Y. Yang, F. Li, S. Luo, Y. Xie, B. Liu, Z. Wang, S. Zhang, Y. Wang, N. Zhong, J. He: “Modified SEIR and AI prediction of the epidemics trend of COVID-19 in China under public health interventions”, *Journal of Thoracic Disease*, Vol.12, No.3, pp.165–174 (2020-3)
- [46] S. He, Y. Peng, K. Sun: “SEIR modeling of the COVID-19 and its dynamics”, *Nonlinear Dynamics*, Vol.101, No.3, pp.1667–1680 (2020-8)
- [47] Y. Omae, J. Toyotani, K. Hara, Y. Gon, H. Takahashi: “Effectiveness of the COVID-19 contact-confirming application (COCOA) based on multi-agent simulation”, *Journal of Advanced Computational Intelligence and Intelligent Informatics*, Vol.25, No.6, pp.931–943 (2021)

-
- [48] Y. Omae, J. Toyotani, K. Hara, Y. Gon, H. Takahashi: “Effectiveness of the COVID-19 contact-confirming application incorporating secondary indirect contact notification function on decreasing the number of infectors”, *Journal of Japan Society for Fuzzy Theory and Intelligent Informatics*, Vol.33, No.3, pp.697–710 (2021)
- [49] A. R. Alho, J. de Abreu e Silva: “Analyzing the relation between land-use/urban freight operations and the need for dedicated infrastructure/enforcement — Application to the city of Lisbon”, *Research in Transportation Business & Management*, Vol.11, pp.85–97 (2014-7)
- [50] S. Jung, S. Joo, C. Oh: “Evaluating the effects of supplemental rest areas on freeway crashes caused by drowsy driving”, *Accident; Analysis and Prevention*, Vol.99, No.Pt A, pp.356–363 (2017-2)
- [51] T. L. Bunn, S. Slavova, P. J. Rock: “Association between commercial vehicle driver at-fault crashes involving sleepiness/fatigue and proximity to rest areas and truck stops”, *Accident Analysis & Prevention*, Vol.126, pp.3–9 (2019-5)
- [52] W. Ho, G. T. S. Ho, P. Ji, H. C. W. Lau: “A hybrid genetic algorithm for the multi-depot vehicle routing problem”, *Engineering Applications of Artificial Intelligence*, Vol.21, No.4, pp.548–557 (2008-6)
- [53] D. Cattaruzza, N. Absi, D. Feillet, T. Vidal: “A memetic algorithm for the multi trip vehicle routing problem”, *European Journal of Operational Research*, Vol.236, No.3, pp.833–848 (2014-8)
- [54] C. G. Csehi, M. Farkas: “Truck routing and scheduling”, *Central European Journal of Operations Research*, Vol.25, No.4, pp.791–807 (2017-12)
- [55] P. Rawinun, K. Somyot: “Optimal path planning with A-star optimization and multi-robot task allocation in hard disk drive manufacturing layout”, *ICIC Express Letters, Part B: Applications*, Vol.12, No.03, p.223 (2021)
- [56] C. Toregas, R. Swain, C. ReVelle, L. Bergman: “The location of emergency service facilities”, *Operations Research*, Vol.19, No.6, pp.1363–1373 (1971-10)

