

Multi Agent Simulationによる複雑社会システムの 解析に関する研究

田中, 真樹

<https://hdl.handle.net/2324/7363862>

出版情報 : Kyushu University, 2024, 博士 (工学), 課程博士
バージョン :
権利関係 :



博 士 学 位 論 文

Multi Agent Simulation による
複雑社会システムの解析に関する研究

2024年10月

九州大学大学院 総合理工学府 総合理工学専攻
機械・システム理工学メジャー

田中 真樹

目次

第 1 章 序論	1
1.1 はじめに	1
1.2 感染症について	5
1.3 交通流について	8
1.4 論文構成	11
第 2 章 進化ゲーム理論の基礎, ワクチン接種ゲームの基礎, 交通流の基礎	18
2.1 進化ゲーム理論の基礎	18
2.1.1 ゲーム理論	18
2.1.2 ナッシュ均衡とパレート最適	19
2.1.3 2×2 ゲーム	20
2.1.3.1 調和ゲーム (Harmony game, HG)	21
2.1.3.2 鹿狩りゲーム (Stag hunt game, SH)	21
2.1.3.3 チキンゲーム (Chicken game, CH)	22
2.1.3.4 囚人のジレンマゲーム (Prisoner's dilemma, PD)	23
2.1.3.5 ギャンブル性ジレンマ D_g とリスク回避性ジレンマ D_r によるゲームクラスの分類	24
2.1.4 進化ゲーム理論	24
2.1.5 進化ダイナミクス	25
2.1.6 レプリケーターダイナミクス	27
2.1.7 多人数 2 戦略ゲームのレプリケーターダイナミクス	28
2.1.8 有限集団における 2 戦略ゲームの進化ゲームダイナミクス	29
2.2 複雑ネットワークとワクチン接種ゲームの基礎	33
2.2.1 複雑ネットワーク	33
2.2.2 ネットワークの特徴量	34
2.2.2.1 次数 (エッジ数)	34
2.2.2.2 次数相関	35
2.2.2.3 クラスター係数	35
2.2.2.4 平均ノード間距離	36
2.2.2.5 Barabási-Albert スケールフリー (BA-SF) モデル	36
2.2.3 ワクチン接種ゲーム	39
2.2.3.1 数理疫学	39
2.2.3.1.1 SIR モデル	39
2.2.3.1.2 感染症蔓延と基本生産数	40

2.2.3.1.3	最終感染者サイズ (Final Epidemic Size, <i>FES</i>) の導出	41
2.2.3.1.4	集団免疫獲得に至るワクチン接種率の目安	42
2.2.3.2	ネットワーク上のワクチン接種ゲームモデル	42
2.2.3.2.1	ネットワーク上における感染症の伝播	44
2.2.3.2.1.1	Gillespie アルゴリズム	44
2.2.3.2.1.2	疫学パラメータの設定	45
2.2.3.2.2	戦略適用方法	47
2.2.3.2.2.1	Individual-based risk assessment (IB-RA)	47
2.2.3.2.2.2	Strategy-based risk assessment (SB-RA)	47
2.2.3.2.2.3	Direct commitment (DC)	48
2.2.3.3	結果の評価に用いる指標	48
2.2.3.3.1	最終感染者サイズ (Final Epidemic Size, <i>FES</i>)	48
2.2.3.3.2	ワクチン接種率 (Vaccination Coverage, <i>VC</i>)	48
2.2.3.3.3	社会平均利得 (Social-Average Payoff, <i>SAP</i>)	49
2.3	交通流の基礎	50
2.3.1	交通流の基本的変数	50
2.3.1.1	平均速度, v	50
2.3.1.2	密度, k	50
2.3.1.3	交通量, Q	50
2.3.2	基本図から読み取ることができる交通流の特徴	51
2.3.3	時空間図	52
2.3.4	交通流のモデル化	53
2.3.5	追従モデル (Optimal Velocity (OV) モデル)	54
2.3.6	Cellular Automaton (CA) モデル	55
2.3.6.1	Rule184	56
2.3.6.2	Quick Start (QS) モデル	56
2.3.6.3	Slow Start (SIS) モデル	57
2.3.6.4	Revised Stochastic Nishinari Fukui Schadschneider (Revised S-NFS) モデル	58
2.3.7	アップデート方法	59
2.3.8	境界条件	60
第3章	ワクチン接種ゲームにおけるハブエージェントの戦略更新機構に関する研究	66
3.1	はじめに	66
3.2	モデルの概要	68
3.2.1	ワクチン接種ゲームの概要	68
3.2.2	戦略更新	69

3.2.3	MAS への導入	70
3.3	結果と考察.....	72
3.3.1	同じような感染リスクを持つ隣人を PW の対戦相手として優先的に選択する効果 72	
3.3.2	模倣の概念に従う戦略更新のための適切な情報	78
3.4	結論.....	81
第 4 章	感染流行を抑制するための先制的ワクチン接種公的補助スキームの最適社会設計 に関する研究.....	85
4.1	はじめに.....	85
4.2	モデルの概要.....	88
4.2.1	スケールフリー性を持つネットワーク上でのワクチン接種ゲーム	88
4.2.1.1	感染症蔓延シーズン.....	89
4.2.1.2	ワクチン接種キャンペーン	90
4.2.2	戦略更新	90
4.2.2.1	Individual-based risk assessment (IB-RA)	90
4.2.2.2	Strategy-based risk assessment (SB-RA)	91
4.2.2.3	Direct commitment (DC)	91
4.2.3	補助金政策	91
4.2.4	補助金のモデル化	92
4.2.5	MAS への導入	93
4.3	結果と考察.....	94
4.3.1	補助金なしの場合	94
4.3.2	異なる補助金政策の効果	95
4.3.3	ハブ優先政策と十分な補助金予算によるワクチン接種	99
4.3.4	低予算でのワクチン接種政策	100
4.3.5	ハブ優先政策の妥当性	101
4.3.6	最適な補助金政策が無駄な支出をどの程度削減できるか.....	103
4.4	結論.....	105
第 5 章	自動運転車両と人間運転車両混在系交通流の背後に潜在する社会ジレンマの解析 と自動運転システムの社会受容性に関する研究.....	109
5.1	はじめに.....	109
5.2	モデルの概要.....	111
5.2.1	人間が運転する車両	112
5.2.2	Adaptive Cruise Control (ACC) 車両.....	114
5.2.3	Cooperative Adaptive Cruise Control (CACC) 車両.....	115

5.2.4	混合流システム	116
5.3	数値シミュレーションの実装	117
5.4	結果と考察	118
5.5	結論	122
第 6 章	人間の刺激-反応機構を包含した新たな連続系自己駆動粒子モデルによる追従模型 の構築と交通流解析に関する研究	126
6.1	はじめに	126
6.2	導入	129
6.2.1	モデルの基本概念	129
6.2.2	使用する用語	129
6.2.3	本モデルの概要	131
6.3	連続系のモデル設計	133
6.3.1	速度差の認識	133
6.3.1.1	速度差の認識関数, f_v	133
6.3.1.2	速度差の認識確率, P_v	134
6.3.1.3	速度差の認識状態, I_v	135
6.3.2	車間距離差の認識	135
6.3.2.1	ペダルの踏みかえにかかる時間と速度の関係	135
6.3.2.2	3つの前方車両との車間距離	136
6.3.2.2.1	最小安全車間距離, $g_{closest}$	136
6.3.2.2.2	巡航車間距離, g_{cruise}	137
6.3.2.2.3	前方車両の影響を受ける最大車間距離, $g_{influenced}$	138
6.3.2.3	車間距離差の認識関数, f_g	138
6.3.2.4	車間距離差の認識確率, P_g	139
6.3.2.5	車間距離差の認識状態, I_g	139
6.3.3	目標速度	140
6.3.4	目標加速度	140
6.3.5	ペダルの踏みかえに必要な時間	141
6.3.6	基礎方程式	143
6.4	モデルの時間離散化	144
6.4.1	時間離散化	144
6.4.2	速度差の時間離散化による確立的認識	144
6.4.3	車間距離差の時間離散化による確率的認識	147
6.4.4	衝突回避機構	151
6.5	結果と考察	153

6.5.1	基本図の再現性	153
6.5.2	流れ場の特徴	156
6.5.3	局所的流れ場の再現性	162
6.6	結論	164
第 7 章	総括結論	168
謝辞		171

第1章 序論

1.1 はじめに

18 世紀半ばから 19 世紀にかけて発生した産業革命に端を発し、今日に至るまで、人類の科学力は目覚ましい発展を遂げている [1].

産業革命前の主だった移動・輸送手段は、船や馬車だったが、動力の発展によって、1830 年代には鉄道が普及したことで、大都市間をモノや人が大量かつ迅速に移動するようになった。この移動手段の発達は、モノや人に限らず、文化や技術の交流範囲を急速に拡大させたため、人類の科学力は大きく発展することとなった。

20 世紀に入ると、米国ではテキサス油田の発見などにより、今日にも通ずるガソリンエンジンを内燃機関に持つ自動車が普及した。これにより、鉄道が敷設されていない地域からでも、誰でも簡単に都市に向けて移動できるようになり、モノや人の行き来は、より活発になった。中でも、大陸間の高速移動に大きく寄与した飛行機の発明は偉大だ。世界の航空旅客数は新型コロナウイルス感染症（COVID-19）が流行した 2019 年までは年々増加傾向で、一度は新型コロナウイルス感染症の流行によって利用者が減少したが、2022 年には再び増加傾向に転じており、今後も旅客数は増加していくものと思われる。航空貨物輸送は、旅客輸送よりも燃料価格の影響を受けやすいため、旅客数ほどではないにしても、増加傾向を示しており、今後も飛行機を利用したモノと人の移動は盛んに行われるものと思われる [2].

そのほかにも、我々の生活をより豊かにしたものとして、ここ数年で爆発的に普及したスマートフォンによって身近なものとなった、インターネットがある。このインターネットは、世界中の人たちと簡単に繋がることができるため、文化や技術の交流をより活発なものにしている。近年では、Internet of Things (IoT) が徐々に普及し始めたことで、例えば、外出先からインターネットを介して自宅のエアコンの電源を入れ、温度を設定できるなど、我々の生活は、より便利で豊かなものになってきている。近年の IoT は、普段の生活だけに限らず、モノの移動にかかわる物流業界において、Logistics 4.0 [1]と呼ばれる革新を引き起こしつつあり、倉庫ロボットや自動運転などの普及による省人化、サプライチェーン全体で物流機能が繋がることでの標準化などのイノベーションが起きている。そのほかにも、人工知能（Artificial Intelligence, AI）の近年の発達スピードは目覚ましいもので、学習、創作、画像認識などの分野で活躍しており、企業の業務や公共サービスの一部に使用されるなど、我々の生活に着実に浸透しつつある。

以上のように、交通機関の発達により、移動にかかる時間の削減による時間距離の削減、インターネットの普及による情報伝達速度の飛躍的な向上、AI の発達などにより、経済はより発展し、我々の生活はどんどん豊かで便利なものになっている。

しかし、産業革命以降の科学力の発展はなにも恩恵のみを与えたわけではない。近年、ニュ

ースなどでもよく耳にする、地球温暖化や海水温上昇、異常気象などを含めた環境汚染の問題がある。これら多くの問題に共通するのは、人間の経済活動に伴う CO₂ の排出によるものが原因と考えられている [3]、という点である。日本における CO₂ 排出の多くは、内燃機関を持つ車や火力発電などの化石燃料の燃焼からである。我々の身近なものとしては、車が例に挙げられるが、2035 年までに EU における新車市場での内燃機関車の発売を禁止する計画が発表されたことは記憶に新しい。また、日本でも EV 車やハイブリッド車などが相次いで開発、発売されており、大手運送会社などでも電気自動車の導入が進むなど、確実に内燃機関のみで走行する車は減ってきている。そのほか、エネルギー問題では、2011 年に発生した東日本大震災以降、原子力発電所の危険性が重視され、従来の火力発電に頼らざるを得なくなっていたが、2022 年から現在まで続いているロシアによるウクライナへの軍事侵攻によって、世界のエネルギー事情は一変し、日本でも再生可能エネルギーへのシフトがより盛んに行われるようになってきている。

これらの技術革新は大変素晴らしいことだが、地球温暖化や異常気象などを食い止めるには至っておらず、せいぜい進行を遅らせる程度のことである。また、再生可能エネルギーの一つに太陽光発電システムがあるが、太陽光発電は太陽光が直接当たらなければならないため、広大な面積を必要とする。そのため、近年では、大規模な山の切り開きによる設置や、釧路湿原への設置などが問題となっており、設置に伴う環境破壊問題が生じている。

また、先にも述べたが、産業革命以降、車や飛行機といった交通手段の発達に伴い、国をまたいで人の移動が活発になった。これらの移動手段の発達は、経済活動をより大規模なものとした一方で、2019 年の暮れから現在まで発生している新型コロナウイルス感染症の世界的大流行の一因になっている。この大流行に対し、多くの国で経済活動を停止して人流を減らすことでパンデミックを抑えることを余儀なくされた。後にワクチンが開発され、徐々に経済活動を再開させたが、現在に至るまで何度も大流行を起こしている。

日本においては、政府から新型コロナウイルス感染症のワクチン接種券が配布され、1 回目と 2 回目のワクチン接種では多くの国民が接種を行った（全国民のうち、およそ 80% [4]）。3 回目も接種券が配布されたが、接種率は 67.1% [4]と低くなった。3 回目の接種率が低くなった要因の一つとして、1 回目と 2 回目のワクチン接種率が高かったため、そこまで流行せず、罹患しなかった人も多かった [5]ことから、発熱や倦怠感などの副作用が人によっては強く出るワクチン接種を 3 回目では回避したのではないかと推察している。

なぜ、環境問題を解決するために太陽光発電システムを設置するのに、その設置に伴う環境破壊は気にしないのか。また、当時は致死率、重症化リスクが決して低くなかった新型コロナウイルス感染症のワクチン接種を控える、などといった行動を我々はとるのだろうか。これらの問題を表面的にみると、合理的な行動とはかけ離れた行動をとっているように見える。しかし、ことはそう単純なものではない。これらの行動の裏には、長期的な利益や、目先の利益、自信を取り巻く環境や社会情勢、周りの人間の行動などが、複雑に絡み合っていて起きている

事象である。すなわち、我々は人間 - 環境 - 社会の相互作用のもと、生活しているといえる [6]。そのため、このような、一見矛盾したような行動をとる理由を解明しようとする、この複雑なシステムを再現するほかない。

この複雑なシステムの再現の手法の一つに **Multi Agent Simulation** (以下, **MAS**) がある。名前の通り、複数のエージェントを一つの系の中に配置したシミュレーションである。図 1-1 に示す概念図のように、このエージェントは何かしらのルールに従って行動する一つの単位のこと、社会的な組織や個人、環境などが割り当てられる。さらに、この各エージェントは、ほかのエージェントと相互に影響し合うため、複雑なシステムを再現することができるシミュレーションとなっている。




図 1-1 Multi Agent Simulation の概念図。

MAS を有名にしたシミュレーションの一つに、**Boids** [7]と呼ばれる人工生命シミュレーションがある。これは、各エージェントを鳥や魚とし、リーダーがいないのに同じ方向に飛ぶ鳥や魚の群れなどの群衆行動を、各エージェントに簡単なルールを与えただけで再現したモデルである。ルールには、互いの衝突を避ける分離、周囲と同じ方向を向く整列、離れすぎないように結合するというものがあり、これら単純な 3 つのルールのみで構成されている。各エージェントが、このような簡単なルールに従うだけで、群れ全体の複雑な動きが自然に発生することを示したシミュレーションである。

Boids ではエージェント間に明示的なネットワークはなかったが、各エージェントを人とし、それぞれのエージェントにネットワークによる関係を与えることで、複雑な人間社会も再現することができる。さらに、各エージェントのルールに後述するゲーム理論を組み合わせることで、周りの人間の行動がどのように影響し、社会全体としてどのような結果になるのかも、シミュレーションできる。まさしく、新型コロナウイルス感染症のワクチン接種行動など

を再現することが可能で, Bauch ら [8]や Fu ら [9]によって提唱されたモデルが基礎となり, 多くの研究が行われている. 再現できるのは動物の群衆行動のみではない. 各エージェントを車とみなし, 各エージェントに加速や減速などのルールを与えることで, 自然発生する渋滞の再現や, 渋滞の解消も再現できる [10].

このように, MAS は人間社会の複雑な社会システムを再現するのに適している. 新型コロナウイルスとの共生は喫緊の課題で, ワクチン接種による予防やマスクの着用などが求められるが, 先にも述べたように, 3 回目以降のワクチン接種率は低下し続けており, 「コロナ疲れ」という言葉がニュースでも取り上げられるくらい, 時間経過とともに人々の感染症蔓延予防に対する態度は非協力的になっていった. さらに, 感染症蔓延予防の観点から移動手段を電車やバスから自家用車に変更した人も多く, 渋滞も問題になっている. また, ニュースでも物流業界の残業時間の上限が適用された, いわゆる「2024 年問題」をよく耳にするようになり, もともと耳にしていた, トラックドライバーの人手不足などの問題に拍車をかけている. この問題を解決する案の一つとして, 自動運転の議論が活発化してきている.

新型コロナウイルスとの共生では, ワクチン接種による予防が一番効果的で, いかに接種率を高めるかが重要となってくる. また, 感染拡大予防のために自家用車を利用することは大きな効果があるが, 渋滞を招く一因となっているが, 産業革命以降の経済の発展を支えているのは物流網であり, 自動運転車の導入などによる渋滞緩和は重大な課題といえる.

以上より, 本論ではワクチン接種や自動運転車の導入や渋滞緩和などの社会的問題に対し, Multi Agent Simulation を使って, モデルの構築, 解析を行う.

1.2 感染症について

2019 年の暮れから何度も大流行している新型コロナウイルス感染症は記憶に新しく、今もなお猛威を振るっていることから、再度大流行が起こることを防ぐことは、社会全体の使命といっても過言ではない。新型コロナウイルスに限らず、インフルエンザなどでもそうだが、予防が可能となるワクチンの開発、感染経路の特定など、医学的、免疫学的な知見は極めて重要なことである。しかし、今回の新型コロナウイルス感染症の蔓延で改めて実感したが、感染症の蔓延を完全に防ぐのは非常に困難なことで、感染拡大を完全に抑え込むにはモノと人の移動を完全に停止することでしか実現できず、これは経済活動の停止を意味することから、現実的な対応ではない。ある程度感染症が蔓延するのは受け入れつつ、それ以上の感染症拡大を防ぐことが必要となる。感染症拡大を防ぐための方法としては、感染者の隔離、予防接種の実行などが挙げられるが、実際に感染症蔓延の範囲が拡大している最中に実証しても遅い。感染症蔓延が始まる前にシミュレーションし、有効な手段を確立、評価しておく必要がある。そのためには、感染の発生から蔓延、収束までの数理モデルを組み立て、動的かつ定量的な定式化が必要不可欠となる。

新型コロナウイルス感染症に対し、先制的ワクチン接種の接種率が高いと感染症の蔓延を抑えることに有効だということが、接種率が高かった 2019 年までの感染者数のデータ [4, 5] から明らかである。これはなにも新型コロナウイルス感染症に対してだけいえることではない。インフルエンザのような、まだ感染症に対し免疫を獲得していない感受性の人たちが、免疫を獲得すると感染しない、もしくは感染しにくくなるような感染症に対して、先制的ワクチン接種は非常に有効な手段で、感染症の蔓延を防ぐだけでなく、新型コロナウイルス感染症のワクチン接種でもよく耳にしたように、重症化や死亡率を低減させる最も有効な手段として知られている [11]。しかし、新型コロナウイルス感染症のワクチン接種率が 3 回目以降減少していることからわかるように、有効な手段だとわかっていても接種が進まず、何度も感染症の蔓延が起きている。これは、ワクチン接種を行うかどうか個人に委ねられており、感染症を発症した際の重症化、身体的・精神的苦痛、休むことによる経済的損失などのリスクや、ワクチン接種にかかる費用や時間、副作用などのコスト、周りの人間がワクチン接種を行ったかどうか左右される [12–14] ため、ワクチン接種率が高くないからだ。そのため、先制的ワクチン接種によって感染症を完全に根絶させたのは天然痘のみとなっている。

なぜ根絶に至ったのは天然痘のみとなっているのだろうか。この理由の一つにワクチン接種に伴うジレンマがある。今回の新型コロナウイルス感染症蔓延に際して、大多数の人は必要最低限の外出により、不必要な他人との接触を避けただろう。このような状況下で、常に接触する人たちがすでにワクチン接種を行っている場合、自身が感染するルート上にいる人たちがみなワクチン接種を行っているのだから、自身の感染率は限りなく 0 に近づく。今挙げた例は極端な例だが、実際に集団のワクチン接種率がある閾値を超えると、集団免疫を獲得

するに至り、この集団に属するワクチン未接種者の感染率は非常に低くなる [11, 15] ことがわかっていて、今回の新型コロナウイルス感染症のワクチン接種では、人によっては副作用が強く出るため、周りの人間がワクチン接種を行っており免疫を獲得しているような状況下では、ワクチン接種を行わずに乗り切ろうとした人もいたことだろう。このように、集団免疫には公共財的性質があるといえ、この公共財がもたらす利益にただ乗りしようとする人たちが出てくる。これをフリーライダー問題 [16–18] といい、多くの人がこの集団免疫にあやかろうとする可能性を示唆する既往研究 [19] もある。これらが意味するのは、図 1-2 に示す概念図のように、ワクチン接種者が増加し、集団免疫を獲得するに至ると、この集団免疫へただ乗りしようとするインセンティブが働き、ワクチン接種を行っていない人が増える。結果、集団免疫が崩壊し、この人たちが感染することによって再び感染症が蔓延することとなる、ということである。これがワクチン接種に伴うジレンマである。このように、集団免疫を獲得するに至る必要なワクチン接種者数に対し、個人の利得を追求した際のワクチン接種者数には乖離が生じる [8, 20–23] ため、ワクチン接種率は高くない。




図 1-2 ワクチン接種に伴うジレンマの概念図。

もちろん、ワクチン接種に伴うジレンマのみが、ワクチン接種率が高くない要因ではなく、ワクチンや感染症に対する知識不足、誤った認識による感染リスクの過小評価やワクチン接種コストの過大評価なども、ワクチン接種率を引き下げる原因となっている [24]。しかし、ワクチン接種率を高める施策やワクチン接種率の予測などには、それ以上に、このジレンマ構造を組み込んだモデルの構築が必要不可欠である。

このジレンマ構造を再現するには、フリーライダーの特徴を再現しなければならない。フリーライダーは、集団免疫にただ乗りしようとする、すなわち、自身の利得を最大化しようとする特徴がある。このような特徴を持つワクチン接種に伴うジレンマ構造を再現しようと、

ゲーム理論を用いた研究が多く行われている [8, 9, 23, 25–33]. Bauch らに代表される初期のワクチン接種行動のゲーム理論的解析では、個人は自身の感染確率について完全に把握しており、その情報を基に行動する静的ゲームが想定されていた [8, 23]. しかし、これは現実とはかけ離れており、我々は自身の感染確率を把握していない. また、ワクチン接種を行うか否かの戦略の決定方法も、フリーライドに成功した、ワクチン接種を行ったおかげで感染症発症を防げたなどの、周りの成功したようにみえる戦略を模倣（学習）する特徴も取り入れる必要がある [34–36].