- [57] X. Fei, H. S. Mahmassani, S. M. Eisenman: “Sensor coverage and location for real-time traffic prediction in large-scale networks”, *Transportation Research Record*, Vol.2039, No.1, pp.1–15 (2007-1)
- [58] L. Bianco, G. Confessore, P. Reverberi: “A network based model for traffic sensor location with implications on O/D matrix estimates”, *Transportation Science*, Vol.35, No.1, pp.50–60 (2001-2)
- [59] W. Tu, Q. Li, Z. Fang, S.-l. Shaw, B. Zhou, X. Chang: “Optimizing the locations of electric taxi charging stations: A spatial–temporal demand coverage approach”, *Transportation Research Part C: Emerging Technologies*, Vol.65, pp.172–189 (2016-4)
- [60] K.-i. Tanaka, T. Furuta: “Locations and service start time of flow-covering facilities with multiple coverage levels”, *Journal of the Operations Research Society of Japan*, Vol.56, No.3, pp.177–197 (2013)
- [61] J. Kolodinskaja, L. Bertulienė: “Layout of Rest Areas and Their Infrastructure Development in the South-Eastern Region of Lithuania”, *The Baltic Journal of Road and Bridge Engineering*, Vol.15, No.3, pp.130–145 (2020-8)
- [62] M. J. Hodgson: “A flow-capturing location-allocation model”, *Geographical Analysis*, Vol.22, No.3, pp.270–279 (1990)
- [63] M. Kojima, S. Mizuno, A. Yoshise: “A little theorem of the big M in interior point algorithms”, *Mathematical Programming*, Vol.59, No.1, pp.361–375 (1993-3)
- [64] D. Simchi-Levi, O. Berman: “A heuristic algorithm for the traveling salesman location problem on networks”, *Operations Research*, Vol.36, No.3, pp.478–484 (1988)
- [65] T. Kamada, S. Kawai: “An algorithm for drawing general undirected graphs”, *Information Processing Letters*, Vol.31, No.1, pp.7–15 (1989-4)
- [66] H. A. Friberg: Presolving and regularization in mixed-integer second-order cone optimization, DTU Wind Energy (2016)

- [67] J. M. Carcione, J. E. Santos, C. Bagaini, J. Ba: “A simulation of a COVID-19 epidemic based on a deterministic SEIR model”, *Frontiers in public health*, Vol.8, No.230, p.PMC7270399 (2020)
- [68] G. Barwolff: “Mathematical modeling and simulation of the COVID-19 pandemic”, *Systems*, Vol.8, No.3, p.24 (2020)
- [69] P. C. Silva, P. V. Batista, H. S. Lima, M. A. Alves, F. G. Guimaraes, R. C. Silva: “COVID-ABS: An agent-based model of COVID-19 epidemic to simulate health and economic effects of social distancing interventions”, *Chaos, Solitons & Fractals*, Vol.139, p.110088 (2020)
- [70] Y. Wei, J. Wang, W. Song, C. Xiu, L. Ma, T. Pei: “Spread of COVID-19 in China: analysis from a city-based epidemic and mobility model”, *Cities*, Vol.110, p.103010 (2021)
- [71] Y. Omae, Y. Kakimoto, J. Toyotani, K. Hara, Y. Gon, H. Takahashi: “Impact of removal strategies of stay-at-home orders on the number of COVID-19 infectors and people leaving their homes”, *International Journal of Innovative Computing, Information and Control*, Vol.17, No.3, pp.1055–1065 (2021)
- [72] Y. Omae, J. Toyotani, K. Hara, Y. Gon, H. Takahashi: “Effectiveness of the COVID-19 contact-confirming application (COCOA) based on multi-agent simulation”, *Journal of Advanced Computational Intelligence and Intelligent Informatics*, Vol.25, No.6, pp.931–943 (2021)
- [73] A. Sharma, S. Bahl, A. K. Bagha, M. Javaid, D. K. Shukla, A. Haleem: “Multi-agent system applications to fight COVID-19 pandemic”, *Apollo Medicine*, Vol.17, No.5, pp.41–43 (2020)
- [74] A. Badica, C. Badica, M. Ganzha, M. Ivanovic, M. Paprzycki: “Multi-agent simulation of core spatial SIR models for epidemics spread in a population”, in 2020 5th IEEE International Conference on Recent Advances and Innovations in Engineering (ICRAIE), pp.1–7, Jaipur (2020)
- [75] Y. Vyklyuk, M. Manylich, M. Skoda, M. M. Radovanovic, M. D. Petrovic: “Modeling and analysis of different scenarios for the spread of COVID-19 by using the

- modified multi-agent systems —Evidence from the selected countries”, *Results in Physics*, Vol.20, p.103662 (2021)
- [76] H. Hirose: “Pandemic simulations by MADE: A combination of multi-agent and differential equations, with novel influenza A (H1N1) case”, *Information*, Vol.16, No.7(B), pp.5365–5390 (2013)
- [77] B. E. Boser, I. Guyon, V. N. Vapnik: “A training algorithm for optimal margin classifiers”, in Proceedings of the Fifth Annual Workshop of Computational Learning Theory, pp.144–152, Pittsburgh (1992)
- [78] C. Cortes, V. Vapnik: “Support-vector networks”, *Machine Learning*, Vol.20, pp.273–297 (1995)
- [79] D. Basak, S. Pal, D. C. Patranabis: “Support vector regression”, *Neural Information Processing —Letters and Reviews*, Vol.11, No.10, pp.203–224 (2007)
- [80] M. Awad, K. Rahul: *Efficient learning machines*, 1st ed., Apress (2015)
- [81] B. Scholkopf, A. J. Smola, R. C. Williamson, P. L. Bartlett: “New support vector algorithms”, *Neural computation*, Vol.12, No.5, pp.1207–1245 (2000)
- [82] J. Feng, L. Liu, D. Wu, G. Li, M. Beer, W. Gao: “Dynamic reliability analysis using the extended support vector regression (X-SVR)”, *Mechanical Systems and Signal Processing*, Vol.126, pp.368–391 (2019)
- [83] S. Liu, T. Yamamoto: “Role of stay-at-home requests and travel restrictions in preventing the spread of COVID-19 in Japan”, *Transportation Research Part A: Policy and Practice*, Vol.159, pp.1–16 (2022-5)
- [84] L. Silva, D. F. Filho, A. Fernandes: “The effect of lockdown on the COVID-19 epidemic in Brazil: evidence from an interrupted time series design”, *Cadernos de saude publica*, Vol.36 (2020)
- [85] J. H. Fowler, S. J. Hill, R. Levin, N. Obradovich: “The effect of stay-at-home orders on COVID-19 cases and fatalities in the United States”, *medRxiv*, p.2020.04.13.20063628 (2020-5)

- [86] P. Drineas, M. W. Mahoney: “Approximating a gram matrix for improved kernel-based learning”, *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, Vol.3559 LNAI, pp.323–337 (2005)
- [87] M. Tohmé, R. Lengellé: “F-SVR: A new learning algorithm for support vector regression”, *ICASSP, IEEE International Conference on Acoustics, Speech and Signal Processing - Proceedings*, pp.2005–2008 (2008)
- [88] P. Y. Hao: “Pair-v-SVR: A novel and efficient pairing nu-support vector regression algorithm”, *IEEE Transactions on Neural Networks and Learning Systems*, Vol.28, pp.2503–2515 (2017-11)
- [89] P. M. Dunuwila, R. A. Rajapakse: “Evaluating optimal lockdown and testing strategies for COVID-19 using multi-agent social simulation”, *ICAC 2020 - 2nd International Conference on Advancements in Computing, Proceedings*, pp.240–245 (2020-12)
- [90] H. Kaneko, K. Funatsu: “Fast optimization of hyperparameters for support vector regression models with highly predictive ability”, *Chemometrics and Intelligent Laboratory Systems*, Vol.142, pp.64–69 (2015)
- [91] World Health Organization: “WHO Director-General’s opening remarks at the media briefing on COVID-19”. <https://www.who.int/dg/speeches/detail/who-director-general-s-opening-remarks-at-the-media-briefing-on-covid-19---11-march-2020> [accessed: 2021/12/2].
- [92] NHK: “新型コロナ 国内感染 150 万人超える “第 5 波” で加速度的に拡大”. <https://www3.nhk.or.jp/news/html/20210901/k10013237121000.html> [accessed: 2021/12/2].
- [93] 厚生労働省: “新型コロナウイルスを想定した「新しい生活様式」の実践例を公表しました”. https://www.mhlw.go.jp/stf/seisakunitsuite/bunya/0000121431_newlifestyle.html [accessed: 2022/12/2].