これらの研究により、例えば Bauch [25]は個人の模倣行動によって周期的な感染症蔓延が生じることを見出し、Vardavas ら [28–30]はインフルエンザ流行に対し、個人にインセンティブを与えない限り、深刻な感染症蔓延を防ぐに足るワクチン接種率に達しないことを示すなど、重要な発見がなされている.

しかし、これらの研究のすべてで集団は一様混合を仮定しており、他人との接触、情報伝達に空間構造を持っていなかった. 現実社会では、明らかに人との繋がりや情報伝達には空間構造があり、感染は隣人から起こるもので、空間構造を持つことが感染症の数理モデルをより現実近づけるのに重要な要素であることが示されている [37].

以上の点を踏まえ、Fu ら [9]は隣人から感染する、すなわちネットワーク上で感染症が伝播する数理モデルに対し、ワクチン接種により完全免疫を獲得する戦略と、非接種による一切の免疫を獲得しない戦略を持つモデルを構築することで、個人の模倣行動によって集団が獲得するワクチン接種率が、ワクチン接種コストに敏感に依存することを見出した.

本研究ではFu らが構築したモデルを基に、いかにワクチン接種率を高めるか、また、現実に近い模倣行動とはどのようなもので、個人の模倣行動が集団にどのような作用を与えるかを、MAS を用いて解析、研究を行う.

1.3 交通流について

生活必需品の購入に際して、インターネットショッピングが普及しつつあるが、店に向いて購入する方法の方が、品定めができ、現物がある場所で手に入るなどということもあり、一般的な購入方法だろう。この時、大量に購入するとなると、普段は自転車や徒歩で買い物に向いている人も、タクシーやバス、自家用車や知人の車に同乗させてもらうなど、車両を利用することは少なくない。今挙げた一例のように、今や、車は生活になくてはならない移動手段で、その証拠に日本の一世帯当たりの保有自家用車数は1台を超えている [38]。

また、日本は国土に対し人が住める場所の面積が狭いこともあり、人口が都市部に集中しているため、都市部では頻繁に渋滞が起きる。国土交通省が出している令和3年度の旅行速度整理表 [39]によると、通勤時間にあたる朝夕の全国の中心部における一般道の平均速度は20[km/h]未満となっている。この速度は、電動アシスト自転車普及しつつある自転車移動の方が、場合によっては速いかもしれない速度である。また、雨の日になると普段は車を使わない人たちも車を利用することもあり、より渋滞が発生しやすくなり、平均速度も落ちる。また、新型コロナウイルス感染症の蔓延に伴い、自家用車による移動は、必要最低限の他人との接触ですむため、予防の観点から非常に有用な移動手段であり、利用者は年々増加傾向だ。このように、車社会と呼ばれ、利用者も増え続けている今日では、移動にかかる時間を短くすることは、CO₂排出量削減においても有効なこともあり、社会全体の課題といえる。

車社会における移動時間（運転時間）の長さは、現代社会におけるストレスの一端を担っており、最近よくニュースでも耳にする「あおり運転」は、される側にとっては、その最たる例ともいえる。あおり運転は別にしても、渋滞の中を運転する際のストレスは相当なもので、特に通勤のように、到着時刻が定められているような運転では、通常の運転時に比べ、間に合うかどうかの不安や焦りなど、かなりのストレスがかかる。この運転にかかわるストレスを軽減する手法の一つに、自動運転技術がある。

現在、日本国内で許可されている自動運転レベルは4で、2023年4月1日に施工された改正道路交通法により、特定条件下における完全自動運転（自動運転システムに対し、ドライバーの介入が求められない）が開始された [40]。物流業界では残業時間が規制された、いわゆる「2024年問題」や労働者不足があり、レベル5となる、どの道路でも人が同乗する必要がない完全自動運転の早期実現が望まれている。

このように、自動運転社会を目指した技術開発など、交通流を巡る社会的関心が高まっており、自動運転システム開発において、コンピューター上で現実の交通流を再現することは重要な意味を持ち、車両流動は多数の相互作用する自己駆動粒子の動力学としての側面を有するため、統計物理学的な関心も高く、現実の交通流をよく再現するモデル化が大きな研究テーマとなっている。

交通流はもともと20世紀半ばには、流体力学に支配されると考えられていた [41–44]。流体力学には、ある空間の質量保存によって方程式をたてる Eulerian-scope、もしくは巨視的な

視点と、個々の粒子を追いかけて運動方程式をたてる **Lagrangian-scope**、もしくは微視的な視点の 2 つがある。交通流にも同様に 2 つの視点がある。巨視的な視点によるモデル（マクロモデル）では、交通流を連続体としてみなし、1 次元流体として扱うモデルであり、微視的な視点によるモデル（ミクロモデル）では、交通流を多くの自己駆動粒子の流れとみなし、各車両の前進運動を **Newton** の第二法則に基づいて、個別に運動方程式をたてるモデルであると既往研究 [42–44] は紹介している。完璧な交通流の再現に至ってはいないが、交通流を上記のマクロの視点で捉えたモデルでは、修正 **KdV** 方程式に沿って適切にモデル化することで、数学的解析手法が有効であることを示している [45–49]。一方で、ミクロモデルの一つである、**MAS** の概念を使用した **Cellular Automaton (CA)** モデル [50] によって、各車両それぞれに、ルールを与えたモデルが、実際の交通流をよりよく再現することが明らかになった。CA モデルは各車両を上記の自己駆動粒子として扱い、連続体ではなく離散的な粒子として扱うミクロな視点にたったモデルであり、時間と空間（道路）の両方の変数が離散化されている。CA モデルの特徴は、各車両それぞれにルールを与えることで交通流を再現することである。このルールには、加速、前方のさらに先の状態を見通す **Quick Start**、停止した状態からの発進の遅れを再現する **Slow Start**、ランダムブレーキなどが提唱され、改良が加えられてきた [51–56]。これらのルールに基づいたモデルの再現性は実際の交通流で観察された実測データと比較され、比較的再現性が高いとされている [57, 58]。また、これらのルールで確立されたモデルを基に、車線の合流や車線変更等の特殊な交通流を再現したモデルを構築し、交通流の背後に隠れたジレンマ構造を解析する研究 [59–66] が行われた。

先にも述べたように、自動運転技術の確立は急務となっている。しかし、自動運転で最も優先すべきは安全であるため、人間が運転する車両に対し、速度が制限される可能性がある。すべての車両が同時に完全自動運転になるわけではないので、必ず人間が運転する車両と混在する期間が出てくる。このような条件下では、自身で運転する方が早く目的地にたどり着ける可能性があるため、完全自動運転の普及が進まない可能性がある。そのため、本研究では、**MAS** を使用した **CA** を用いて、完全自動運転を導入した際のモデルの構築と、導入に関するジレンマ構造の解析を行うことを一つの研究テーマとする。

また、CA モデルの妥当性の検証は通常、交通流の特徴を顕著にする基本図（後述）の平均化された指標によって判断しているため、基本図では再現性が高いが、アニメーション等によって実際の流れを可視化すると、現実の交通流と乖離する可能性がある。例えば、**Quick Start** 効果を考慮した CA モデルでは、車両が前方車両にギャップなしで追従する様子が見られ、これは非現実的である。CA モデルにも問題があり、このような問題は CA モデルが時間と空間の両方を完全に離散化したモデルであることに起因する可能性がある。なぜなら、時間と空間の両方を離散化することとは、各時刻で離散化された空間（道路）に存在しなければならないため、加速度と速度が段階的な値しか取れなくなり、細かな加減速の調節が不可能になるからである。

そこで、本研究では、より解像度の高いモデルの構築をもう一つのテーマに掲げ、マクロモデルよりも再現性の高いミクロな視点から、MAS を用いた新たな時空間連続系のモデルの確立を目指す。

1.4 論文構成

本論文の構成は図 1-3 に示す通りである。本論文は序論（第 1 章）、進化ゲーム理論の基礎、ワクチン接種ゲームの基礎、交通流の基礎（第 2 章）、ワクチン接種ゲームに関する研究（第 3 章と第 4 章）、交通流モデルに関する研究（第 5 章と第 6 章）、総括結論（第 7 章）で構成される。




図 1-3 本論文の構成。

第 1 章の序論では、現在社会の複雑な社会システムについて言及し、MAS の有用性を示し、現在社会が抱える問題に焦点をあて、その問題に取り組んできた既往研究を示すことで、本研究の位置付けと意義を整理した。

第 2 章では、本研究で使用する進化ゲーム理論の基礎、ワクチン接種ゲームの基礎、交通流の基礎について整理し、理解を深める。

第 3 章では、ワクチン接種ゲームについて、医者や学校の先生のように多くの人とかかわりを持つハブエージェントに関して、ワクチン接種を行うかどうかの戦略をどのように更新しているかについて考察する。また、ハブエージェントの振る舞いが、そこまで多くの人とかかわりを持たないエージェントの戦略更新に、どのような影響を与え、社会全体のワクチン接種率がどう変化するかについて、解析、考察する。

第 4 章では、ワクチン接種公的補助スキーム（割引券や無料券など）によるワクチン接種率向上を目指す上で、公的補助スキームが戦略更新に与える影響を考察し、最適な公的補助

スキームについて解析，考察する．

第 5 章では，完全自動運転車両と人間運転車両混在系の多車線系の交通流モデルを構築し，完全自動運転車両導入の背後に潜むジレンマ構造について，ゲーム理論を用いて解析を行う．

第 6 章では，超離散化モデルが持つ弱点を克服するべく，時空間ともに連続な交通流モデルの理論を構築し，MAS を用いてシミュレーションを行い，実測データとの比較を行うことで，モデルの妥当性を評価する．

第 7 章では，第 3 章から第 6 章までで得られた結果について結論を整理し，第 1 章で述べた本研究の意義に対する評価と展望について言及する．

参考文献

- [1] 1 世界における多様なイノベーションの歴史,
<https://www.mlit.go.jp/hakusyo/mlit/h28/hakusho/h29/html/n1131000.html>.
- [2] 航空：航空輸送の現状 - 国土交通省, https://www.mlit.go.jp/koku/koku_tk1_000013.html.
- [3] J. Hansen, M. Sato, R. Ruedy, A. Lacis, and V. Oinas, *Global Warming in the Twenty-First Century: An Alternative Scenario*, Proc Natl Acad Sci U S A **97**, 9875 (2000).
- [4] 日本国内のワクチン接種状況 オミクロン株対応ワクチンの接種率 / NHK,
<https://www3.nhk.or.jp/news/special/coronavirus/vaccine/progress/>.
- [5] 新型コロナウイルス 日本国内の感染者数・死者数・重症者数データ / NHK特設サイト,
<https://www3.nhk.or.jp/news/special/coronavirus/data-all/>.
- [6] 谷本潤, 谷本教授の努力すれば誰にでもわかる環境システムの数理解析基礎, 110 (2012).
- [7] C. W. Reynolds, *Flocks, Herds and Schools: A Distributed Behavioral Model*, ACM SIGGRAPH Computer Graphics **21**, 25 (1987).
- [8] C. T. Bauch, A. P. Galvani, and D. J. D. Earn, *Group Interest versus Self-Interest in Smallpox Vaccination Policy*, Proc Natl Acad Sci U S A **100**, 10564 (2003).
- [9] F. Fu, D. I. Rosenbloom, L. Wang, and M. A. Nowak, *Imitation Dynamics of Vaccination Behaviour on Social Networks*, Proceedings of the Royal Society B: Biological Sciences **278**, 42 (2011).
- [10] B. S. Kerner, *The Physics of Traffic*, (2004).
- [11] R. M. Anderson, R. M. May, and I. College, *Infectious Diseases of Humans : Dynamics and Control* (Oxford University Press, 1991).
- [12] G. B. Chapman and E. J. Coups, *Predictors of Influenza Vaccine Acceptance among Healthy Adults*, Prev Med (Baltim) **29**, 249 (1999).
- [13] G. B. Chapman and E. J. Coups, *Emotions and Preventive Health Behavior: Worry, Regret, and Influenza Vaccination*, Health Psychol **25**, 82 (2006).
- [14] S. Basu, G. B. Chapman, and A. P. Galvani, *Integrating Epidemiology, Psychology, and Economics to Achieve HPV Vaccination Targets*, Proc Natl Acad Sci U S A **105**, 19018 (2008).
- [15] M. Brisson and W. J. Edmunds, *Economic Evaluation of Vaccination Programs: The Impact of Herd-Immunity*, Med Decis Making **23**, 76 (2003).
- [16] C. B. Hagan, *The Logic of Collective Action: Public Goods and the Theory of Groups*, Vol. 60 (Cambridge University Press, 1966).
- [17] R. Axelrod, *An Evolutionary Approach to Norms*, American Political Science Review **80**, 1095 (1986).
- [18] T. Yamagishi, *The Provision of a Sanctioning System as a Public Good*, J Pers Soc Psychol **51**, 110 (1986).

- [19] D. A. Asch, J. Baron, J. C. Hershey, H. Kunreuther, J. Meszaros, I. Ritov, and M. Spranca, *Omission Bias and Pertussis Vaccination*, *Med Decis Making* **14**, 118 (1994).
- [20] Cullen. J. and J. P. West, *The Economics of Health: An Introduction* (Martin Robertson , Oxford, 1979).
- [21] P. E. M. Fine and J. A. Clarkson, *Individual versus Public Priorities in the Determination of Optimal Vaccination Policies*, *Am J Epidemiol* **124**, 1012 (1986).
- [22] P.-Y. Geoffard and T. Philipson, *Disease Eradication: Private versus Public Vaccination*, *American Economic Review* **87**, 222 (1997).
- [23] C. T. Bauch and D. J. D. Earn, *Vaccination and the Theory of Games*, *Proc Natl Acad Sci U S A* **101**, 13391 (2004).
- [24] V. A. A. Jansen, N. Stollenwerk, H. J. Jensen, M. E. Ramsay, W. J. Edmunds, and C. J. Rhodes, *Measles Outbreaks in a Population with Declining Vaccine Uptake*, *Science* (1979) **301**, 804 (2003).
- [25] C. T. Bauch, *Imitation Dynamics Predict Vaccinating Behaviour*, *Proceedings of the Royal Society B: Biological Sciences* **272**, 1669 (2005).
- [26] T. C. Reluga, C. T. Bauch, and A. P. Galvani, *Evolving Public Perceptions and Stability in Vaccine Uptake*, *Math Biosci* **204**, 185 (2006).
- [27] A. P. Galvani, T. C. Reluga, and G. B. Chapman, *Long-Standing Influenza Vaccination Policy Is in Accord with Individual Self-Interest but Not with the Utilitarian Optimum*, *Proc Natl Acad Sci U S A* **104**, 5692 (2007).
- [28] R. Vardavas, R. Breban, and S. Blower, *Can Influenza Epidemics Be Prevented by Voluntary Vaccination?*, *PLoS Comput Biol* **3**, e85 (2007).
- [29] R. Breban, R. Vardavas, and S. Blower, *Mean-Field Analysis of an Inductive Reasoning Game: Application to Influenza Vaccination*, *Phys Rev E Stat Nonlin Soft Matter Phys* **76**, 031127 (2007).
- [30] R. Breban, *Health Newscasts for Increasing Influenza Vaccination Coverage: An Inductive Reasoning Game Approach*, *PLoS One* **6**, e28300 (2011).
- [31] C. T. Bauch and S. Bhattacharyya, *Evolutionary Game Theory and Social Learning Can Determine How Vaccine Scares Unfold*, *PLoS Comput Biol* **8**, e1002452 (2012).
- [32] M. L. Ndeffo Mbah, J. Liu, C. T. Bauch, Y. I. Tekel, J. Medlock, L. A. Meyers, and A. P. Galvani, *The Impact of Imitation on Vaccination Behavior in Social Contact Networks*, *PLoS Comput Biol* **8**, e1002469 (2012).
- [33] H. Zhang, F. Fu, W. Zhang, and B. Wang, *Rational Behavior Is a ‘Double-Edged Sword’ When Considering Voluntary Vaccination*, *Physica A: Statistical Mechanics and Its Applications* **391**, 4807 (2012).
- [34] D. Helbing, *A Mathematical Model for Behavioral Changes by Pair Interactions and Its Relation*

to Game Theory (Springer, Berlin, 1992).

- [35] J. Björnerstedt and J. W. Weibull, *Nash Equilibrium and Evolution by Imitation* (MacMillan, New York, 1996).
- [36] J. Hofbauer and K. Sigmund, *Evolutionary Games and Population Dynamics*, Evolutionary Games and Population Dynamics (1998).
- [37] K. Rock, S. Brand, J. Moir, and M. J. Keeling, *Dynamics of Infectious Diseases*, Reports on Progress in Physics **77**, 026602 (2014).
- [38] 1 世帯当たり1.032台に — 自家用乗用車(登録車と軽自動車)の世帯当たり普及台数—, <https://www.airia.or.jp/publish/file/r5c6pv00000104ju-att/kenbetsu2022.pdf>.
- [39] 令和3年度全国道路・街路交通情勢調査 一般交通量調査 集計結果整理表 表5 旅行速度整理表, <https://www.mlit.go.jp/road/census/r3/data/pdf/syuuukei05.pdf>.
- [40] 多田善隆, 自動運転の実現に向けた取り組みについて, <https://www.mlit.go.jp/koku/content/001609155.pdf>.
- [41] R. Haberman, *Mechanical Vibrations, Population Dynamics, and Traffic Flow*, Society for Industrial and Applied Mathematics (Prentice-Hall (New Jersey), 1977).
- [42] B. S. Kerner, *Introduction to Modern Traffic Flow Theory and Control: The Long Road to Three-Phase Traffic Theory* (Springer: Berlin Heidelberg, Berlin Heidelberg, 2009).
- [43] J. Tanimoto, *Fundamentals of Evolutionary Game Theory and Its Applications*, Vol. 6 (Springer: Tokyo Japan, 2015).
- [44] J. Tanimoto, *Evolutionary Games with Sociophysics: Analysis of Traffic Flow and Epidemics*, Vol. 17 (Springer, Singapore, 2018).
- [45] L. Michael, James and W. Gerald, Beresford, *On Kinematic Waves II. A Theory of Traffic Flow on Long Crowded Roads*, Proc R Soc Lond A Math Phys Sci **229**, 317 (1955).
- [46] T. Musha and H. Higuchi, *Traffic Current Fluctuation and the Burgers Equation*, Japanese Journal of Applied Physics, Part 1: Regular Papers and Short Notes and Review Papers **17**, 811 (1978).
- [47] B. S. Kerner and P. Konhäuser, *Cluster Effect in Initially Homogeneous Traffic Flow*, Phys Rev E **48**, (1993).
- [48] T. S. Komatsu and S. I. Sasa, *Kink Soliton Characterizing Traffic Congestion*, Phys Rev E **52**, 5574 (1995).
- [49] T. Nagatani, *Thermodynamic Theory for the Jamming Transition in Traffic Flow*, Phys Rev E Stat Phys Plasmas Fluids Relat Interdiscip Topics **58**, 4271 (1998).
- [50] K. Nagel and M. Schreckenberg, *A Cellular Automaton Model for Freeway Traffic*, Journal de Physique I **2**, 2221 (1992).
- [51] M. Fukui and Y. Ishibashi, *Traffic Flow in 1D Cellular Automaton Model Including Cars Moving*

- with High Speed*, J Physical Soc Japan **65**, 1868 (1996).
- [52] R. Barlovic, L. Santen, A. Schadschneider, and M. Schreckenberg, *Metastable States in Cellular Automata for Traffic Flow*, European Physical Journal B **5**, 793 (1998).
 - [53] K. Nishinari and D. Takahashi, *Multi-Value Cellular Automaton Models and Metastable States in a Congested Phase*, J Phys A Math Gen **33**, 7709 (2000).
 - [54] K. Nishinari, M. Fukui, and A. Schadschneider, *A Stochastic Cellular Automaton Model for Traffic Flow with Multiple Metastable States*, J Phys A Math Gen **37**, 3101 (2004).
 - [55] S. Sakai, K. Nishinari, and S. Iida, *A New Stochastic Cellular Automaton Model on Traffic Flow and Its Jamming Phase Transition*, J Phys A Math Gen **39**, 15327 (2006).
 - [56] S. Kokubo, J. Tanimoto, and A. Hagishima, *A New Cellular Automata Model Including a Decelerating Damping Effect to Reproduce Kerner's Three-Phase Theory*, Physica A: Statistical Mechanics and Its Applications **390**, 561 (2011).
 - [57] J. Tanimoto, T. Fujiki, S. Kukida, N. Ikegaya, and A. Hagishima, *Acquisition of the Field Measurement Data Relating to Lane Change Actions*, International Journal of Modern Physics C **26**, 1 (2015).
 - [58] E. Fukuda, J. Tanimoto, Y. Iwamura, K. Nakamura, and A. Mitsuhiro, *Field Measurement Analysis to Validate Lane-Changing Behavior in a Cellular Automaton Model*, Phys Rev E **94**, 052209 (2016).
 - [59] A. Yamauchi, J. Tanimoto, A. Hagishima, and H. Sagara, *Dilemma Game Structure Observed in Traffic Flow at a 2-to-1 Lane Junction*, Phys Rev E Stat Nonlin Soft Matter Phys **79**, 036104 (2009).
 - [60] M. Nakata, A. Yamauchi, J. Tanimoto, and A. Hagishima, *Dilemma Game Structure Hidden in Traffic Flow at a Bottleneck Due to a 2 into 1 Lane Junction*, Physica A: Statistical Mechanics and Its Applications **389**, 5353 (2010).
 - [61] S. Kukida, J. Tanimoto, and A. Hagishima, *Analysis of the Influence of Lane Changing on Traffic-Flow Dynamics Based on the Cellular Automaton Model*, International Journal of Modern Physics C **22**, 271 (2011).
 - [62] J. Tanimoto, T. Fujiki, Z. Wang, A. Hagishima, and N. Ikegaya, *Dangerous Drivers Foster Social Dilemma Structures Hidden behind a Traffic Flow with Lane Changes*, Journal of Statistical Mechanics: Theory and Experiment **2014**, P11027 (2014).
 - [63] J. Tanimoto, S. Kukida, and A. Hagishima, *Social Dilemma Structures Hidden behind Traffic Flow with Lane Changes*, Journal of Statistical Mechanics: Theory and Experiment **2014**, (2014).
 - [64] J. Tanimoto and K. Nakamura, *Social Dilemma Structure Hidden behind Traffic Flow with Route Selection*, Physica A: Statistical Mechanics and Its Applications **459**, 92 (2016).
 - [65] Y. Iwamura and J. Tanimoto, *Complex Traffic Flow That Allows as Well as Hampers Lane-*

Changing Intrinsically Contains Social-Dilemma Structures, Journal of Statistical Mechanics: Theory and Experiment **2018**, (2018).

- [66] J. Tanimoto and X. An, *Improvement of Traffic Flux with Introduction of a New Lane-Change Protocol Supported by Intelligent Traffic System*, Chaos Solitons Fractals **122**, 1 (2019).
- [67] 川嶋 弘尚, 交通流, 公益社団法人 日本オペレーションズ・リサーチ学会 機関誌 「オペレーションズ・リサーチ」 Vol.32 No.6 (1987).

第2章 進化ゲーム理論の基礎，ワクチン接種ゲームの基礎，交通流の基礎

2.1 進化ゲーム理論の基礎

2.1.1 ゲーム理論

ゲーム理論は相互依存関係にある複数のエージェント，または単独のエージェントの振る舞いに関して研究する応用数学の一分野である．ここでいうエージェントとは，自己利益の最大化を目指して合理的な意思決定を行う実態の総称である．また，相互依存関係とは，あるエージェントの意思決定が，ほかのエージェントの意思決定にも影響を及ぼすような，自身にとって最適な行動が，相手の行動に依存するようなゲーム的状况のことを指す [1]．

相互依存関係にあるエージェントたちが，ある戦略を選択すると，その戦略に応じた結果が生じる．この結果に対し各エージェントは報酬を得る（または罰金を支払う）．各エージェントがそれぞれに戦略をたてる，つまり連携をとらない非協力ゲームにおける合理的な意思決定とは，自身の獲得する利益を最大化する戦略を選択することである [2]．

相互依存関係における非協力ゲームでは，各エージェントが本来追求すべき利益は，自身の最大利得ではなく，互いに共通する利益である [3]．そのためには，各エージェントは相互依存関係にあるほかのエージェントと共通する価値を見出し，共有する必要がある．

現実社会では，一度に対戦する相手は 1 人ではなく，複数の場合が考えられるが，非協力ゲームでは 1 人であることが多い．ここで，自身のエージェントの番号を i とし，戦略の個数が m 個あり，対戦相手を j とし，戦略の個数が n 個ある場合，このゲームのことを $m \times n$ ゲームという．また，それぞれの戦略を $s_{i_1}, s_{i_2} \dots s_{i_m}$, $s_{j_1}, s_{j_2} \dots s_{j_n}$ と表すとする．この時，互いが得る利得は，互いの戦略に依存し決まるため，この利得の組み合わせを $m \times n$ ゲームの利得行列といい，例えば，エージェント i と j の戦略が s_{i_2} , s_{j_3} だった場合の利得を（エージェント i の利得，エージェント j の利得）= $(u_{i_2j_3}, u_{j_3i_2})$ と表すとする，全利得のマトリックスは表 2-1 のようになる．

表 2-1 $m \times n$ ゲームの利得行列

j の戦略 i の戦略	s_{j_1}	s_{j_2}	...	s_{j_n}
s_{i_1}	$(u_{i_1j_1}, u_{j_1i_1})$	$(u_{i_1j_2}, u_{j_2i_1})$	...	$(u_{i_1j_n}, u_{j_ni_1})$
s_{i_2}	$(u_{i_2j_1}, u_{j_1i_2})$	$(u_{i_2j_2}, u_{j_2i_2})$	...	$(u_{i_2j_n}, u_{j_ni_2})$
$\vdots$	$\vdots$	$\vdots$	...	$\vdots$
s_{i_m}	$(u_{i_mj_1}, u_{j_1i_m})$	$(u_{i_mj_2}, u_{j_2i_m})$	...	$(u_{i_mj_n}, u_{j_ni_m})$

2.1.2 ナッシュ均衡とパレート最適

非協力ゲームの解の一種に Nash によって定義されたナッシュ均衡がある [4]。ナッシュ均衡とは、あるゲームについて、すべてのエージェントが自身の戦略変更によって利得を増加させることができない戦略の組み合わせのことを指す。つまり、ナッシュ均衡に至ると、すべてのエージェントは自身の戦略変更を行わなくなるということである。ナッシュ均衡はすべてのゲームにおいて必ず 1 つ以上存在し、複数存在する場合もある。

次の表 2-2 に 3×3 ゲームの利得行列の例を示している。太字が表している数字は相手の戦略に対する自身の最大利得である。つまり、相手が S_{j_1} の戦略をとるならば、自身は S_{i_1} の戦略をとるのが最適ということである。これは相手についても同じことがいえ、互いに現在の戦略を保ち続けることが最適な戦略ということになり、ナッシュ均衡であるといえる。相手の戦略が S_{j_2} の時はどうだろうか。この場合も自身は S_{i_1} の戦略をとるのが最適である。しかし、相手の立場に立つと話は変わる。相手にとってはエージェント i が S_{i_1} の戦略をとるならば、 S_{j_1} に戦略を変更した方が、より高い利得を得ることができる。したがって、この組み合わせはナッシュ均衡にはならない。以上より、互いの利得が太字になっている組み合わせがナッシュ均衡になることがわかる。つまり、 (S_{i_3}, S_{i_3}) もまたナッシュ均衡である。

表 2-2 3×3 ゲームの利得行列の例

j の戦略 i の戦略	S_{j_1}	S_{j_2}	S_{j_3}
S_{i_1}	(4 , 4)	(3 , 1)	(2, 3)
S_{i_2}	(1, 3)	(2, 2)	(4, 2)
S_{i_3}	(3, 2)	(2, 4)	(5 , 5)

ナッシュ均衡とは別に、パレート最適という概念がある。これはイタリアの経済学者兼社会学者である Pareto が提唱したミクロ経済学の資源分配に関する概念で、ある資源分配において、誰かの効用（満足度）を減少させることでしか、ほかの誰かの効用を増加させることができない状態のことを指すと定義されている。もしもパレート最適でないならば、誰かの効用を減少させずに、誰かの効用を上昇させることができる。例えば、まだ分配していない資源があった場合などが該当するため、非効率な分配となっているということである。また、パレート最適ではない状態から、誰かの効用を減少させることなく、誰かの効用を上昇させるよう資源分配を変更することを、パレート改善するという。一般に、全エージェントにとって状態 A の方が状態 B より望ましい場合、A は B よりパレート優位であるとい、B は A よりパレート劣位であるという。さらに、A がすべての状態において最良の状況である場合、A はパレート最適であるといい、表 2-2 の例では灰色で示している (S_{i_3}, S_{i_3}) の組み合わせがパレート最

適である。

ナッシュ均衡は必ずしもパレート最適ではなく、表 2-2 の例では (s_{i_1}, s_{i_1}) の組み合わせはナッシュ均衡だがパレート最適ではない。パレート最適以外にも均衡を持つ状況を、非協力ゲームではジレンマといい、代表例が後述する囚人のジレンマである。

また、この節以降に登場する利得表では、太字をナッシュ均衡、網掛けをパレート最適とする。

2.1.3 2×2 ゲーム

2×2ゲームとは、名前の通り、 $m \times n$ ゲームにおける m と n が2の時のゲームのことで、各エージェントが同じ戦略の選択肢を2つ持つ対称ゲームを指す。その戦略とは、協調戦略 (Cooperation, C) と裏切り戦略 (Defection, D) である。

次の表 2-3 に2×2ゲームの利得行列を示す。

表 2-3 2×2ゲームの利得行列

j の戦略 i の戦略	C	D
C	(R, R)	(S, T)
D	(T, S)	(P, P)

ここで R は Reward, S は Sucker または Saint, T は Temptation, P は Punishment の頭文字である。対称ゲームの利得表は、表 2-4 のように相手の利得を省略して、自身の利得のみで表すこともできる。

表 2-4 2×2ゲームの利得行列 (自身の利得のみ)

	C	D
C	R	S
D	T	P

2×2ゲームは利得パラメータがとる符号の組み合わせに応じて、調和ゲーム (Harmony game, HG), 鹿狩りゲーム (Stag hunt game, SH), チキンゲーム (Chicken game, CH), 囚人のジレンマゲーム (Prisoner's dilemma, PD) の4種のゲームカテゴリーに大きく分類することができる。

以降の節で詳しくみていく。

2.1.3.1 調和ゲーム (Harmony game, HG)

表 2-4 の R, S, T, P において、 $R > T \wedge S > P$ が成立している場合、ジレンマが存在しない調和ゲームとなる。表 2-5 に調和ゲームの利得行列の例を示している。この例からわかるように、ナッシュ均衡とパレート最適は戦略が (C, C) の時で一致しており、このゲームにはジレンマが存在しないことがわかる。

表 2-5 調和ゲームの利得行列の例

	C	D
C	(1, 1)	(0, 0)
D	(0, 0)	(-1, -1)

2.1.3.2 鹿狩りゲーム (Stag hunt game, SH)

表 2-4 の R, S, T, P において、 $R > T \wedge S < P$ が成立している場合を鹿狩りゲームと呼ぶ。鹿をハンティングしに山に入る場合を想定する。この時、鹿は大きいため 1 人では仕留めることができず、必ず 2 人で協力しなければ仕留めることができない。しかし、山には鹿以外にもウサギがいる。このウサギは 1 人で簡単に捕まえることができる。片方が鹿を協力して仕留めようと思っている時に、もう一方がウサギを捕まえに行くと、鹿は 2 人でなければ仕留められないのだから、鹿を捕まえに行った者に対する裏切り行為といえる。つまり、鹿を仕留めに行く戦略が C で、ウサギを仕留めに行く戦略が D となる。これが鹿狩りゲームである。

ここで、それぞれの戦略の利得を考えてみる。両者が鹿を仕留めに行く C 戦略の時は、最大の利得を得ることができる。片方が鹿を仕留めに行き、もう片方がウサギを仕留めに行く時はどうだろうか。鹿を捕まえるためには 2 人の協力がなければならないので、C 戦略は何も得ることができない。しかしウサギを仕留めに行く D 戦略では、鹿ほどではないにしてもウサギを仕留めることができ、何も仕留められないよりはましである。最後に両者が D 戦略をとった時は、お互いにウサギは手に入る。

以上の利得関係を表 2-6 に示す。

表 2-6 鹿狩りゲームの利得行列の例

	C	D
C	(1, 1)	(-1, 0.5)
D	(0.5, -1)	(0, 0)

この表からわかるようにパレート最適とナッシュ均衡が一致するのは (C, C) の時である。しかし、(D, D) もまたナッシュ均衡である。これは、相手が D 戦略だった場合に、自身が C 戦略

だと一番低い利得を得ることになるため、リスク回避として、自身も D 戦略をとるかどうかなというジレンマ構造を持っているからである。

以上より、鹿狩りゲームはパレート最適と一致しないナッシュ均衡が存在することから、ジレンマが存在するゲームであることがいえる。

2.1.3.3 チキンゲーム (Chicken game, CH)

表 2-4 の R, S, T, P において、 $R < T \wedge S > P$ が成立している場合、チキンゲームになる。チキンゲームとは、簡単にいうと、どちらが臆病者、または腰抜けかを決めるゲームである。例えば、サウナを想定する。サウナではしばしば我慢大会が開かれ、最後まで残り続けた方が勝ちで、勝った方はビールなどの冷たい飲み物を負けた方から買ってもらうなど、富と名声を得るようなゲームである。しかし、このゲームには危険がつきもので、互いに我慢し続けると病院行きとなり、最悪命を落とす。互いに「こんなゲームはやめよう」と声を掛け合えば、何も手に入らないが、少なくとも病院行きは回避できる。つまり、サウナ室から出ようとする戦略が C で、我慢し続ける戦略が D となる。

表 2-7 にチキンゲームの利得行列の例を示している。

表 2-7 チキンゲームの利得行列の例

	C	D
C	(0.5, 0.5)	(0, 1)
D	(1, 0)	(-1, -1)

この例からわかるように、チキンゲームのナッシュ均衡は (C, D) と (D, C) の 2 つである。つまり相手と違う戦略をとるのがナッシュ均衡となるため、相手と違う戦略をとることが望ましい戦略となる。しかし、非協力ゲームでは意思疎通を行わないので、確率 x で C 戦略、 $1 - x$ で D 戦略をとることが望ましい。また、今までのように、常に同じ戦略を保持したままにすることを純粋戦略と呼び、確率に従って戦略を選択することを混合戦略と呼ぶ。本論文では純粋戦略のみを扱うため、混合戦略の詳細は割愛するが、チキンゲームでは

$$x = \frac{S - P}{T + S - R - P} \quad (2.1)$$

の確率で C 戦略を選択することが望ましい。この時の期待利得 E は

$$E = \frac{TS - RP}{T + S - R - P} \quad (2.2)$$

となる。

チキンゲームのパレート最適は (D, D) 以外である。しかし、ナッシュ均衡は (C, D) と (D, C) であるため、両者は一致しない。したがって、チキンゲームもまた、ジレンマが存在するといえ

る。

このほかにも、利得行列の(C,C)と(C,D)または(D,C)の値によって、表 2-8 に示すように、狭義のチキンゲーム（表 2-8 の(a)）、リーダーゲーム（表 2-8 の(b)）、英雄ゲーム（表 2-8 の(c)）がある。なお、パレート最適とナッシュ均衡となる戦略の組み合わせは、表 2-7 と同様であり、太字と網掛けは煩雑になるため省略している。

表 2-8 チキンゲーム種類とその利得行列の例

(a) 狭義のチキンゲーム			(b) リーダーゲーム			(c) 英雄ゲーム		
	C	D		C	D		C	D
C	(3,3)	(1,4)	C	(3,3)	(2,5)	C	(2,2)	(3,4)
D	(4,1)	(0,0)	D	(5,2)	(0,0)	D	(4,3)	(0,0)

2.1.3.4 囚人のジレンマゲーム (Prisoner's dilemma, PD)

表 2-4 の R , S , T , P において、 $R < T \wedge S < P$, 特に $R < T \wedge S < P \wedge 2R > S + T$ が成立している場合を囚人のジレンマゲームと呼ぶ。囚人のジレンマゲームを理解するために、共犯の疑いがかけられている囚人 2 人に対する司法取引を想定する。この 2 人は別々の部屋に隔離されており、警察は自白させるために、以下の条件と報酬を伝える。両者が自白したら禁固 5 年。どちらか一方のみが自白した場合は、自白した方は釈放で、黙秘を続けた方が禁固 10 年。両者とも黙秘を続けた場合は、両者ともに禁固 2 年ですむという内容である。

この条件では、相手が黙秘を続け自身が自白することが一番魅力的だ。逆に最も避けたいのは、自身が黙秘を続け相手が自白した場合である。囚人の 2 人にとっては、互いに自白（相手を裏切る、以降 D 戦略）して禁固 5 年になるよりも、お互いに黙秘（協力する、以降 C 戦略）を続けて禁固 2 年の方が得ではあるが、自己の利益を追い求める限り、(D,D) に帰結する。なぜなら、表 2-9 に示すように、相手がどちらの戦略をとったとしても、自身は D 戦略を選択した方が、より高い利益を得ることができるからである。このように個人にとっての最善な選択と、全体にとっての最適な選択が異なることからジレンマが生じている。

表 2-9 囚人のジレンマの利得行列の例

	C	D
C	(0.5, 0.5)	(-1, 1)
D	(1, -1)	(0, 0)

また、表 2-9 からわかるように、ナッシュ均衡は(D,D)であるのに対し、パレート最適は

(D,D)以外である。したがって、ジレンマがあるといえる。

2.1.3.5 ギャンブル性ジレンマ D_g とリスク回避性ジレンマ D_r によるゲームクラス分類

先ほどまでは、表 2-4 の R , S , T , P のそれぞれの大小関係を基にクラス分類を行ってきたが、それぞれのクラス分けでは、常に R と T , S と P の組み合わせで大小関係を比較してきた。そこで、 R と T の大小関係を、ギャンブル性ジレンマ $D_g \equiv T - R$, リスク回避性ジレンマ $D_r \equiv P - S$ を定義する [5]と、それぞれのクラス分けは

1. 調和ゲーム, $D_g < 0 \wedge D_r < 0$
2. 鹿狩りゲーム, $D_g < 0 \wedge D_r > 0$
3. チキンゲーム, $D_g > 0 \wedge D_r < 0$
4. 囚人のジレンマゲーム, $D_g > 0 \wedge D_r > 0$