参考文献

- [94] 厚生労働省: “新型コロナウイルスの集団感染を防ぐために”. <https://www.mhlw.go.jp/content/10900000/000602323.pdf> [accessed: 2021/12/2].
- [95] Q. J. Leclerc, N. M. Fuller, L. E. Knight, S. Funk, G. M. Knight: “What settings have been linked to SARS-CoV-2 transmission clusters? [version 2; peer review: 2 approved]”, *Wellcome Open Research*, Vol.5, No.83 (2020)
- [96] 内閣官房: “新型コロナウイルス感染症緊急事態宣言の概要”. https://corona.go.jp/news/news_20200421_70.html [accessed: 2021/12/2].
- [97] C. A. d. S. Siqueira, Y. N. L. d. Freitas, M. d. C. Cancela, M. Carvalho, A. Oliveras-Fabregas, D. L. B. d. Souza: “The effect of lockdown on the outcomes of COVID-19 in Spain: An ecological study”, *PLOS ONE*, Vol.15, No.7, p.e0236779 (2020-7)
- [98] L. Silva, D. Figueiredo Filho, A. Fernandes: “The effect of lockdown on the COVID-19 epidemic in Brazil: evidence from an interrupted time series design”, *Cadernos de Saúde Pública*, Vol.36 (2020-10)
- [99] H. J. Song, J. Yeon, S. Lee: “Impact of the COVID-19 pandemic: Evidence from the U.S. restaurant industry”, *International Journal of Hospitality Management*, Vol.92, p.102702 (2021-1)
- [100] 帝国データバンク: “飲食店の倒産動向調査（2020年）”. <https://www.tdb.co.jp/report/watching/press/p210101.html> [accessed: 2021/12/2].
- [101] 日本フードサービス協会, 全国生活衛生同業組合中央会: “新型コロナウイルス感染症対策の基本的対処方針（改正）に基づく外食業の事業継続のためのガイドライン”. http://www.jfnet.or.jp/contents/_files/safety/FSguideline_201130kai.pdf [accessed: 2021/12/2].
- [102] D. K. Chu, E. A. Akl, S. Duda, K. Solo, S. Yaacoub, H. J. Schünemann, D. K. Chu, E. A. Akl, A. El-harakeh, A. Bognanni, T. Lotfi, M. Loeb, A. Hajizadeh, A. Bak, A. Izcovich, C. A. Cuello-Garcia, C. Chen, D. J. Harris, E. Borowiack, F. Chamseddine, F. Schünemann, G. P. Morgano, G. E. U. M. Schünemann, G. Chen, H. Zhao, I. Neumann, J. Chan, J. Khabisa, L. Hneiny, L. Harrison, M. Smith, N. Rizk, P. G. Rossi, P. AbiHanna, R. El-khoury, R. Stalteri,

- T. Baldeh, T. Piggott, Y. Zhang, Z. Saad, A. Khamis, M. Reinap, S. Duda, K. Solo, S. Yaacoub, H. J. Schünemann: “Physical distancing, face masks, and eye protection to prevent person-to-person transmission of SARS-CoV-2 and COVID-19: a systematic review and meta-analysis”, *The Lancet*, Vol.395, No.10242, pp.1973–1987 (2020-6)
- [103] S. E. Kimes, S. K. A. Robson: “The impact of restaurant table characteristics on meal duration and spending”, *Cornell Hotel and Restaurant Administration Quarterly*, Vol.45, No.4, pp.333–346 (2004-11)
- [104] A. Vidotto, K. N. Brown, J. C. Beck: “Managing restaurant tables using constraints”, *Knowledge-Based Systems*, Vol.20, No.2, pp.160–169 (2007-3)
- [105] T. Tanizaki, T. Shimmura: “Modeling and analysis method of restaurant service process”, *Procedia CIRP*, Vol.62, pp.84–89 (2017-1)
- [106] L. Bañón, C. Bañón: “Improving room carrying capacity within built environments in the context of COVID-19”, *Symmetry*, Vol.12, No.10, p.1683 (2020-10)
- [107] M. Salari, R. J. Milne, C. Delcea, L. Kattan, L.-A. Cotfas: “Social distancing in airplane seat assignments”, *Journal of Air Transport Management*, Vol.89, p.101915 (2020-10)
- [108] 小平 行秀: “LSIにおけるセル配置手法を用いた身体的距離を考慮した座席レイアウト手法”, 第192回システムとLSIの設計技術研究発表会, Vol.25, No.2020-SLDM-192, pp.1–5 (2020)
- [109] M. Hu, H. Lin, J. Wang, C. Xu, A. J. Tatem, B. Meng, X. Zhang, Y. Liu, P. Wang, G. Wu, H. Xie, S. Lai: “Risk of coronavirus disease 2019 transmission in train passengers: an epidemiological and modeling study”, *Clinical Infectious Diseases*, Vol.72, pp.604–610 (2021-2)
- [110] 佐藤 貴大, 円山 琢也: “スマホ・アプリ型回遊調査データによる熊本都心部回遊行動圏の分析”, 都市計画論文集, Vol.50, pp.345–351 (2015)
- [111] 湯本 耀大, 出水 瑛, 藤生 慎, 高山 純一: “スマートフォンアプリを活用した市民の移動軌跡データを用いた行動圏域分析—金沢市中心市街地を対象として—”, AI・データサイエンス論文集, Vol.2, pp.272–283 (2021)

参考文献

- [112] 佐藤 貴大, 円山 琢也: “カーネル密度推定法を応用したスマホ型回遊調査データの時空間分析”, 都市計画論文集, Vol.51, pp.192–199 (2016)
- [113] H. Kato: “Development of a spatio-temporal analysis method to support the prevention of COVID-19 infection: Space-time kernel density estimation using GPS location history data”, *Urban Informatics and Future Cities*, pp.51–67 (2021)
- [114] F. E. Rex, C. A. D. S. Borges, P. S. Kafer: “Spatial analysis of the COVID-19 distribution pattern in Sao Paulo State, Brazil”, *Ciencia and Saude Coletiva*, Vol.25, pp.3377–3384 (2020)
- [115] 国土地理院: “令和3年全国都道府県市区町村別面積調”. <https://www.gsi.go.jp/KOKUJYOHO/MENCHO/backnumber/GSI-menseki20211001.pdf> [accessed: 2021/12/2].
- [116] 総務省統計局: “人口推計”. <https://www.stat.go.jp/data/jinsui/index.html> [accessed: 2021/12/2].
- [117] 株式会社 Agoop: “流動人口データ”. <https://www.agoop.co.jp/service/dynamic-population-data/> [accessed: 2021/12/2].
- [118] C. M. Bishop: *Pattern recognition and machine learning*, 2nd ed., Springer (2006)
- [119] D. W. Scott: *Multivariate density estimation, theory, practice, and visualization*, 2nd edition, Wiley (2015)
- [120] J. S. Horne, E. O. Garton: “Likelihood cross-validation versus least squares cross-validation for choosing the smoothing parameter in kernel home-range analysis”, *Journal of Wildlife Management*, Vol.70, No.3, pp.641–648 (2006)
- [121] J. Ma, J. Theiler, S. Perkins: “Accurate on-line support vector regression”, *Neural Computation*, Vol.15, No.11, pp.2683–2703 (2003-11)

業績リスト

査読付き論文

- (1) Yohei Kakimoto, Yuto Omae, Jun Toyotani, and Hirotaka Takahashi. Fast screening framework for infection control scenario identification. *Mathematical Biosciences and Engineering*, Vol. 19, No. 12, pp. 12316–12333, 2022. [IF = 2.194]
- (2) Yohei Kakimoto and Yoichi Shimakawa. Rest-area location model for time-driven demands to the expend buffer time of freight vehicles. *International Journal of Innovative Computing, Information and Control*, Vol. 18, No. 1, pp.15–28, 2022.
- (3) 柿本陽平, 大前佑斗, 豊谷純. 千葉県習志野市における新型コロナウイルス感染予防対策のための人口密集エリアの推定と分類. 日本情報ディレクトリ学会誌, Vol. 20, No. 1, pp. 81–88, 2022.
- (4) Yohei Kakimoto, Yoichi Shimakawa, and Hirotaka Takahashi. Optimal location model of electric vehicle charging facility based on the flow-capturing location-allocation model —Case study by using the data of road network of Bangkok, Thailand. *Journal of Computations and Modelling*, Vol. 8, No. 2, pp. 111–136, 2018.
- (5) 柿本陽平, 高橋弘毅, 島川陽一. 制約充足問題を線形計画法で解く場合の制約条件の緩和とその評価. 日本経営工学会論文誌, Vol. 66, No. 4, pp. 348–354, 2016.