となる。これらを図 2-1 に示すように $D_g - D_r$ 平面上に表すと、4 象限のそれぞれに、各ゲームクラスが対応していることがわかる。




図 2-1 ギャンブル性ジレンマ D_g とリスク回避性ジレンマ D_r によるゲームクラス分類

2.1.4 進化ゲーム理論

ゲーム理論とは、1944 年に von Neumann と Morgenstern [6]によって、相互依存関係にある人間が、どのように行動の意思決定を行っているのかを研究するために創始された理論である。そして、前節までにたびたび登場した、ゲーム理論において重要な均衡の概念であるナッシュ均衡は、1950 年に Nash [4]によって発見されている。2 × 2ゲームでは、各エージェント

は自己利益を最大化する戦略を選択する，すなわち合理的な意思決定を常に下すことを仮定しているが，人間は必ずしも合理性に基づいて意思決定を行っていないことが知られている。

そこで登場したのが進化ゲーム理論である．進化ゲーム理論とは，ゲーム理論を動学化した理論体系であり，Maynard Smith [7]の研究をはじめ，Taylor と Jonker [8]や Hofbauer, Schuster および Sigmund [9]らによって創設された．特筆すべき点は，進化ゲーム理論では合理性を仮定しないことである．ゲーム理論では，エージェントは種を構成する個体，戦略は表現型，利得は適応度と表現される．進化ゲーム理論では，種間競争による適応度の差が，戦略間のゲームにおける利得によって決められ，ゲームの結果は種の繁殖の帰結，すなわち自然淘汰を表現している [10]．

この節以降，本研究に関する知識として，進化について記述を行うが，必要最低限にとどめ，詳細やそのほかの概念および導出過程は参考文献 [10]を参照することで，代わりとする．

2.1.5 進化ダイナミクス

生物の進化ダイナミクスの基礎単位は，複製，淘汰，突然変異の3つからなる．進化とは，自身の複製を作り，繁殖を行う個体から構成される集団内で起こる現象のことを指す．異なる種で構成された集団において，特定の種の繁殖速度がほかの種の集団に勝っていれば，結果として，その種のみが繁殖に成功し，ほかの種を駆逐するという淘汰が起こる．しかし，複製は常に正確というわけではなく，突然変異によって，その種から派生した新たな種を生み出すことがある．このようにして，淘汰の過程で突然変異によって新たな種が生まれることで，多種多様な種が維持される．

以上のことを踏まえ，ある1つの種についての繁殖ダイナミクスを考える．ある時刻 t における個体数を $X(t)$ ，繁殖率を r とし，繁殖までの時間が平均 $1/r$ の指数分布に従うと仮定すると，

$$\frac{d}{dt}X = rX \quad (2.3)$$

となる．時刻 $t = 0$ における個体数を X_0 とすると，微分方程式(2.3)の解は

$$X(t) = X_0 e^{rt} \quad (2.4)$$

となり，個体数 X は式(2.4)のマルサス法則に従って繁殖する．しかし，生物の寿命は有限なので，死亡率を導入する必要がある．死亡率を d とし，寿命が平均 $1/d$ の指数分布に従うと仮定すると，式(2.3)は

$$\frac{d}{dt}X = (r - d)X \quad (2.5)$$

と書き直される．つまり，実質的な成長率は $r - d$ で，当然ながら， $r < d$ なら集団は絶滅し， $r > d$ なら無限に繁殖することになる． $r = d$ なら個体数は常に一定だが，式(2.4)からも明らかのように，少しでも出生と死亡のバランスが崩れると，指数関数的に個体数が変化することになる．つまり，

$$\frac{r}{d} \quad (2.6)$$

が1よりも大きければ個体数は時間とともに増大, 1よりも小さければ減少, 1ならば変化なしということになる. この式(2.6)の比のことを, 基本生産比と呼ぶ.

先ほどまでは, 単に出生と死亡の確率のみを考えていたが, 生物が生命活動を維持するには, エネルギーを外部から取り込む必要があり, この外部に存在するエネルギー量によって制約を受ける, つまり環境の容量等の影響によって制約を受ける. このことを表現したモデルの一つに, 以下のロジスティック方程式

$$\frac{d}{dt}X = rX(1 - X/K) \quad (2.7)$$

がある. ここで K は環境収容力である. 式(2.7)は, 個体数 X の増加速度が時間発展とともに緩やかになっていくことを表しており, 個体数が K に到達すると, それ以上増加しないことを表している. 時刻 $t = 0$ における個体数を X_0 とすると,

$$X(t) = \frac{KX_0e^{rt}}{K + X_0(e^{rt} - 1)} \quad (2.8)$$

が式(2.7)の解となる.

式(2.8)までは, 集団に所属する種は1つのみを想定していたが, ここからは集団内に異なる速度で繁殖する, 相互依存関係にある種が複数存在する場合の淘汰ダイナミクスを考える. まずは2つの種のみで構成される集団を考える. 種をそれぞれ A と B とし, それぞれの時刻 t における個体数を $X_A(t)$, $X_B(t)$ とする. また, それぞれの繁殖率を a と b とすると,

$$\begin{cases} \frac{d}{dt}X_A = aX_A \\ \frac{d}{dt}X_B = bX_B \end{cases} \quad (2.9)$$

に従って個体数は増減し, 繁殖率は適応度と解釈される. この時, それぞれの時刻 $t = 0$ における個体数を X_{A0} , X_{B0} とすると, 式(2.9)の解は

$$\begin{cases} X_A(t) = X_{A0}e^{at} \\ X_B(t) = X_{B0}e^{bt} \end{cases} \quad (2.10)$$

となる. ここで個体数の割合 $\rho(t) = X_A(t)/X_B(t)$ とすると

$$\frac{d}{dt}\rho = \frac{X_B \frac{dX_A}{dt} - X_A \frac{dX_B}{dt}}{X_B^2} = (a - b)\rho \quad (2.11)$$

となり, 初期値 $\rho_0 = X_{A0}/X_{B0}$ を用いると, 式(2.11)の解は

$$\rho(t) = \rho_0 e^{(a-b)t} \quad (2.12)$$

となる. 式(2.12)より, $a > b$ ならば ρ は無限大に発散し, 淘汰の面で A の方が有利となる. 一方, 逆ならば ρ は0に収束し, B の方が有利となる.

次に, 集団サイズが環境収容力等によって一定に保たれている場合を考える. 時刻 t における種 A と B の集団に占める割合をそれぞれ $x_A(t)$ と $x_B(t)$ とすると, $x_A + x_B = 1$ が成立する. ま

た, それぞれの繁殖率を a と b とすると,

$$\begin{cases} \frac{d}{dt}x_A = (a - \phi)x_A \\ \frac{d}{dt}x_B = (b - \phi)x_B \end{cases} \quad (2.13)$$

に従って成長する. ここで ϕ は集団の平均適応度であり, $x_A + x_B = 1$ に留意すると $\phi = ax_A + bx_B$ となる. さらに $x_A + x_B = 1$ より, x_B は削除できるので, 式(2.13)は

$$\frac{d}{dt}x_A = x_A(1 - x_A)(a - b) \quad (2.14)$$

という単独の微分方程式で記述できる. 式(2.14)は2つの自明な均衡点 $x_A = 0$, $x_A = 1$ を持ち, これら2つの点では式(2.14)は0となる. $a > b$ ならば, 種AとBの個体数がいかなる存在比であったとしても, $0 < x_A < 1$ の範囲では, 式(2.14)は常に0よりも大きく, $x_A = 1$ が安定, つまりBが淘汰される. 逆に $a < b$ ならば, Aが淘汰されるのが安定となる.

次に, 集団に多種存在する場合を考える. 存在する種を $i \in 1, 2, 3 \dots n$ とし, ある種 i の適応度(繁殖率)を $f_i (> 0)$, それぞれの種の集団に占める割合を $x_i(t)$ とすると, 集団の構成はベクトルで表現することができ, 構成ベクトル $\vec{x}$ は $(x_1, x_2, x_3 \dots x_n)$ となる. 以上より, 淘汰ダイナミクスは

$$\begin{cases} \frac{d}{dt}x_i = x_i(f_i - \bar{f}) \\ \bar{f} = \sum_{i=1}^n x_i f_i \end{cases} \quad (2.15)$$

と表される. ここで $\bar{f}$ は集団の平均適応度である. ある種 i の適応度が, 集団の平均適応度を超えるか否かで, その種の個体数の増減が決まる. なお, 集団のサイズは常に一定であることを仮定している.

2.1.6 レプリケータダイナミクス

Taylor と Jonker [8]によって, 初めて進化ゲームダイナミクスに微分方程式が導入された. その後, Zeeman [11]や Hofbauer, Schuster および Sigmund [9]らによって研究が行われた.

レプリケータ方程式は, 進化ゲームダイナミクスの基礎であり, 突然変異が起こらない無限集団における n 個の戦略(表現型)間の頻度依存淘汰を記述するものである. エージェント(個体)は, ある戦略をとって, ほかのエージェントと相互作用し, 利得(適応度)を獲得する. 戦略の番号を $i \in 1, 2, 3 \dots n$ とし, 戦略を S_i とし, この戦略をとっているエージェント数 N_i と表すとすると, エージェント数は

$$\frac{d}{dt}N_i = (a + f_i)N_i \quad (2.16)$$

に従って増減することになる. ここで a は自然適応度, $f_i > 0$ は戦略 S_i がゲームによって生じた適応度(繁殖率)を表す. また, 自然適応度 a は戦略によらず一定であると仮定する.

ある戦略 S_i をとっているエージェントの全体に占める割合を x_i で表すとする．集団の構成は、この x_i を用いてベクトル表現でき、 $\vec{x} = (x_1, x_2, x_3 \dots x_n)$ となる．また、全エージェント数を N とすると、 $x_i = N_i/N$ となる．これらを踏まえて式(2.16)の i について総和をとると、

$$\begin{cases} \frac{d}{dt}N = (a + \bar{f})N \\ \bar{f} = \sum_{i=1}^n x_i f_i \end{cases} \quad (2.17)$$

を得る．ここで、 $\bar{f}$ は集団の平均適応度を表している．また、式(2.16)を式変形していくと、

$$\frac{d}{dt}N_i = \frac{d}{dt}Nx_i = x_i \frac{dN}{dt} + N \frac{dx_i}{dt} \Leftrightarrow N \frac{dx_i}{dt} = \frac{dN_i}{dt} - x_i \frac{dN}{dt} \quad (2.18)$$

を得る．この式(2.18)について、式(2.16)と式(2.17)を用いて計算していくと、

$$N \frac{dx_i}{dt} = \frac{dN_i}{dt} - x_i \frac{dN}{dt} = (a + f_i)N_i - (a + \bar{f})Nx_i \quad (2.19)$$

を得る．また、この式(2.19)について $x_i = N_i/N \Leftrightarrow N_i = Nx_i$ を用いて計算を進めると、

$$\frac{d}{dt}x_i = (f_i - \bar{f})x_i \quad (2.20)$$

を得る．この式(2.20)をレプリケータ方程式と呼ぶ．また、利得行列を $\vec{A}$ 、戦略番号 i を $\vec{e}_i$ で表せば、式(2.20)は

$$\frac{d}{dt}x_i = (\vec{e}_i^T \cdot \vec{A}\vec{x} - \vec{x}^T \cdot \vec{A}\vec{x})x_i \quad (2.21)$$

と表すこともできる [2]．

式(2.20)は、進化ゲームにおいて、ゲームによって得る利得が平均より多ければ、その戦略をとるエージェントは増加し、少なければ減少することを意味している．

2.1.7 多人数 2 戦略ゲームのレプリケータダイナミクス

多人数 2 戦略ゲームダイナミクスについて表 2-4 を用いて考える．戦略は C 戦略と D 戦略の 2 つなので、前節の集団の構成ベクトル $\vec{x}$ は $\vec{x} = (x_c, x_d)$ となる．また、 $x_c + x_d = 1$ より、 x_c および x_d の時間 1 回微分を $\dot{x}_c$ 、 $\dot{x}_d$ と表記することとすると、 $\dot{x}_c = -\dot{x}_d$ が成立する．つまり、片方の戦略についてのみ考えれば十分ということである．

ここで、C 戦略のレプリケータ方程式は式(2.21)より

$$\dot{x}_c = \left([1 \ 0] \cdot \begin{bmatrix} R & S \\ T & P \end{bmatrix} \begin{bmatrix} x_c \\ x_d \end{bmatrix} - [x_c \ x_d] \cdot \begin{bmatrix} R & S \\ T & P \end{bmatrix} \begin{bmatrix} x_c \\ x_d \end{bmatrix} \right) x_c \quad (2.22)$$

となる．また、 $x_c + x_d = 1$ を考慮し、式展開を行っていくと、

$$\dot{x}_c = ((P - S - T + R)x_c - (P - S))x_c(1 - x_c) \quad (2.23)$$

が得られる．式(2.23)について、 $0 \leq x_c \leq 1$ であることから、 $x_c = 0, 1$ が自明な解（均衡点）で、さらに $(P - S)/(P - S - T + R)$ もまた解であることがわかる．また、節 2.1.3 のギャンブル性ジレンマ $D_g \equiv T - R$ 、リスク回避性ジレンマ $D_r \equiv P - S$ を用いると、 $D_r/(D_r - D_g)$ と表すこと

ができる． D_g と D_r の正負と均衡点の安定性は一致し，最終的に 2×2 ゲームで分類した4つのゲームクラスに区分できる．図2-2に各ゲームクラスの x_C と $\dot{x}_C$ ，均衡点の安定性，淘汰ダイナミクスの関係図を示している [2]．




図2-2 各ゲームクラスの x_C と $\dot{x}_C$ ，均衡点の安定性，淘汰ダイナミクスの関係図 [2]

図2-2から読み取れるように，(a)調和ゲームではC戦略のみが生き残り，(b)鹿狩りゲームでは，初期のC戦略が全体に占める割合に依存して，どちらかの戦略に均衡し，(c)チキンゲームでは初期の割合に依存せず，どちらかの戦略に吸引され，(d)囚人のジレンマゲームではD戦略のみが生き残ることがわかる．

2.1.8 有限集団における2戦略ゲームの進化ゲームダイナミクス

最後に，本論文で取り扱うモデルはいずれも有限集団に対する2戦略ゲームなので，有限集団における2戦略ゲームの進化ゲームダイナミクスを考える．今まで記述してきた，無限集団における進化ゲームダイナミクスでは，決定論的記述であるレプリケータ方程式を用いてアプローチを行ってきたが，有限集団に対しては，確率論的扱いが必要となる [12, 13]．

サイズが N の集団を想定する．この時，自然淘汰がどの戦略に有利に働くかを調べるには，

特定の戦略 S の最終的な確立となる固着確立が、集団内のエージェントがまだどの戦略も選択していない状態から、誰か1人のエージェントが戦略 S を一様分布で戦略を選択する確率 $1/N$ よりも大きいかどうかを調べることに同義である。表 2-4 のような 2×2 ゲームで考えると、C 戦略の固着確立とは、D 戦略エージェントが $N-1$ 人いる集団内の1人のC 戦略エージェントが、絶滅することなく集団にC 戦略を浸透させ、最終的に全体を占めるC 戦略のエージェント数の割合を意味する。つまり、C 戦略の固着確立が $1/N$ よりも大きければ、淘汰はD 戦略よりもC 戦略に有利に働く。

C 戦略エージェントの人数を N_C 、D 戦略エージェントの人数を $N_D = N - N_C$ とする。この時、C 戦略エージェントがほかのC 戦略エージェントとゲームを行う確率、C 戦略エージェントがほかのD 戦略エージェントとゲームを行う確率、D 戦略エージェントがほかのD 戦略エージェントとゲームを行う確率は、それぞれ、 $(N_C - 1)/(N - 1)$ 、 $(N - N_C - 1)/(N - 1)$ 、 $N_C/(N - 1)$ である。したがって、C 戦略エージェントの人数が N_C の時の集団のC 戦略エージェントの期待利得 $E_{N_C}^C$ とD 戦略エージェントの $E_{N_C}^D$ は、

$$\begin{cases} E_{N_C}^C = \frac{R(N_C - 1) + S(N - 1)}{N - 1} \\ E_{N_C}^D = \frac{TN_C + P(N - N_C - 1)}{N - 1} \end{cases} \quad (2.24)$$

となる。

前節までの進化ゲームダイナミクスへのアプローチでは、ある戦略をとるエージェントの期待利得は、そのまま適応度と解釈される。ここで新たに淘汰圧の尺度として、パラメータ $\omega \in [0, 1]$ を導入する。期待利得が適応度に及ぼす影響が小さければ、淘汰圧は弱く、逆であれば淘汰圧は強くなる。C 戦略エージェントとD 戦略エージェントの適応度を、それぞれ $f_{N_C}^C$ 、 $f_{N_C}^D$ とすると、式(2.24)を用いて

$$\begin{cases} f_{N_C}^C = 1 - \omega + \omega E_{N_C}^C \\ f_{N_C}^D = 1 - \omega + \omega E_{N_C}^D \end{cases} \quad (2.25)$$

となる。この式(2.25)からわかるように、淘汰圧 ω が0の時、ゲームの結果は進化ダイナミクスに何も影響を与えず、逆に ω が1の時はゲームの結果がそのまま適応度となる。

ここで、単位時間ごとに適応度に比例した確率で繁殖を行うエージェントが1つだけ選択され、そのエージェントの子がランダムに選択されたエージェントと取って代わる確率過程 (Moran 過程) を考える。C 戦略エージェントの数が1人増える、すなわち状態が N_C から $N_C + 1$ の状態へと遷移する確率 p_{N_C, N_C+1} は、

$$p_{N_C, N_C+1} = \frac{N_C f_{N_C}^C}{N_C f_{N_C}^C + (N - N_C) f_{N_C}^D} \frac{N - N_C}{N} \quad (2.26)$$

与えられる。また、C 戦略エージェントの数が1人減る、すなわち状態が N_C から $N_C - 1$ の状態へと遷移する確率 p_{N_C, N_C-1} は、

$$p_{N_C, N_C-1} = \frac{(N - N_C)f_{N_C}^D}{N_C f_{N_C}^C + (N - N_C)f_{N_C}^D} \frac{N_C}{N} \quad (2.27)$$

で与えられ、状態が遷移しない、つまり C 戦略エージェントの数が増えない確率 p_{N_C, N_C} は、式(2.26)および式(2.27)を用いて

$$p_{N_C, N_C} = 1 - p_{N_C, N_C+1} - p_{N_C, N_C-1} \quad (2.28)$$

となる。また、集団内に占める C 戦略エージェントが 0 人、もしくは N 人の場合、状態は変化のしようがないため、 $P_{0,0} = P_{N,N} = 1$ となり、この過程は 2 つの吸引状態 $N_C = 0$ と $N_C = N$ を持つ。

次に、C 戦略と D 戦略の固着確立 ρ_C と ρ_D を求める。状態 N_C から始めた時に、状態 N に達する確率を q_{N_C} とすると、

$$q_{N_C} = p_{N_C, N_C-1} q_{N_C-1} + (1 - p_{N_C, N_C+1} - p_{N_C, N_C-1}) q_{N_C} + p_{N_C, N_C+1} q_{N_C+1} \quad (2.29)$$

で表される。また、 $1 - q_{N_C}$ は状態 N_C から始めた時に、状態 0 に達する確率を表しており、吸引点となる $N_C = 0$ と $N_C = N$ では $q_0 = 0$, $q_N = 1$ となる。ここで、

$$r_{N_C} = q_{N_C} - q_{N_C-1} \quad (2.30)$$

を導入する。また、この r_{N_C} に対し、 $N_C = 1$ から N までの和をとると、

$$\sum_{i=1}^N r_i = (q_1 - q_0) + (q_2 - q_1) + \cdots (q_N - q_{N-1}) = q_N - q_0 = 1 \quad (2.31)$$

である。ここで、 $\alpha_{N_C} = p_{N_C, N_C-1} / p_{N_C, N_C+1}$ を導入する。すると、 r_{N_C+1} は式(2.29)と式(2.30)より、 $r_{N_C+1} = \alpha_{N_C} r_{N_C}$ となる。また、 $r_1 = q_1 - q_0 = q_1$ より、 $r_2 = \alpha_1 r_1$, $r_3 = \alpha_1 \alpha_2 r_1$ となることから、式(2.31)は

$$\sum_{i=1}^N r_i = q_1 + q_1 \sum_{j=1}^{N-1} \prod_{k=1}^j \alpha_k = 1 \quad (2.32)$$

となり、式(2.32)の q_1 について整理すると、

$$q_1 = \frac{1}{1 + \sum_{j=1}^{N-1} \prod_{k=1}^j \alpha_k} \quad (2.33)$$

を得る。さらに、

$$q_{N_C} = q_1 \left(1 + \sum_{j=1}^{N_C-1} \prod_{k=1}^j \alpha_k \right) \quad (2.34)$$

なので、式(2.34)の右辺の q_1 に式(2.33)を適用すると、

$$q_{N_C} = \frac{1 + \sum_{j=1}^{N_C-1} \prod_{k=1}^j \alpha_k}{1 + \sum_{j=1}^{N-1} \prod_{k=1}^j \alpha_k} \quad (2.35)$$

となる。ここで、C 戦略と D 戦略の固着確立 ρ_C と ρ_D は q_1 と $1 - q_{N-1}$ のことである。また式(2.26)と式(2.27)より、 α_{N_C} は

$$\alpha_{N_C} = \frac{p_{N_C, N_C-1}}{p_{N_C, N_C+1}} = \frac{f_{N_C}^D}{f_{N_C}^C} \quad (2.36)$$

となるので、式(2.36)を使用して、C 戦略と D 戦略の固着確立 ρ_C と ρ_D は

$$\begin{cases} \rho_C = \frac{1}{1 + \sum_{i=1}^{N-1} \prod_{j=1}^i \left(\frac{f_j^D}{f_j^C} \right)} \\ \rho_D = \frac{\prod_{i=1}^{N-1} \left(\frac{f_i^D}{f_i^C} \right)}{1 + \sum_{i=1}^{N-1} \prod_{j=1}^i \left(\frac{f_j^D}{f_j^C} \right)} \end{cases} \quad (2.37)$$

となる．さらに両戦略の固着確立の比は

$$\frac{\rho_D}{\rho_C} = \prod_{i=1}^{N-1} \left(\frac{f_i^D}{f_i^C} \right) \quad (2.38)$$

となる．

弱い淘汰圧の極限を考える．つまり、式(2.37)のそれぞれの $\omega \rightarrow 0$ に対する Taylor 展開を求めると、

$$\begin{cases} \rho_C \approx \frac{1}{N} \frac{1}{1 - (\alpha_C N - \beta_C) \omega / 6} \\ \rho_D \approx \frac{1}{N} \frac{1}{1 - (\alpha_D N - \beta_D) \omega / 6} \\ \begin{cases} \alpha_C = R + 2S - T - 2P \\ \alpha_D = P + 2T - S - 2R \\ \beta_C = 2R + S + T - 4P \\ \beta_D = 2P + T + S - 4R \end{cases} \end{cases} \quad (2.39)$$

を得る．もし $\rho_C > 1/N$ ($\rho_D > 1/N$) ならば、淘汰は C (D) 戦略にとって有利に働き、

$$\begin{cases} \rho_C > 1/N \Leftrightarrow R(N-2) + S(2N-1) > T(N+1) + P(2N-4) \\ \rho_D > 1/N \Leftrightarrow P(N-2) + T(2N-1) > S(N+1) + R(2N-4) \end{cases} \quad (2.40)$$

を満たすことになる．無限集団のレプリケータ方程式では、淘汰圧 ω の値は全く影響を与えないが（ただし $\omega = 0$ を除く）、有限集団を記述する確率過程では、大きな影響を与える．そのため、進化ゲームにおいて有限集団を想定する場合は、淘汰圧がゲームの帰結に影響を与える因子の一つであることに注意しなければならない．

2.2 複雑ネットワークとワクチン接種ゲームの基礎

本節では、まず現実社会の人間のかかわりを模擬した、複雑ネットワークの概要と、本研究で使用するネットワークについて説明したのち、ワクチン接種ゲームの基礎を説明する。

2.2.1 複雑ネットワーク

複雑ネットワークとは、現実社会において様々な場面で存在するネットワークの性質を研究する分野である。その一例を図 2-3 に示している。本研究で興味があるのは人間関係のネットワークで、様々な研究が行われてきた [14–20] が、ネットワークは航空路線 [15] や食物連鎖 [21–23] や、インターネットの URL など使用される World Wide Web (WWW) [24, 25] など、社会、工学、生物、情報と様々な分野に存在する。複雑ネットワークの分野が著しく発展し始めたのはここ数十年の話で、初期の研究においては、観測の難しさや、計算機の性能などの問題から、扱えるネットワークの規模はノード数が 100 程度までのものだった [26]。しかし、ここ数年で計算機の性能の向上や、インターネットの爆発的普及により、大規模なデータの扱いを容易にさせたため、例えば、AI の一つである深層学習モデル (Deep Learning Models) を使用している Chat GPT-3 では 1750 億ものノードを持つといわれている [27]。




図 2-3 複雑ネットワークの一例

ネットワークの研究の起源は、18 世紀に Euler が提唱したグラフ理論にまでさかのぼる [28]。グラフ理論とは、ノードとエッジの繋がり方に着目して、グラフの性質を研究する数学の一分野 [28] である。1959 年に Erdős と Rényi が考案したランダム・グラフ [29] の解析が、この分野に重要な進展をもたらした。この解析以降、グラフの解析的取扱いは大きく進捗し、1998 年には Watts と Strogatz によるスモールワールド性の考察 [14]、1999 年の Barabási と Albert によるスケールフリー性の考察 [30] と、複雑ネットワークに関する研究が盛んに行われていくこととなる。Barabási と Albert は、一見全く関係性のない複雑なネットワークの間に、普遍的

な性質を持つことを指摘しており、この指摘から 10 年ほどの間に、この分野は急激に発展した。

複雑ネットワークは、その学問自体も複雑で、応用範囲也多岐にわたることから、すべてを詳細に記述することは避け、本研究に関係のある、ネットワークの特徴量と、人間関係が持つスケールフリー性を模擬した、Barabási と Albert が提案したネットワークモデル Barabási-Albert スケールフリーモデルについて述べるにとどめ、詳細やそのほかの情報などは参考文献 [26] を参照してもらうこととする。

2.2.2 ネットワークの特徴量

ネットワークを特徴づける主な概念には、あるノード付近の情報のみで計算可能な局所的なもの、ネットワーク全体からの情報を用いて計算する大局的なものが存在する。以下に紹介する特徴量において、次数、次数相関、クラスター係数は局所的な量であり、平均ノード間距離は大局的な量である。

2.2.2.1 次数（エッジ数）

次数を説明するのに、図 2-3 を使用する。このネットワークの例では、ノード n_2 が直接繋がっているノードは n_1 , n_3 , n_5 の 3 つである。この繋がりの数のことを次数（リンク数）と呼ぶ。

ここで、全体のノード数を N 、ある次数 k を持つノード数を N_k とすると、ある次数 k が全体に占める割合を p_k は

$$p_k = \frac{N_k}{N} \quad (2.41)$$

となる。また、最大次数を K とすると、各次数の割合を収めた配列 $\{p\}$ は

$$\{p\} = \{p_0, p_1, \dots, p_K\} \quad (2.42)$$

と表現され、これはそのまま次数分布を表していることになる。例えば図 2-3 では、最大次数 K は 6 で、 $p_0 = 0$, $p_1 = 3/8$, $p_2 = 3/8$, $p_3 = 1/8$, $p_4 = 0$, $p_5 = 0$, $p_6 = 1/8$ となる。また、当然最大次数を超える次数を持つノードの割合は 0 である。

また、ネットワークを成す全ノードが持つ平均の次数を平均次数 $\langle k \rangle$ と呼び、あるノード i の持つ次数を d_i とすると、平均次数 $\langle k \rangle$ は

$$\langle k \rangle = \frac{1}{N} \sum_{i=1}^N d_i \quad (2.43)$$

と定義される。また、あるノード i の持つ次数を d_i とある次数 k を持つノード数を N_k との間には

$$\sum_{i=1}^N d_i = \sum_{k=0}^K k N_k \quad (2.44)$$

の関係が成り立つので、平均次数 $\langle k \rangle$ は式(2.41)より

$$\langle k \rangle = \frac{1}{N} \sum_{i=0}^K i N_k = \sum_{i=0}^K i p_i \quad (2.45)$$

とすることもできる。また、図 2-3 では $\langle k \rangle = 2.25$ となる。

2.2.2.2 次数相関

次数相関は、2002 年の Newman [31]の報告によって注目されるようになり、その名の通り、繋がっている 2 つのノード間の次数の傾向を測る概念が次数相関である。

次数相関を測る方法は 2 通りある。一つは次数 k と繋がっているノードの平均次数に基づく方法である [32]。あるノード n_i に繋がっているノード数は、そのノードが持つ次数にほかならないので、 d_i である。次数 k を持つノードに繋がっているノードの平均次数 $\langle k_{nn}^k \rangle$ は

$$\langle k_{nn}^k \rangle = \sum_{k'=0}^K k' P(k'|k) \quad (2.46)$$

で与えられる。ここで、 $P(k'|k)$ は自身が次数 k であるという条件下で自身と繋がっているノードの次数のうち、 k' が占める割合を表している。

$\langle k_{nn}^k \rangle$ が k の値に対して増加傾向を示せば、そのネットワークは正の次数相関を持ち、減少傾向を示せば負の次数相関を持つ。一方、相関がなければ、 $P(k'|k)$ は k によらず

$$P(k'|k) = \frac{k' p_{k'}}{\langle k \rangle} \quad (2.47)$$

で与えられる。相関がない時は、この式(2.47)を式(2.46)に代入すると

$$\langle k_{nn}^k \rangle = \sum_{k'=0}^K k' \frac{k' p_{k'}}{\langle k \rangle} = \frac{\langle k^2 \rangle}{\langle k \rangle} \quad (2.48)$$

を得ることができる。 $\langle k_{nn}^k \rangle$ は k によらず一定だが、ネットワーク中のノードの次数がそれぞれ異なる場合は、 $\langle k^2 \rangle > \langle k \rangle^2$ （すなわち $\langle k_{nn}^k \rangle > \langle k \rangle$ ）であることが知られている。

もう一つの方法は、統計学的指標であるピアソン相関係数を用いて次数相関を測る方法である [31]。この方法では、式(2.46)のように各次数に対して相関を求めるのではなく、全体としての相関をみるため、式(2.46)も情報量は劣るが、その値の正負のみで相関の正負を判定できるのが長所である。

また、食物連鎖などの生物系や WWW などの工学系ネットワークでは負の相関を持つが、映画俳優の共演や学术论文の共著者などの人間関係のネットワークでは、正の相関を持つことがわかっている。

2.2.2.3 クラスター係数

例えば、図 2-3 の $n_2 - n_3 - n_5$ 間や $n_4 - n_5 - n_6$ 間の関係のように、知人の知人が、自身の知

人であるような関係性は、日常でもよく見られる光景である．図 2-3 の $n_2 - n_3 - n_5$ 間や $n_4 - n_5 - n_6$ 間の関係のように、図にすると三角形となる．この三角形のことを複雑ネットワークではクラスターと呼ぶ．クラスターは人間関係だけではなく、様々なネットワークに存在する．

クラスターの量を測るには、クラスター係数 C が用いられる．あるネットワークのクラスター係数 C は、あるノード n_i のクラスター係数 C_i を用いて、

$$C = \frac{1}{N} \sum_{i=1}^N C_i \quad (2.49)$$

と定義される．また、あるノード n_i のクラスター係数 C_i は、自身を含むクラスター数 N_{C_i} が、自身の持つエッジから 2 つのエッジを選ぶ全組み合わせの数 N_{2C_i} のうち、どれだけを占めるかの割合で、

$$C_i = \frac{N_{C_i}}{N_{2C_i}} \quad (2.50)$$

である．また、あるノード n_i が持つ次数を d_i とすると、自身の持つエッジから 2 つのエッジを選ぶ全組み合わせ数 N_{2C_i} は、 $1, 2, \dots, d_i$ の数字から 2 つの数字を選ぶ時の全組み合わせ数にほかならないので、

$$N_{2C_i} = \frac{1}{2} d_i (d_i - 1) \quad (2.51)$$

である．そのため、式(2.50)は式(2.51)を使って

$$C_i = \frac{2N_{C_i}}{d_i(d_i - 1)} \quad (2.52)$$

となる．例えば、図 2-3 の C_2 は $1/3$ であり、 $C = 19/60 \approx 1/3$ である．

また、 $C = 1$ となるのは、全ノードが全ノードと繋がっている、完全グラフのみである．

2.2.2.4 平均ノード間距離

ノード間距離とは、ネットワーク上の任意の 2 つのノード n_i と n_j の距離 $g_{i,j}$ において、ノード n_i から n_j までの最小エッジ数と定義される．ネットワークの平均ノード間距離 L は、全ノードの 2 つの組み合わせに対する距離 $g_{i,j}$ の平均値であり、全ノード数が N ならば、任意の 2 つのノードの選び方は $N(N-1)/2$ 通り存在するため、

$$L = \frac{2}{N(N-1)} \sum_{i=1}^{N-1} \sum_{j=i+1}^N g_{i,j} \quad (2.53)$$

と定義される．例えば、図 2-3 の $g_{1,8}$ は 3 であり、 $L = 51/28 \approx 2$ である．

2.2.2.5 Barabási-Albert スケールフリー (BA-SF) モデル

人間関係のネットワークを調べるために、1969 年に Travers と Milgram [33] が行った面白い

実験がある。それは、ネブラスカ州の住人を無作為に選び、ボストン在住の目標人物まで手紙をリレーして届けるという社会実験であり、始点である住人は目標人物を知っていればその人の元へ、知らない場合はこの人物を知っていそうな、ファースト・ネームで呼び合うくらいに近い仲の人へ手紙を託すよう依頼された。結果的に、多くの手紙は届かなかったが、届いた手紙が経由した人数の平均をとると、およそ 6 人のみであり、このことは 6 次の隔たり、もしくは Watts と Strogatz によるスモールワールド [14] の報告から、スモールワールド性と呼ばれている。

一方、地震の規模、山火事、生物の絶滅、金融市場、学术论文の引用数などの次数分布に、べき則が現れることが知られている [34]。このように次数分布にべき則が現れるネットワークのことを、スケールフリー・ネットワークと呼び、多くのネットワークはスケールフリー性を持つ。べき則とは、ある次数 k が全体に占める割合を p_k に対し、

$$p_k \propto k^{-\gamma} \quad (2.54)$$

の関係性を持つことを指す。ここで γ はべき指数と呼ばれる。式(2.54)を両対数グラフに描けば、図 2-4 に示す模式図のように、傾きが $-\gamma$ の傾向を持つ線形になる。また、現実のネットワークにおけるべき指数 γ は $2 \leq \gamma \leq 3$ であることが多い。




図 2-4 べき分布の模式図

スケールフリー・ネットワークにおいて、次数の大きなノードをハブと呼ぶ。例えば、図 2-3 では n_5 のノードがハブである。どの程度の次数を持っているとハブと呼ばれるか、特段決まりはないが、次数分布が正規分布だった場合と比べて、次数 k に対する p_k の減り方は遅いため、巨大な次数を持つノードは少ないながらもそれなりに存在することになる。

以上のような 2 つの特性、すなわち、スモールワールド性とスケールフリー性の両方を持つネットワークを生成するアルゴリズムが、1999 年に Barabási と Albert [30] によって考案された。このアルゴリズムによって生成されるネットワークモデルを Barabási-Albert スケールフリー (BA-SF) モデルと呼ぶ。

ノード数が N の BA-SF モデル生成のアルゴリズムは

1. m_0 個のノードを持つ完全グラフを作成する。

2. m 本のエッジを持つノードを，優先選択で次数の大きいノードに高い確率で繋ぐ．
3. ノード数が N になるまでステップ 2 を繰り返す．

という単純な手順である．この時，新たなノードが選択先としてある次数 d_i を持つノード n_i 選ぶ確率 Π_i は，現在のノード数を N' とすると，

$$\Pi_i = \frac{d_i}{\sum_{j=1}^{N'} d_j} \quad (2.55)$$

で与えられる．以上のステップ 1 から 3 までを簡略化したフローチャートを図 2-5 に示している．




図 2-5 BA-SF ネットワークモデルの生成アルゴリズムのフローチャート

注意が必要なのが，この式(2.55)が計算されるタイミングは，ステップ 2 に入った直後で行われ，ステップ 2 の m 本のエッジの追加は，同時に行われる，つまり，重複なしで必ず m 本のエッジが追加される点である．したがって， m 本のエッジの追加を行う際に，一本ずつ式(2.55)の再計算は行わない．

また，平均次数 x が 2 の倍数の BA-SF ネットワークを作成するには， $m_0 = x + 1$ ， $m = x/2$ にすればよい．すると，ステップ 1 の時の全ノードの次数の和は $x(x + 1)$ であり，ステップ 2 で以降，全ノードの次数の和は x ずつ増えるので，初項が $x(x + 1)$ ，公差が x の等差数列となり，ステップ 2 で追加したノード数は $N - m_0 = N - x$ なので，ステップ 3 終了時の全ノードの次数の和は $x(x + 1) + x(N - (x + 1)) = xN$ となり，平均次数が x となることがわかる．

BA-SF ネットワークモデルの式(2.54)のべき指数 γ はおよそ 3.0 となる．なお，次数分布の導出については参考文献 [26]を参照してほしい．また，次数相関は 0 に近い負の相関を持つ．平均ノード間距離 L については

$$\begin{cases} L \propto \frac{\ln N}{\ln \ln N}, & \gamma = 3 \\ L \propto \ln N, & \gamma < 3 \end{cases} \quad (2.56)$$

であることがわかっており [35]，これは現実よりも小さい値である [36]．クラスター係数 C に

については, $C \propto N^{-3/4}$ が予想された [37]が, その後

$$C = \frac{m-1}{8} \frac{(\ln N)^2}{N} \quad (2.57)$$

であることが示された [38, 39].

2.2.3 ワクチン接種ゲーム

序論で述べたように, 新型コロナウイルス感染症により, 感染症蔓延を防ぐために先制的ワクチン接種率を高めることは, 社会共通の課題といえる. しかし, ワクチン接種の裏にはジレンマが存在すると述べた. そこで, このジレンマを特徴づけるために, 数理疫学の感染症の流行にゲーム理論を適用した枠組みとして登場したのがワクチン接種ゲームである.

序論でも述べたが, ワクチン接種ゲームは, ワクチン接種行動に関する初期のゲーム理論的アプローチ [40, 41]が行われて以来, 様々な研究がワクチン接種ゲームの枠組みを提案している [40–51]. その中でも, 本論文では 2011 年に Fu らが提案した, ネットワーク上のワクチン接種ゲームの枠組み [49]を基盤として, モデルの構築, 解析を行う.

そこで, まず数理疫学の基礎を解説したのち, ネットワーク上でのワクチン接種ゲームの枠組みを説明する.

2.2.3.1 数理疫学

数理疫学には様々なモデルがあるが, 本研究で用いるモデルである, Karmack と McKendrick の最も単純な感染症の数理モデル (SIR モデル) [52]を紹介したのち, 感染症の流行現象における, いくつかの重要な概念について説明する.

2.2.3.1.1 SIR モデル

SIR モデルとは, 1927 年に Karmack と McKendrick [52]によって提案された, 感染する可能性のある感受性人口 (Susceptible, S), 感染しており感染させる能力を持つ感染性人口 (Infectious, I), 感染状態から回復し, 免疫を獲得した回復性人口 (Recovered, R) の 3 つの状態の人口から構成される集団を想定したモデルである. また, このモデルは人口の出生や死亡を想定しておらず, 感染期間中は人口に変動がないものとしてモデルは構築されている. ここで, ある時刻 t における感受性, 感染性, 回復性のそれぞれの人口を $S(t)$, $I(t)$, $R(t)$ で表すと, それぞれの人口の時間発展は

$$\frac{d}{dt} S(t) = -\beta S(t)I(t) \quad (2.58)$$

$$\frac{d}{dt} I(t) = \beta S(t)I(t) - \gamma I(t) \quad (2.59)$$

$$\frac{d}{dt} R(t) = \gamma I(t) \quad (2.60)$$

となる．ここで， β は1日あたり感染者1人あたりの感染率， γ は1日当たりの感染状態からの回復率（感染性から回復性に状態遷移するまでの平均日数が $1/\gamma$ ）とそれぞれ定義する．また，回復性人口 R は，完全免疫を獲得し，その流行期間内では二度と感染しない，つまり，回復性状態から免疫のない感受性状態へは遷移しないことを仮定している．式(2.58)および式(2.59)における $\beta S(t)I(t)$ は，感染性人口が感受性人口に接触した際，感受性人口が感染する割合は感染力に比例することを意味している．以上の一連の流れの模式図を図 2-6 に示している．




図 2-6 SIR モデルの模式図

また，集団サイズを N とすると，ある時刻 t における集団サイズ $N(t)$ は

$$N(t) = S(t) + I(t) + R(t) \quad (2.61)$$

であり，この集団サイズ $N(t)$ の時間1回微分は

$$\begin{aligned} \frac{d}{dt}N(t) &= \frac{d}{dt}S(t) + \frac{d}{dt}I(t) + \frac{d}{dt}R(t) \\ &= -\beta S(t)I(t) + \beta S(t)I(t) - \gamma I(t) + \gamma I(t) \\ &= 0 \end{aligned} \quad (2.62)$$

となることから，確かに集団サイズが一定に保たれていることがわかる．また，式(2.58)から式(2.60)までの式形態は，集団が空間構造を持たず，一様に混合された状態（well-mixed）であることを前提としている．また，集団サイズを無限大にすると， $N = 1$ とでき， S ， I ， R は全体に占める割合とできる．

2.2.3.1.2 感染症蔓延と基本生産数

集団サイズが無限大の SIR モデルにおいて，集団に感染性人口が少数発生した時に，感染症の蔓延（感染性人口が時間とともに増加）が起こる条件を考える．時刻 $t = 0$ における感受性人口の占める割合を $S(0)$ ，感染性人口の占める割合を $I(0)$ とし，回復性人口はいない($R(0) = 0$) とすると，式(2.59)は

$$\frac{d}{dt}I(t) = (\beta S(0) - \gamma)I(t) \quad (2.63)$$

となり、無限大の集団サイズを想定していることから、 $I(0)$ は限りなく 0 に近く、 $R(0) = 0$ であるから、 $S(0)$ は 1 と近似できるため、式(2.63)は

$$\frac{d}{dt}I(t) = (\beta - \gamma)I(t) \quad (2.64)$$

と書き直される。したがって、感染性人口の占める割合 $I(t)$ の一般式は

$$I(t) = I(0)e^{(\beta - \gamma)t} \quad (2.65)$$

となり、節 2.1.5 で紹介したように、マルサス法則に従って感染性人口は指数関数的に増加、減少することになる。したがって、 $\beta - \gamma > 1$ ならば感染症蔓延が起こることになる。ここで、基本生産数 R_0 は

$$R_0 = \frac{\beta}{\gamma} \quad (2.66)$$

と定義される。この基本生産数 R_0 は 1 人の感染者が生産する二次感染者を意味し、 $R_0 > 1$ であれば、感染性人口は時間とともに指数関数的に増加し感染症蔓延を引き起こすが、 $R_0 < 1$ であれば、初期感染者が発生したとしても、感染性人口は時間とともに自然に減少し、感染症蔓延は起こらない。基本生産数 R_0 は感染率 β と回復率 γ の 2 つのパラメータのみに依存しており、このパラメータの値によって解の安定的挙動が変化する。

現実社会における感染症の基本生産数 R_0 の算出は容易ではないが、多くの統計学的研究から、麻疹や百日咳、COVID-19 など、様々な感染症の基本生産数 R_0 が推定されている [53–56]。

2.2.3.1.3 最終感染者サイズ (Final Epidemic Size, *FES*) の導出

前節の初期条件、 $(S, I, R) = (S(0), I(0), 0)$ で始まった感染症蔓延について、最終的に感染しなかった感受性人口が占める割合を $S(\infty)$ とすると、式(2.58)と式(2.60)の右辺の $I(t)$ について整理し、それぞれの式を結合すると、

$$\frac{1}{S(t)} \frac{d}{dt}S(t) = -\frac{\beta}{\gamma} \frac{d}{dt}R(t) \Leftrightarrow \frac{d}{dt}S(t) = -S(t)R_0 \frac{d}{dt}R(t) \quad (2.67)$$

となるので、両辺の t についての積分、

$$\lim_{T \rightarrow \infty} \int_0^T \frac{d}{dt}S(t) dt = \lim_{T \rightarrow \infty} \int_0^T -S(t)R_0 \frac{d}{dt}R(t) dt, \text{ を実行すると}$$

$$S(\infty) = S(0)e^{-R_0(R(\infty) - R(0))} \quad (2.68)$$

を得る。また、前節同様 $S(0)$ は 1 に近似でき、 $R(0) = 0$ であることから、式(2.68)は

$$S(\infty) = e^{-R_0 R(\infty)} \quad (2.69)$$

となる。また、時間が無限に発展した時には、感染者 $I(\infty) = 0$ であることから、回復性人口の割合は $1 - S(\infty)$ となる。したがって、最終感染者サイズ $R(\infty)$ は

$$R(\infty) = 1 - e^{-R_0 R(\infty)} \quad (2.70)$$

となる。

2.2.3.1.4 集団免疫獲得に至るワクチン接種率の目安

基本生産数 R_0 を特定する利点の一つに、集団免疫獲得に必要なワクチン接種率がわかるという点が挙げられる．前節までの、ワクチン接種者が存在しない集団において、初期感染者が現れる前にワクチン接種を行う、すなわち先制的ワクチン接種を行い、完全免疫を獲得した人口の割合を V_0 とし、この割合がいかなる時刻 t においても不変であると仮定すると、式(2.58)から式(2.60)において、 V_0 の割合の人たちは感染ダイナミクスに影響を与えず、時刻 t における感受性人口の割合 $S(t)$ 、感染性人口の割合 $I(t)$ 、回復性人口の割合 $R(t)$ の和は

$$S(t) + I(t) + R(t) = 1 - V_0 \quad (2.71)$$

となる．また、初期感染者が発生した直後においては、初期感受性人口の割合 $S(0)$ は $1 - V_0$ と近似できるので、感染性人口の割合 $I(t)$ の時間発展は

$$\frac{d}{dt}I(t) = (\beta(1 - V_0) - \gamma)I(t) \quad (2.72)$$

となる．したがって、感染性人口の占める割合 $I(t)$ の一般式は

$$I(t) = I(0)e^{(\beta(1 - V_0) - \gamma)t} \quad (2.73)$$

となる．以上より、先制的ワクチン接種を行った場合の基本生産数 R'_0 は式(2.66)の R_0 を用いて

$$R'_0 = (1 - V_0)R_0 \quad (2.74)$$

となる．式(2.74)において、 $R'_0 < 1$ すなわち

$$1 - \frac{1}{R_0} < V_0 \quad (2.75)$$

であれば感染症の蔓延は発生せず、式(2.75)を満たすだけの先制的ワクチン接種を行った人口の割合が達成できれば、感染症蔓延を防ぐことが可能ということになる．また、最終的に感染しなかった感受性人口が占める割合を $S(\infty)$ と最終感染者サイズ $R(\infty)$ は

$$S(\infty) = (1 - V_0)e^{-R_0R(\infty)} \quad (2.76)$$

$$R(\infty) = (1 - V_0)(1 - e^{-R_0R(\infty)}) \quad (2.77)$$

となる．

2.2.3.2 ネットワーク上のワクチン接種ゲームモデル

現実の感染症は、感染者と接触した人に伝播していく．そのため、前節までで想定した、well-mixed で集団のサイズが無限大という仮定は外し、ネットワーク上で感染症が伝播していくモデルを考える必要がある．また、ワクチン接種を行うかどうかの戦略もネットワーク上の隣人とゲームを行い、決定される必要がある．また、本モデルで取り扱う感染症は、インフルエンザや新型コロナウイルスのような、流行周期が周期的なものを想定している、つまり、一度免疫を獲得すると、その免疫が一生持続するような感染症は想定していない．したがって、ワクチン接種を行う戦略をとった者は、感染症蔓延が起こる前にワクチン接種を行わなければならない．そして感染症の流行期を迎え、感染症流行期の終焉ののち、自身の戦略の評価、隣人との比較（ゲーム）を行い、次の流行期に備えるという流れである．以上がネット

ワーク上のワクチン接種ゲームモデルの一連の流れで、図 2-7 にその概念図を示している。

図 2-7 からわかるように、本モデルは図中の下段の戦略更新とワクチン接種を行う第 1 ステージと、上段の感染流行期間の第 2 ステージから成る。

第 1 ステージでは、感染症蔓延が起こる前にワクチン接種を行うか否かの戦略決定を行い、ワクチン接種を行うという戦略 (C 戦略) をとったエージェントはワクチン接種を行い、ワクチン接種を行わない戦略 (D 戦略) をとったエージェントは、そのまま次の感染症流行期間である第 2 ステージを迎える。また、初期感染者が発生し、感染症蔓延、感染症蔓延の終焉を迎えるまでの括りを 1 シーズンと呼び、ワクチン接種を行ったエージェントは、この 1 シーズン中は完全免疫を獲得し、このシーズン中は感染しない。このシーズンが終わった後には獲得した免疫は無効になる。また、シーズン終了時に獲得する利得を表 2-10 に示している。本来、ワクチン接種にはワクチン接種コスト C_v がかかり、感染者は感染コスト C_i を支払うが、通常ワクチン接種ゲームでは感染コスト C_i で利得表を規格化する。そのため、ワクチン接種コストは相対ワクチン接種コスト $C_r = C_v/C_i$ ($0 \leq C_r \leq 1$) が用いられる。つまり、ワクチン接種を行わず、感染もしなかったエージェント (フリーライダー) が最も高い利得を得る。




図 2-7 ネットワーク上のワクチン接種ゲームの概念図

表 2-10 ワクチン接種ゲームの利得行列

状態 戦略	非感染	感染
C	$-C_r$	
D	0	-1

第2ステージでは、感染症の発生、流行の発生、流行の終焉が起こる．この時、感染性エージェントが回復性エージェントへの状態遷移は不可逆的に起こり、そのシーズン中は完全免疫を獲得する．ただし、シーズン終了時には免疫は無効となる．図 2-7 で SIR/V モデルとなっているのは、感染性蔓延が始まる前にワクチン接種を行った状態Vのエージェントが存在し、このエージェントは SIR ダイナミクスに影響を与えないことから、SIR モデルに V 状態を足した、SIR/V モデルとなっている．感染性はシーズン開始時に、ワクチン接種を行っていないエージェントの中からランダムに I_0 人が初期感染者として発生し、ネットワーク上で感染症が伝播していく．ネットワーク上の感染症伝播には式(2.58)から式(2.60)のような方程式で表現することはできず、確率論的シミュレーションが必要となる．

そしてシーズン終了時に各エージェントは利得を得て、次のシーズンに向けて戦略を更新し、次のシーズンを迎えるという一連の流れを、全体の C 戦略と D 戦略の割合が変化しなくなるまで繰り返していく．

2.2.3.2.1 ネットワーク上における感染症の伝播

ネットワーク上の感染症伝播には式(2.58)から式(2.60)のような方程式で表現することはできず、確率論的シミュレーションが必要となる．また、式(2.58)から式(2.60)で前提として well-mixed で無限大の集団サイズの下で使用していた、感受性エージェントが 1 日当たり 1 人当たりに感染させる確率 β は、ネットワーク上における有限の集団サイズを持つモデルには適用できず、well-mixed かつ無限大の集団サイズを持つ、ワクチン接種者がいない状況での最終感染者サイズと同じ割合の最終感染者サイズになるような値を求めて使用しなければならない．そして、ネットワーク上での戦略更新のルールを説明する．

2.2.3.2.1.1 Gillespie アルゴリズム

Gillespie アルゴリズム [57]は確率論的伝播過程を表現するアルゴリズムである．ざっくり説明すると、一度の状態遷移イベントでは 1 つの状態遷移のみ発生し、次の状態遷移イベントが発生するまでの時間も乱数によって求める、というアルゴリズムである．多くの隣人を持つエージェントほど感染リスクは大きくなるので、感受性エージェント i が感染する確率は、そのエージェントの隣人の感染者数 N_i^I に比例すると仮定する [58]．すると、全エージェント

数を N とすると、シミュレーション手順は

1. ある時刻 t におけるあるエージェント i が感受性または感染性エージェントだった場合の状態遷移確立 $p_i^{S \rightarrow I}(t)$ と $p_i^{I \rightarrow R}(t)$ を計算する. 感受性エージェントが感染性エージェントへ状態背にする確率は $p_i^{S \rightarrow I}(t) = \beta N_i^I$ で, 感染性エージェントが回復性エージェントへ状態遷移する確率は $p_i^{I \rightarrow R}(t) = \gamma$ である. 回復性エージェントになった場合は, そのシーズン中は完全免疫を獲得するため, これ以上状態遷移しない. つまり, あるエージェント i のある時刻 t における状態遷移確立を $p_i(t)$ とすると, この時, あるエージェント i が状態遷移する確率は

$$p_i(t) = \begin{cases} p_i^{S \rightarrow I}(t) = \beta N_i^I, & \text{感受性エージェントだった場合} \\ p_i^{I \rightarrow R}(t) = \gamma, & \text{感染性エージェントだった場合} \\ 0, & \text{回復性エージェントだった場合} \end{cases} \quad (2.78)$$

となる. ここで全エージェントの状態遷移確立の和を $\lambda(t)$ とすると,

$$\lambda(t) = \sum_{i=1}^N p_i(t) \quad (2.79)$$

となる.

2. 次の状態遷移事象は時刻 $t' = t + \Delta t$ で起こるが, ここで Δt は平均が $1/\lambda(t)$ である指数分から取得する. つまり, $u \in [0, 1)$ の一樣乱数を, 状態遷移を決定する乱数とは別に発生させ, 時間間隔を $\Delta t = -\ln(1 - u)/\lambda(t)$ で求める.
3. 当然, 状態遷移確立が大きいほど選択される確率は大きいはずなので, 各エージェントの状態遷移確立を $\lambda(t)$ で規格化し, 乱数 $v \in [0, 1)$ と比較し, あるエージェント k が

$$\sum_{i=1}^{k-1} \frac{p_i(t)}{\lambda(t)} \leq v < \sum_{i=1}^k \frac{p_i(t)}{\lambda(t)} \quad (2.80)$$

の関係を満たすならば, エージェント k が状態遷移するとして選択される. また,

$$\sum_{i=1}^0 \frac{p_i(t)}{\lambda(t)} = 0 \quad (2.81)$$

と定義する.

4. 感染者数 $I(t)$ が 0 になるまで 1 から 3 を繰り返す.
という, 以上の 1 から 4 のステップで構成される.

2.2.3.2.1.2 疫学パラメータの設定

一般に, 集団がネットワーク構造を持つ場合は, well-mixed な集団の場合での疫学ダイナミクスと異なることが知られている. よって, 構成するネットワーク構造の影響だけを検討するためには, well-mixed かつ無限大の集団サイズ時に最終感染者サイズと同じになるような, 感受性エージェントが 1 日当たり 1 人当たりに感染させる確率 β を決定する必要がある. 本研究では Fu [49]らが想定した基本生産数 $R_0 = 2.5$, 1 日当たりの回復確率 $\gamma = 1/3$ を用いると,

式(2.70)から最終感染者サイズは $0.8926 \dots \approx 0.9$ となる．よって，本研究で使用する集団サイズ $N = 10^4$ の BA-SF ネットワーク上で，同様にワクチン接種者がいない状態で最終感染者サイズが9割になるような感染率 β を求める．

感染率 β の同定方法は，図 2-8 に示すように，1 日当たり 1 人当たりに感染させる確率 β と最終感染者サイズ FES の関係を表した図のように，感染率 β の値を変化させて，最終感染者サイズ FES が 0.9 となるような感染率 β を求める方法である．図 2-8 では，集団サイズ $N = 10^4$ の平均次数 $\langle k \rangle$ が 4, 8, 12 の BA-SF ネットワークを使用した結果の一例を示している．ネットワーク上にワクチン接種者はおらず，ある感染率 β に対し初期感染者 $I_0 = 5$ として，SIR ダイナミクスを感染性人口が 0 になるまで行う．この 1 シーズンを 100 回行った時の最終感染者サイズの平均値を最終感染者サイズ FES として採用している．また，感染率 β は 0 から 1 まで，0.001 刻みで値を増やしている．

図 2-8 から， $\langle k \rangle = 4$ の時 $\beta \approx 0.578495$ ， $\langle k \rangle = 8$ の時 $\beta \approx 0.198549$ ， $\langle k \rangle = 12$ の時 $\beta \approx 0.117863$ と決定することができ，平均次数が大きいほど，小さな感染率 β の値で最終感染者サイズ FES が大きくなることがわかる．




図 2-8 集団サイズ $N = 10^4$ の平均次数 $\langle k \rangle$ が 4 (赤)，8 (黒)，12 (青) の BA-SF ネットワーク上での 1 日当たり 1 人当たりに感染させる確率 β と最終感染者サイズ FES の関係．図から， $\langle k \rangle = 4$ の時 $\beta \approx 0.578495$ ， $\langle k \rangle = 8$ の時 $\beta \approx 0.198549$ ， $\langle k \rangle = 12$ の時 $\beta \approx 0.117863$ と決定することができる．

2.2.3.2.2 戦略適用方法

ワクチン接種ゲームにおける戦略には、ワクチン接種を行う C 戦略と行わない D 戦略の 2 つが存在する。図 2-7 に示すように、各エージェントはシーズン終了時に、そのエージェントの状態によって表 2-10 で得た利得によって相手とゲームを行い、次のシーズンの戦略を決定する。

通常、人間の意思決定や、物理刺激に対する反応などは非線形な応答を示し、また常に合理的な決定を下すわけではなく、確率的に意思決定を行っている。ゲーム理論の利得に基づいて考えると、相手と自身の利得の差が大きく、相手の利得の方が自身の利得に比べて大きい場合、相手の行動（戦略）を模倣しやすく、相手の利得の方が小さい、または大きくてもさほど差がない場合は模倣しにくい。この特徴を表す関数として Fermi 関数があり、ワクチン接種ゲームでは、一般的に、この Fermi 関数と対戦相手を選んで確率的に戦略を決定する Pairwise Fermi (PW-Fermi) ルールが採用される [49, 59–61]。そこで、この節では、本研究のワクチン接種ゲームで使用する PW-Fermi ルールに従う基本の 3 つの戦略適用方法を紹介する。

2.2.3.2.2.1 Individual-based risk assessment (IB-RA)

Individual-based risk assessment (IB-RA)は個人ベースの戦略更新で、2011 年に Fu ら [49]によって提案された、ワクチン接種ゲームで最も基本的な戦略更新方法である。対戦相手をネットワーク上の自身の隣人から 1 人、ランダムに選出し、その相手の利得と比較し次の戦略を決定するため、個人ベースと呼ばれる。

あるエージェント i が i の第 1 近傍の隣人からランダムに選出したエージェントを j とし、それぞれの利得を π_i , π_j とした時、エージェント i がエージェント j の戦略を模倣する確率 $P(S_i \leftarrow S_j)$ は

$$P(S_i \leftarrow S_j) = \frac{1}{1 + \exp[-(\pi_j - \pi_i)/\kappa]} \quad (2.82)$$

で与えられる。ここで κ は $\kappa > 0$ の実数で、利得差に対する敏感度で本研究では常に $\kappa = 0.1$ を想定する。

もしも、ランダムに選出した隣人の戦略が同じだった場合は、現在の戦略を維持し、違う場合は式(2.82)の確立に従って戦略を更新する。

2.2.3.2.2.2 Strategy-based risk assessment (SB-RA)

IB-RA は個人ベースだったが、Strategy-based risk assessment (SB-RA)は 2014 年に Fukuda ら [62]によって提案され、対戦相手を第 1 近傍の隣人からランダムに選出するところまでは IB-RA と同じだが、使用する利得が対戦相手の戦略の社会平均利得を用いる点が違う。対戦相手の戦略の社会平均利得を $\langle \pi_j \rangle$ とすると、エージェント i がエージェント j の戦略を模倣する確率 $P(S_i \leftarrow S_j)$ は

$$P(S_i \leftarrow S_j) = \frac{1}{1 + \exp[-(\langle \pi_j \rangle - \pi_i)/\kappa]} \quad (2.83)$$

と定義される． κ の値や，対戦相手の戦略が同じだった場合などは IB-RA の時と同じである．

2.2.3.2.2.3 Direct commitment (DC)

Direct commitment (DC)は 2018 年に Iwamura ら [63]によって提案された．DC は IB-RA や SB-RA とは異なる概念で，エージェントがランダムに選出した隣人の戦略を模倣する確率を定義するのではなく，直接どちらの戦略を採用するかを確立を定義する．あるエージェント i が C 戦略を採用する確率 $P(S_i \leftarrow C)$ は

$$P(S_i \leftarrow C) = \frac{1}{1 + \exp[-(\langle \pi_C \rangle - \langle \pi_D \rangle)/\kappa]} \quad (2.84)$$

と定義される．ここで， $\langle \pi_C \rangle$ と $\langle \pi_D \rangle$ はそれぞれ，エージェント i の第 1 近傍の隣人の C 戦略エージェントと D 戦略エージェントの平均利得を表す． κ の値は IB-RA と同じである．また，D 戦略を採用する確率 $P(S_i \leftarrow D)$

$$P(S_i \leftarrow D) = 1 - P(S_i \leftarrow C) \quad (2.85)$$

と定義される．

2.2.3.3 結果の評価に用いる指標

この節では集団サイズが N におけるモデルのシミュレーション結果の評価に用いる指標について紹介する．この節では， N_C を C 戦略エージェント数， N_R を感染したエージェント数とする．

2.2.3.3.1 最終感染者サイズ (Final Epidemic Size, FES)

最終感染者サイズ FES は全体における感染したエージェント数の割合なので，

$$FES = \frac{N_R}{N} \quad (2.86)$$

で与えられる．

2.2.3.3.2 ワクチン接種率 (Vaccination Coverage, VC)

ワクチン接種率 VC はワクチン接種エージェント数が全体に占める割合である．ここで，ワクチン接種者数 N_V は C 戦略エージェントの人数と同じなので，

$$VC = \frac{N_C}{N} \quad (2.87)$$

で与えられる．

2.2.3.3.3 社会平均利得 (Social-Average Payoff, *SAP*)

社会平均利得 *SAP* は、その名の通り、社会全体の平均利得である。感染コストを1とし、相対ワクチン接種コストを C_r とすると、

$$SAP = \frac{1}{N}(-C_r N_C - N_R) = -C_r VC - FES \quad (2.88)$$

となる。

2.3 交通流の基礎

本節では交通流の基本的な変数と、交通流再現のアプローチ方法をいくつか紹介する。

2.3.1 交通流の基本的変数

交通流の基本的な変数は平均速度 $\bar{v}$ 、密度 k 、交通量 Q の3つ [64]がある。これら3つを以下の節で説明する。

2.3.1.1 平均速度, v

平均速度 $\bar{v}$ は2つの定義がある。それは時間平均速度 (time mean speed) v_t と空間平均速度 (space mean speed) v_s である。時間平均速度 v_t は、ある単位時間内に n 台の車両それぞれの速度 v_i を測定した時

$$v_t = \frac{1}{n} \sum_{i=1}^n v_i \quad (2.89)$$

と定義される。一方で、空間平均速度 v_s は、ある単位区間を n 台の車両が通過し、それぞれの車両の通過時間を t_i とする時、

$$v_s = \frac{1}{\frac{1}{n} \sum_{i=1}^n t_i} \quad (2.90)$$

と定義される。一般的に、空間平均速度 v_s よりも時間平均速度 v_t の方が、測定が安易である。

2.3.1.2 密度, k

密度 k は、ある瞬間に単位長さの道路上にある車両台数である。後述するが、実道路上で密度を求めることは困難を極め、例えば、上空からヘリコプターなどで道路を撮影し、特定の区間内にいる車両数を調べることになるため、通常は交通量 Q と空間平均速度 v_s を用いて算出される。

2.3.1.3 交通量, Q

交通量 Q は、ある時間内に道路上の1点を通過する車両台数と定義される。また、すべての車両が同じ速度で走行しているならば、各車両の車間距離に変化がないため、以下の

$$Q = kv_s \quad (2.91)$$

という関係式が成立する。この関係式から密度 k を算出する。以下で具体的な計測方法を示す。車両の流れ方向に対して、上流側を地点 A、下流側を地点 B とする。この地点 A-B の長さを l とし、単位時間あたりの地点 B の通過台数を n とし、それぞれの地点 A-B の通過時間を t_i とすると、式(2.90)より、空間平均速度 v_s は

$$v_s = \frac{l}{\frac{1}{n} \sum_{i=1}^n t_i}$$

となる．また，計測時間を T とすると交通量 Q は

$$Q = \frac{n}{T}$$

となることから，密度 k は

$$k = \frac{Q}{v_s}$$

となるため，最終的に

$$k = \frac{1}{l} \frac{T}{\sum_{i=1}^n t_i} \quad (2.92)$$

となる．

2.3.2 基本図から読み取ることができる交通流の特徴

交通流の特徴を議論するのに基本図を用いる．この基本図は縦軸に交通量 Q ，横軸に密度 k をとる．以下の図 2-9 を用いて交通流の特徴を説明するが，この図では縦軸に 5 分当たりの交通量 q ，横軸に 1km 当たりの密度 ρ で表記していることに注意されたい．




図 2-9 東名高速道路の実測データを基に作成された基本図 [65]を，資料 [66]を参考に手を加えた基本図．

交通流の特徴は大きく 4 つの特徴にわかれる．図中の A にあたる自由相，B にあたるメタ安定相，C にあたる混合相，そして D にあたる渋滞相である．A の自由相は密度が低いため，全車両が十分な車間距離を保って減速せずに一定の速度で走行できるように，密度の増加とともに交通量も増加する線形の特徴を示す．B のメタ安定相は A に比べ高密度になっており，最初のうちは車両台数が増加しても一定の速度で走行できるが，何らかの原因で 1 台の車両が減速した場合，高密度がゆえに前方車両の減速を吸収できるだけの十分な車間距離が確保されていないため，1 台の減速が流れ方向とは逆方向に伝播することで C の混合相に相転移する．実際，このメタ安定相は数分しか確認されず，時間とともに混合相に相転移することが知られている．D の渋滞相はその名の通り渋滞が発生した流れで，stop and go 波などの特徴的な流れが観測される．

モデルの妥当性を判断するのに，この基本図を用いて議論されることが多く，特に重要とされるのは，B のメタ安定相が存在するか否かとされている．これは，この B のメタ安定相から C の混合相への相転移が確認される密度が，世界中の高速道路で観測された基本図をみても，およそ 25[台/km]で一致しており [65]，交通流を特徴づけるものであることから，モデルの妥当性を判断するのに重要な要因になるからである．

2.3.3 時空間図

もう一つ，交通流を理解するのに使用される図がある．これを時空間図といい，縦軸に車両の位置，横軸に時間をとったものを指す．したがって，各プロットはある時刻における車両の位置を示しており，基本図からはわからない，実際の流れを可視化する役目を担っている．特に混合相や渋滞相を観察するのに役立つ．

以下の図 2-10 は，後述する CA モデルの一つである Revised S-NFS モデルのシミュレーションから得られた結果である．縦軸に位置，横軸に時間をとっている．この図中の赤で囲まれた部分は車両が停止していることを表しており，帯状のプロットが時間とともに交通の流れ方向とは反対方向に伝播しているのが見て取れる．この赤で囲まれた部分以外に，時間とともに位置が正の方向に伸びている複数の筋が確認される．この筋の傾きが大きいほど速い速度で移動していることを示しており，複数の帯状のプロットから S 字状になった筋が確認できる．

このように，基本図だけでは確認できない実際の車両の流れを可視化するという役目を持っており，モデルの妥当性を判断する一つの材料になっている．




図 2-10 後述する CA モデルのひとつである Revised S-NFS モデルのシミュレーション結果から得られた時空間図．縦軸に位置，横軸に時間をとっている．車両の進行方向は縦軸の正の方向である．

2.3.4 交通流のモデル化

交通流をモデル化する際，序論の節 1.3 で説明したように，巨視的な視点からのアプローチと微視的な視点からのアプローチの 2 つが存在 [60, 61, 67] し，図 2-11 に示すように流体モデルは分類される．巨視的な視点によるアプローチでは，前節の， $Q - k$ 関係に注目し，系全体を 1 次元流体として扱い数学的観点から交通流を解析する流体モデル [68–72] がある．一方で微視的な視点によるアプローチでは，車両一台一台を粒子とみなし，各車両の運動を連立微分方程式として記述することで系を解析する追従モデル [73–75]，時間と空間の両方を離散化した CA モデル [76–80] がある．次節以降で代表的なマイクロモデルを紹介する．




図 2-11 交通流モデルの大まかな分類．

2.3.5 追従モデル (Optimal Velocity (OV) モデル)

追従モデルである Optimal Velocity (OV)モデルは 1990 年代半ばに Bando ら [81]によって提案されたモデルである。このモデルは前方車両との車間距離に応じて最適な速度を決定し、その最適速度に向けて速度を調節するというのがコンセプトである。また車両の大きさを無視するとしている。このコンセプトを数学的に表記すると

$$\frac{d^2x_n(t)}{dt^2} = a \left\{ V(\Delta x_n(t)) - \frac{dx_n(t)}{dt} \right\} \quad (2.93)$$

となる。ここで a は定数、 $x_n(t)$ は車両番号が n の時刻 t における位置である。また、 $\Delta x_n(t)$ は時刻 t における前方車両と車間距離（つまり $\Delta x_n(t) = x_{n+1}(t) - x_n(t)$ ）であり、 $V(\Delta x_n(t))$ は OV 関数と呼ばれる関数であり、このモデルの中核をなす関数である。OV 関数は前方車両との車間距離に応じた最適速度を返す関数であり、車間距離が小さいほど小さな速度を返し、車間距離が大きいほど大きな速度を返す単調増加関数である。ただし、最大速度は車両の持つ最高速度や制限速度等によって確かに存在するため、最大速度を v_{max} とすると、OV 関数は $v_{max} = V(\Delta x_n \rightarrow \infty)$ に漸近する必要がある。このような特性を持つ OV 関数を Bando らは
$$V(\Delta x_n(t)) = \tanh(\Delta x_n(t) - c) + \tanh c \quad (2.94)$$

としている。ただし c は定数である。ここで OV 関数の特徴を見てみる。

$$\tanh x = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

より、

$$\begin{aligned} \frac{d}{dx} V(x) &= \frac{d}{dx} \left(\frac{e^{x-c} - e^{-(x-c)}}{e^{x-c} + e^{-(x-c)}} + \frac{e^c - e^{-c}}{e^c + e^{-c}} \right) \\ &= \frac{d}{dx} \frac{1 - e^{-2(x-c)}}{1 + e^{-2(x-c)}} \\ &= \frac{2e^{-2(x-c)}(1 + e^{-2(x-c)}) + 2e^{-2(x-c)}(1 - e^{-2(x-c)})}{(1 + e^{-2(x-c)})^2} \\ &= \frac{4e^{-2(x-c)}}{(1 + e^{-2(x-c)})^2} \\ &\therefore \frac{d}{dx} V(x) > 0 \end{aligned}$$

となり、OV 関数は単調増加関数である。また、OV 関数の極限は、車間距離が 0 以上の正の数であることに注意して、

$$\begin{aligned} \lim_{x \rightarrow \infty} V(x) &= \lim_{x \rightarrow \infty} \left(\frac{1 - e^{-2(x-c)}}{1 + e^{-2(x-c)}} + \tanh c \right) \\ &= 1 + \tanh c \end{aligned}$$

となり、OV 関数は発散せず有限である。また、 $V(0) = 0$ は自明であるから、確かに式(2.94)の OV 関数は前述の特徴を満たすことが確認できた。また、図 2-12 に $c = 2$ とした時のグラフを

示している．このグラフからも式(2.94)は前述の特徴を満たしていることが明らかになった．




図 2-12 式(2.94)の定数 $c = 2$ とした時の OV 関数の図で，横軸に車間距離 Δx ，縦軸に $V(\Delta x)$ をとっている．実線が OV 関数で，点線は $\Delta x \rightarrow \infty$ とした時の漸近線である．

2.3.6 Cellular Automaton (CA) モデル

Cellular Automaton (CA) モデルは 1940 年代に John von Neumann と Stanisław Marcin Ulam によって生物の自己複製機能をシミュレーションするためのモデルとして開発された [82]．CA を用いた有名なシミュレーションモデルとして *Scientific American* の 1970 年の 10 月号で紹介された Conway のライフゲーム [83]がある．このライフゲームは 2 次元の格子状に仕切られた「Cell」を用いて，上下左右のセルの状態（生と死のどちらか）によって次タイムステップの自身の状態が左右されるというモデルで，ルール自体はとても単純である．このライフゲームからも読み取れるように，CA モデルの本質は自身も含めることがあるが，自身の周りの状態によって次の自身の状態が左右されるということであり，車の運転も前後左右の車両の挙動を運転する際の判断材料にしていることから相性もいいといえる．ライフゲームではセルの状態は生と死の 2 つの状態であったが，交通流ではセル上に車両が「存在している」か「存在していない」の 2 つの状態が相当する．これは暗に 1 つのセルには 1 台のみ存在できるという体積排除効果を含んでいることを意味している．交通流の CA モデルでは車線が 1 つであればセルの次元は 1 次元なので，前後の車両の挙動に対して自車がどのように振舞うかのルールを定めればよいことになり，このルールによって様々なモデルの創造が可

能である。

2.3.6.1 Rule184

Rule184 [84]とは交通流の CA モデルにおいて最も単純なモデルではあるが、CA モデルの基礎といっても過言ではなく、様々な CA モデルは Rule184 の発展させたモデルになっている。このモデルは 1 次元の CA モデルで、各セルは車両が存在する「1」、車両が存在しない「0」の 2 つの値のどちらか一方をとる。また、次タイムステップでどちらの値になるかは両隣と自身を含んだ 3 つのセルの状態によって決定される。具体的なルールはセルの番号を i で表記し、任意のタイムステップを t と表記する時、番号 i の時刻 t におけるセルの状態は u_i^t で表記されとする。また、進行方向は i に対して正の方向とする。この時、次タイムステップ $t+1$ における番号 i のセルの状態 u_i^{t+1} は以下の表 2-11 の状態遷移表に従って決定される。また、Rule184 の 184 は表 2-11 の下段の「10111000」を 2 進数と捉え、10 進数に直すと 184 になることに由来している。この状態遷移のルールは様々な理解の仕方があり、

- ・「10」が存在する場合、状態を入れ替えて「01」とする。
- ・1 が 0 に続く場合、1 は $i+1$ に移動する。1 が 1 に続く場合、1 は移動せず、1 が続かない 0 も 0 のままである。ただし自身のセル番号は i とする。
- ・0 のセルは $i-1$ のセルの状態を模倣し、1 のセルは $i+1$ のセルの状態を模倣する。ただし自身のセル番号は i とする。

等の理解の仕方がある。最も直感的な理解は 2 番目のもので、交通流の観点からも納得しやすいものである。

このような単純なルールでも停止する車両が流れ方向、つまり i に対して負の方向に伝播するのが確認されている。ただし、肝心なメタ安定相から混合相への相転移は確認されていない。

表 2-11 Rule184 の状態遷移表。

$(u_{i-1}^t, u_i^t, u_{i+1}^t)$	(1,1,1)	(1,1,0)	(1,0,1)	(1,0,0)	(0,1,1)	(0,1,0)	(0,0,1)	(0,0,0)
u_i^{t+1}	1	0	1	1	1	0	0	0

2.3.6.2 Quick Start (QS) モデル

Quick Star (QS) モデルは、見通しの概念を導入したモデル [76]である。このモデルでは、2 セル先、つまり前方車両の先のセルの状態を見通すことができたモデルである。Rule184 では前後のセルの状態しか見ることができなかったため、前方のセルに車両がいる場合は動くことができなかった（表 2-11 の $(u_{i-1}^t, u_i^t, u_{i+1}^t) = (1,1,0)$ が該当する）が、このモデルでは 2 セル先に車両がない場合、前方のセルに車両がいても、この車両は次タイムステップでは前方に進むだろうとして、自車も進むことができるモデル（図 2-13）である。




図 2-13 Quick Start (QS) モデルの具体例. 各行が左側に書かれたタイムステップにおける車両の位置を示している. 進行方向は向かって右方向で, 四角がセル, 黒丸が車両を表しており, 番号は車両番号を表している.

2.3.6.3 Slow Start (SIS) モデル

Slow Start (SIS) モデルは Rule184 に車の慣性を導入したモデル [77] で, ここでいう慣性とは, 一度停止した車両が再始動するまでに時間がかかるということである. ルールは非常に単純で, 一度停止した車両は, 前方に動ける状況になっても 1 タイムステップは停止したままで, 次のタイムステップで再始動するというものである. このモデルの具体例を以下の図 2-14 に示している. この図からも読み取れるように, 再始動が 1 タイムステップ遅れていることが見て取れる.

このように単純なルールを追加しただけでも, メタ安定相から混合相への相転移が確認され, この相転移を表現するには Slow Start が有効であると考えられている.




図 2-14 Slow Start (SIS) モデルの具体例. 形式は図 2-13 と同じである.

2.3.6.4 Revised Stochastic Nishinari Fukui Schadschneider (Revised S-NFS) モデル

2011 年に Kokubo らによって提案された Revised Stochastic Nishinari Fukui Schadschneider (Revised S-NFS) モデル [80] は 2006 年に Sakai らによって提案された Stochastic Nishinari Fukui Schadschneider (S-NFS) モデル [79] にさらに改良を加えたモデルである。この S-NFS モデルは 2004 年に Nishinari らによって提案された Nishinari Fukui Schadschneider (NFS) モデル [78] に確率分岐という概念を持ち込んだモデルである。この NFS モデルは、Rule184 の最高速度 v を $v > 1$ に拡張した Fukui Ishibashi (FI) モデル [85] と、加減速のルールに確率論を導入し、ランダムブレーキのルールを組み込んだ Nagel Schreckenberg (NS) モデル [86]、前節と前々節の QS モデルと SIS モデルを統合した初のモデルである。S-NFS モデルは NFS モデルに新たに NS モデルのランダムブレーキを導入し、さらに NFS の SIS と導入したランダムブレーキの適用に確率を持ち込んだモデルで、Revised S-NFS モデルは、SIS とランダムブレーキ適用の確率をさらに細分化し、QS の見通し数も確率に応じて変更するという修正を加えたモデルである。モデルの発展を S-NFS モデルまでではあるが、2006 年の 11 月 6 日から 8 日にかけて、ここ九州大学筑紫キャンパスで行われた RIAM シンポジウムの酒井らによる報告書 [87] に、図とともにわかりやすく解説されている。

S-NFS モデル以降のモデルは全部で 6 つのルールによって構成されている。それは Rule 1 の加速 (Acceleration), Rule 2 の車両の慣性を取り入れた SIS モデルと QS モデルの見通し機構を組み合わせた再起動の時間遅れ (Slow to start), Rule 3 の QS モデルの見通し機構を取り入れた無駄のない加減速 (Perspective (Quick start; QS)), Rule 4 の条件によって変化する確率に支配され発生するランダムブレーキ (Random brake), Rule 5 の衝突回避 (Avoid collision), そして Rule 6 の車両の前進 (Moving forward) である。これらのルールによる 1 タイムステップにおける漸化式は

Rule 1. “Acceleration”

$$v_i^{(1)} = \begin{cases} \min[V_{\max}, v_i^{(0)} + 1], & g_i \geq G \vee v_i^{(0)} \leq v_{i-1}^{(0)} \\ v_i^{(0)}, & g_i < G \wedge v_i^{(0)} > v_{i-1}^{(0)} \end{cases} \quad (2.95)$$

Rule 2. “Slow to start”

$$v_i^{(2)} = \begin{cases} \begin{cases} \min[v_i^{(1)}, x_{i-S_i}^{t-1} - x_i^{t-1} - S_i] \\ S_i = S, & \text{random}[0, 1) < r, \\ S_i = 1, & \text{random}[0, 1) \geq r \end{cases} & \text{random}[0, 1) < q \\ v_i^{(1)}, & \text{random}[0, 1) \geq q \end{cases} \quad (2.96)$$

Rule 3. “Perspective (Quick start; QS)”

$$v_i^{(3)} = \begin{cases} \min[v_i^{(2)}, x_{i-S_i}^t - x_i^t - S_i] \\ S_i \text{ is same with Rule 2.} \end{cases} \quad (2.97)$$

Rule 4. “Random brake”

$$v_i^{(4)} = \begin{cases} \begin{cases} \max[1, v_i^{(3)} - 1] \\ \begin{cases} p_i = P_1, & g_i \geq G \\ p_i = P_2, & v_i^{(0)} < v_{i-1}^{(0)} \\ p_i = P_3, & v_i^{(0)} = v_{i-1}^{(0)} \\ p_i = P_4, & v_i^{(0)} > v_{i-1}^{(0)} \end{cases}, & \text{random}[0, 1) < 1 - p_i \\ v_i^{(3)}, & \text{random}[0, 1) \geq 1 - p_i \end{cases} \end{cases} \quad (2.98)$$

Rule 5. “Avoid collision”

$$v_i^{(5)} = \min[v_i^{(4)}, x_{i-1}^t - x_i^t + v_{i-1}^{(5)} - 1] \quad (2.99)$$

Rule 6. “Moving forward”

$$x_i^{t+1} = x_i^t + v_i^{(5)} \quad (2.100)$$

である． Rule 1 から 6 までは順番に適用されていく． また， i は車両番号で， $i - 1$ は前方車両を意味する． t は現在のタイムステップで， $t + 1$ は次タイムステップを意味する． x は車両位置を意味し， x_i^t は車両番号 i のタイムステップ t における車両位置となる． また， v は肩の数字の Rule 番号適用後の車両速度を意味しており， $v_i^{(0)}$ はタイムステップ t における速度で， $v_i^{(0)} = x_i^t - x_i^{t-1}$ である． また， g_i は車両番号 i の前方車両との車間距離を表しており， $g_i = x_{i-1} - x_i + 1$ である． $V_{\max}$ は最大速度を表しており， G と P_1 から P_4 は車間距離の閾値と Random brake 適用確率で，それぞれモデルパラメータである． また P_1 から P_4 は $P_1 > P_2 > P_3 > P_4$ の関係が成立するように設定される． q と r は閾値を表すモデルパラメータで， S もまたモデルパラメータである． また， S と S_i はそれぞれ見通し台数を表している．

もともと Rule 5 の式(2.99)の右辺 $v_{i-1}^{(5)}$ は $v_{i-1}^{(4)}$ であったが，後述する第 5 章の研究によって現在の式に変更された． もとの式では衝突を回避するために不自然な減速が観測され，加速しにくいモデルになっていたため修正された． Rule 5 は， Rule 5 適用後の前方車両の速度が参照されているため，モデルを実装する際はループ構造になり，全車両の $v^{(5)}$ が変化しなくなるまで繰り返され， Rule 5 の適用は前方から後方に順に適用するため，このモデルは後述するシーケンシャル・アップデート，周期系境界条件のサーキット状の系を用いてシミュレーションされる．

2.3.7 アップデート方法

アップデート方法は大きく 3 つ [88] あり，それらはパラレル・アップデート，ランダム・アップデート，そしてシーケンシャル・アップデートである． パラレル・アップデートはその名前の通り，1 タイムステップで同時に全車両をアップデートする方法で，実測データを再現する際に使用されることが多い． ランダム・アップデートは 1 タイムステップでランダムに 1 台選んで，その 1 台のみアップデートさせる方法である． このランダム・アップデートには，

ちょうどパラレル・アップデートとランダム・アップデートの中間のような、1 タイムステップに複数台ランダムに選択してアップデートする n - ランダム・アップデートと呼ばれる方法もある。シーケンシャル・アップデートは1 タイムステップで全車両アップデートするが、進行方向に対し、前方から、もしくは後方から順にアップデートする。中にはランダムに順番付けするものもあるが、アップデートする順番が決まっているものを総称してシーケンシャル・アップデートと呼ぶ。

金井ら [88] はアップデート方法によって結果が少なからず左右されるとしており、モデルを構築する際には、どのアップデート方法を採用するか吟味する必要がある。

2.3.8 境界条件

境界条件とは系の境界部の条件のことで、周期系境界条件と開放系境界条件の2つがある。周期境界条件とは図 2-15 から見て取れるように、サーキット、もしくはリング状の系で、両端が繋がっている。一方で、開放系境界条件は図 2-16 から見て取れるように、2 つの確率、流入確率 α と流出確率 β によって系の車両台数を管理する。周期系境界条件ではモデルパラメータを少なくできることが長所で、短所は、系の全台数を変更できないのと、境界条件付近での位置と車間距離の管理に注意が必要な点である。開放系境界条件の長所は、系の全台数を途中で変更することができるのと境界条件を気にしなくていい点で、最大のポイントは恣意的に渋滞を起こすことや、流出確率を一時的に 0 にして、急に 1 にすることで簡単に信号の停止と発進を再現できることである。しかし、モデルパラメータが 2 つ増え、議論しなければならない相図 $\alpha - \beta$ 相が増え、さらに考察が複雑になる点が短所である。

どちらも一長一短なので、目的にあった境界条件を採用することが重要である。




図 2-15 周期系境界条件の模式図.



図 2-16 開放系境界条件の模式図.

参考文献

- [1] 鷲田豊明, 環境ゲーム論—対立と協力, 交渉の環境学— (上智大学出版, 2010).
- [2] 石原英樹, 金井雅之, 進化的意思決定 (シリーズ意思決定の科学) (朝倉書店, 2002).
- [3] 生天目章, ゲーム理論と進化ダイナミクス—人間関係に潜む複雑系 (相互作用科学シリーズ) (森北出版, 2004).
- [4] Jr. John F. Nash, *Equilibrium Points in N-Person Games*, Proceedings of the National Academy of Sciences **36**, 48 (1950).
- [5] 谷本潤, 谷本教授の努力すれば誰にでもわかる環境システムの数理解析基礎, 110 (2012).
- [6] J. von Neumann and O. Morgenstern, *Theory of Games and Economic Behavior* (Princeton University Press, 1944).
- [7] J. Maynard Smith, 進化とゲーム理論—闘争の論理— (産業図書, 1985).
- [8] P. D. Taylor and L. B. Jonker, *Evolutionary Stable Strategies and Game Dynamics*, Math Biosci **40**, 145 (1978).
- [9] J. Hofbauer, P. Schuster, and K. Sigmund, *A Note on Evolutionary Stable Strategies and Game Dynamics*, J Theor Biol **81**, 609 (1979).
- [10] M. A. Nowak, 進化のダイナミクス—生命の謎を解き明かす方程式 (共立出版, 2008).
- [11] E. C. Zeeman, *Population Dynamics from Game Theory* (Springer, New York, 1980).
- [12] M. A. Nowak, A. Sasaki, C. Taylor, and D. Fudenberg, *Emergence of Cooperation and Evolutionary Stability in Finite Populations*, Nature 2004 428:6983 **428**, 646 (2004).
- [13] C. Taylor, D. Fudenberg, A. Sasaki, and M. A. Nowak, *Evolutionary Game Dynamics in Finite Populations*, Bull Math Biol **66**, 1621 (2004).
- [14] D. J. Watts and S. H. Strogatz, *Collective Dynamics of 'Small-World' Networks*, Nature 1998 393:6684 **393**, 440 (1998).
- [15] L. A. N. Amaral, A. Scala, M. Barthélemy, and H. E. Stanley, *Classes of Small-World Networks*, Proc Natl Acad Sci U S A **97**, 11149 (2000).
- [16] F. Liljeros, C. R. Edling, L. A. Nunes Amaral, H. E. Stanley, and Y. Åberg, *The Web of Human Sexual Contacts*, Nature 2001 411:6840 **411**, 907 (2001).
- [17] M. E. J. Newman, *Scientific Collaboration Networks. I. Network Construction and Fundamental Results*, Phys Rev E **64**, 016131 (2001).
- [18] M. E. J. Newman, *Scientific Collaboration Networks. II. Shortest Paths, Weighted Networks, and Centrality*, Phys Rev E **64**, 016132 (2001).
- [19] M. E. J. Newman, *The Structure of Scientific Collaboration Networks*, Proc Natl Acad Sci U S A **98**, 404 (2001).
- [20] H. Ebel, L. I. Mielsch, and S. Bornholdt, *Scale-Free Topology of e-Mail Networks*, Phys Rev E **66**, 035103 (2002).

- [21] J. A. Dunne, R. J. Williams, and N. D. Martinez, *Food-Web Structure and Network Theory: The Role of Connectance and Size*, Proc Natl Acad Sci U S A **99**, 12917 (2002).
- [22] J. Camacho, R. Guimerà, and L. A. Nunes Amaral, *Robust Patterns in Food Web Structure*, Phys Rev Lett **88**, 228102 (2002).
- [23] J. M. Montoya and R. V. Solé, *Small World Patterns in Food Webs*, J Theor Biol **214**, 405 (2002).
- [24] R. Albert, H. Jeong, and A. L. Barabási, *Diameter of the World-Wide Web*, Nature 1999 401:6749 **401**, 130 (1999).
- [25] A. Broder, R. Kumar, F. Maghoul, P. Raghavan, S. Rajagopalan, R. Stata, A. Tomkins, and J. Wiener, *Graph Structure in the Web*, Computer Networks **33**, 309 (2000).
- [26] 増田直紀 and 今野紀雄, 複雑ネットワーク：基礎から応用まで (近代科学社, 2010).
- [27] T. B. Brown, B. Mann, N. Ryder, M. Subbiah, J. Kaplan, P. Dhariwal, A. Neelakantan, P. Shyam, G. Sastry, A. Askell, S. Agarwal, A. Herbert-Voss, G. Krueger, T. Henighan, R. Child, A. Ramesh, D. M. Ziegler, J. Wu, C. Winter, C. Hesse, M. Chen, E. Sigler, M. Litwin, S. Gray, B. Chess, J. Clark, C. Berner, S. McCandlish, A. Radford, I. Sutskever, and D. Amodei, *Language Models Are Few-Shot Learners*, Adv Neural Inf Process Syst **2020-December**, (2020).
- [28] J. A. Bondy and U. S. R. Murty, *Graph Theory with Applications* (American Elsevier Publishing Company, 1976).
- [29] P. Erdős and A. Rényi, *On the Evolution of Random Graphs*, Vol. 5 (Publications of the Mathematical Institute of the Hungarian Academy of Sciences, 1960).
- [30] A. L. Barabási and R. Albert, *Emergence of Scaling in Random Networks*, Science (1979) **286**, 509 (1999).
- [31] M. E. J. Newman, *Assortative Mixing in Networks*, Phys Rev Lett **89**, (2002).
- [32] R. Pastor-Satorras, A. Vázquez, and A. Vespignani, *Dynamical and Correlation Properties of the Internet*, Phys Rev Lett **87**, 258701 (2001).
- [33] J. Travers and S. Milgram, *An Experimental Study of the Small World Problem*, Soc Networks 179 (1977).
- [34] マーク・ブキャナン, 歴史は「べき乗則」で動く — 種の絶滅から戦争までを読み解く複雑系科学 (ハヤカワ文庫, 2009).
- [35] B. Bollobás, *Random Graphs: Second Edition* (Cambridge University Press, 2001).
- [36] R. Cohen and S. Havlin, *Scale-Free Networks Are Ultrasmall*, Phys Rev Lett **90**, 4 (2003).
- [37] R. Albert and A. L. Barabási, *Statistical Mechanics of Complex Networks*, Rev Mod Phys **74**, 47 (2002).
- [38] K. Klemm and V. M. Eguíluz, *Growing Scale-Free Networks with Small-World Behavior*, Phys Rev E **65**, 057102 (2002).
- [39] A. Barrat and R. Pastor-Satorras, *Rate Equation Approach for Correlations in Growing Network*

Models, Phys Rev E Stat Nonlin Soft Matter Phys **71**, 036127 (2005).

- [40] C. T. Bauch, A. P. Galvani, and D. J. D. Earn, *Group Interest versus Self-Interest in Smallpox Vaccination Policy*, Proc Natl Acad Sci U S A **100**, 10564 (2003).
- [41] C. T. Bauch and D. J. D. Earn, *Vaccination and the Theory of Games*, Proc Natl Acad Sci U S A **101**, 13391 (2004).
- [42] C. T. Bauch, *Imitation Dynamics Predict Vaccinating Behaviour*, Proceedings of the Royal Society B: Biological Sciences **272**, 1669 (2005).
- [43] T. C. Reluga, C. T. Bauch, and A. P. Galvani, *Evolving Public Perceptions and Stability in Vaccine Uptake*, Math Biosci **204**, 185 (2006).
- [44] A. P. Galvani, T. C. Reluga, and G. B. Chapman, *Long-Standing Influenza Vaccination Policy Is in Accord with Individual Self-Interest but Not with the Utilitarian Optimum*, Proc Natl Acad Sci U S A **104**, 5692 (2007).
- [45] R. Vardavas, R. Breban, and S. Blower, *Can Influenza Epidemics Be Prevented by Voluntary Vaccination?*, PLoS Comput Biol **3**, e85 (2007).
- [46] R. Breban, R. Vardavas, and S. Blower, *Mean-Field Analysis of an Inductive Reasoning Game: Application to Influenza Vaccination*, Phys Rev E Stat Nonlin Soft Matter Phys **76**, 031127 (2007).
- [47] R. Breban, *Health Newscasts for Increasing Influenza Vaccination Coverage: An Inductive Reasoning Game Approach*, PLoS One **6**, e28300 (2011).
- [48] C. T. Bauch and S. Bhattacharyya, *Evolutionary Game Theory and Social Learning Can Determine How Vaccine Scares Unfold*, PLoS Comput Biol **8**, e1002452 (2012).
- [49] F. Fu, D. I. Rosenbloom, L. Wang, and M. A. Nowak, *Imitation Dynamics of Vaccination Behaviour on Social Networks*, in *Proceedings of the Royal Society B: Biological Sciences*, Vol. 278 (Royal Society, 2011), pp. 42–49.
- [50] M. L. Ndeffo Mbah, J. Liu, C. T. Bauch, Y. I. Tekel, J. Medlock, L. A. Meyers, and A. P. Galvani, *The Impact of Imitation on Vaccination Behavior in Social Contact Networks*, PLoS Comput Biol **8**, e1002469 (2012).
- [51] H. Zhang, F. Fu, W. Zhang, and B. Wang, *Rational Behavior Is a ‘Double-Edged Sword’ When Considering Voluntary Vaccination*, Physica A: Statistical Mechanics and Its Applications **391**, 4807 (2012).
- [52] W. O Kermack and A. G. McKendrick, *A Contribution to the Mathematical Theory of Epidemics*, Proceedings of the Royal Society of London. Series A, Containing Papers of a Mathematical and Physical Character **115**, 700 (1927).
- [53] K. Dietz and D. Schenzle, *Proportionate Mixing Models for Age-Dependent Infection Transmission*, J Math Biol **22**, 117 (1985).
- [54] I. Nåsell, *Hybrid Models of Tropical Infections*, Vol. 59 (Springer, Berlin, 1985).

- [55] A. C. Ghani, N. M. Ferguson, C. A. Donnelly, and R. M. Anderson, *Predicted VCJD Mortality in Great Britain*, Nature 2000 406:6796 **406**, 583 (2000).
- [56] Y. Alimohamadi, M. Taghdir, and M. Sepandi, *Estimate of the Basic Reproduction Number for COVID-19: A Systematic Review and Meta-Analysis*, Journal of Preventive Medicine and Public Health **53**, 151 (2020).
- [57] D. T. Gillespie, *Exact Stochastic Simulation of Coupled Chemical Reactions*, J Phys Chem **81**, 2340 (1977).
- [58] M. J. Keeling and K. T. D. Eames, *Networks and Epidemic Models*, J R Soc Interface **2**, 295 (2005).
- [59] G. Szabó and C. Tóke, *Evolutionary Prisoner's Dilemma Game on a Square Lattice*, Phys Rev E **58**, 69 (1998).
- [60] J. Tanimoto, *Fundamentals of Evolutionary Game Theory and Its Applications*, Vol. 6 (Springer: Tokyo Japan, 2015).
- [61] J. Tanimoto, *Evolutionary Games with Sociophysics: Analysis of Traffic Flow and Epidemics*, Vol. 17 (Springer, Singapore, 2018).
- [62] E. Fukuda, S. Kokubo, J. Tanimoto, Z. Wang, A. Hagishima, and N. Ikegaya, *Risk Assessment for Infectious Disease and Its Impact on Voluntary Vaccination Behavior in Social Networks*, Chaos Solitons Fractals **68**, 1 (2014).
- [63] Y. Iwamura and J. Tanimoto, *Realistic Decision-Making Processes in a Vaccination Game*, Physica A: Statistical Mechanics and Its Applications **494**, 236 (2018).
- [64] 川嶋 弘尚, 交通流, 公益社団法人 日本オペレーションズ・リサーチ学会 機関誌 「オペレーションズ・リサーチ」 Vol.32 No.6 (1987).
- [65] 雄規杉山, 交通流の物理, 日本流体力学会誌「ながれ」 **22**, 95 (2003).
- [66] 金井政宏, 西成活裕, and 時弘哲治, 交通流の確率モデルについて, 2005.
- [67] B. S. Kerner, *Introduction to Modern Traffic Flow Theory and Control: The Long Road to Three-Phase Traffic Theory* (Springer: Berlin Heidelberg, Berlin Heidelberg, 2009).
- [68] L. Michael, James and W. Gerald, Beresford, *On Kinematic Waves II. A Theory of Traffic Flow on Long Crowded Roads*, Proc R Soc Lond A Math Phys Sci **229**, 317 (1955).
- [69] T. Musha and H. Higuchi, *Traffic Current Fluctuation and the Burgers Equation*, Japanese Journal of Applied Physics, Part 1: Regular Papers and Short Notes and Review Papers **17**, 811 (1978).
- [70] B. S. Kerner and P. Konhäuser, *Cluster Effect in Initially Homogeneous Traffic Flow*, Phys Rev E **48**, (1993).
- [71] T. S. Komatsu and S. I. Sasa, *Kink Soliton Characterizing Traffic Congestion*, Phys Rev E **52**, 5574 (1995).
- [72] T. Nagatani, *Thermodynamic Theory for the Jamming Transition in Traffic Flow*, Phys Rev E **58**,

4271 (1998).

- [73] J. Tanimoto and X. An, *Improvement of Traffic Flux with Introduction of a New Lane-Change Protocol Supported by Intelligent Traffic System*, Chaos Solitons Fractals **122**, 1 (2019).
- [74] L. A. Pipes, *An Operational Analysis of Traffic Dynamics*, J Appl Phys **24**, 274 (1953).
- [75] D. C. Gazis, R. Herman, and R. W. Rothery, *Nonlinear Follow-the-Leader Models of Traffic Flow*, Oper Res **9**, 545 (1961).
- [76] R. Barlovic, L. Santen, A. Schadschneider, and M. Schreckenberg, *Metastable States in Cellular Automata for Traffic Flow*, European Physical Journal B **5**, 793 (1998).
- [77] K. Nishinari and D. Takahashi, *Multi-Value Cellular Automaton Models and Metastable States in a Congested Phase*, J Phys A Math Gen **33**, 7709 (2000).
- [78] K. Nishinari, M. Fukui, and A. Schadschneider, *A Stochastic Cellular Automaton Model for Traffic Flow with Multiple Metastable States*, J Phys A Math Gen **37**, 3101 (2004).
- [79] S. Sakai, K. Nishinari, and S. Iida, *A New Stochastic Cellular Automaton Model on Traffic Flow and Its Jamming Phase Transition*, J Phys A Math Gen **39**, 15327 (2006).
- [80] S. Kokubo, J. Tanimoto, and A. Hagishima, *A New Cellular Automata Model Including a Decelerating Damping Effect to Reproduce Kerner's Three-Phase Theory*, Physica A: Statistical Mechanics and Its Applications **390**, 561 (2011).
- [81] M. Bando, K. Hasebe, A. Nakayama, A. Shibata, and Y. Sugiyama, *Dynamical Model of Traffic Congestion and Numerical Simulation*, Phys Rev E **51**, 1035 (1995).
- [82] J. Von Neumann and A. W. Burks, *Theory of Self-Reproducing Automata*. (University of Illinois Press, Urbana, 1966).
- [83] M. Gardner, *MATHEMATICAL GAMES The Fantastic Combinations of John Conway's New Solitaire Game "Life,"* Sci Am **223**, 120 (1970).
- [84] S. W. World and S. Vll, *Theory and Applications of Cellular Automata* (World Scientific, Singapore, 1986).
- [85] M. Fukui and Y. Ishibashi, *Traffic Flow in 1D Cellular Automaton Model Including Cars Moving with High Speed*, J Physical Soc Japan **65**, 1868 (1996).
- [86] K. Nagel and M. Schreckenberg, *A Cellular Automaton Model for Freeway Traffic*, Journal de Physique I France **2**, 2221 (1992).
- [87] 酒井聡士, 西成活裕, and 飯田晋司, 確率的に拡張された交通流セルオートマトンの相転移ライン導出, 2007.
- [88] 金井政宏, 西成活裕, and 時弘哲治, 交通流モデルにおける Update Rule 依存性, 2006.

第3章 ワクチン接種ゲームにおけるハブエージェントの戦略更新機構に関する研究

3.1 はじめに

2003 年の SARS や 2009 年の豚インフルエンザ, そして, 2019 年から現在も猛威を振るっている新型コロナウイルスをはじめとする感染症の蔓延を抑えることは, 社会全体で取り組むべき課題であり, このような社会背景により, 近年, ワクチン接種ゲームは盛んに研究されてきた. ワクチン接種ゲームのモデルは, Bauch [1]や Fu ら [2]といった先駆者によって形作られ, 免疫学的知見に基づく感染症伝播だけでなく, 感染症蔓延に対する, 人々のワクチン接種行動も考慮した数理モデルとなっている. 先の例で挙げたような感染症に対しては, 先制的ワクチン接種が効果的な対策となることが知られている [3]. 集団が十分なワクチン接種率を得て, 感染症蔓延が起きなくなる「集団免疫」を作り出すには, 集団内の人々の自主的なワクチン接種が求められる. しかし, 通常こういったワクチン接種にかかるコストは低くなく, 集団免疫を達成するとワクチン接種を行っていない, つまり, 免疫を獲得していない人も感染しなくなるため, この集団免疫にただ乗りしようとするインセンティブが働き, みながワクチン接種を行わなくなり, 集団免疫が崩壊することで, 再び感染症蔓延が発生してしまう. このように, 社会全体にとっての最適行動と個人にとっての最適行動に乖離があり, このことを「ワクチン接種に伴うジレンマ」という. Tanimoto [4, 5]によるとこの「ワクチン接種に伴うジレンマ」は公共財ゲームやマルチプレイヤーのチキンゲームに共通してみられる社会的ジレンマと同じ構造を持つとされている.

ワクチン接種ゲームに関して, 過去数年間にわたり多くの研究がなされてきた. これらの既往研究の多くは, Fu ら [2]が提案したモデル, すなわち MAS を使用したモデルが多く使用されている. 後の理論的アプローチでは, 単一シーズン (感染性が発生してから収束するまでの期間を 1 シーズンと呼ぶ) における感受性 (Susceptible) - 感染性 (Infectious) - 回復性 (Recovered) の SIR モデルや, 連続シーズンにおける人間の意思決定プロセスに関する研究が行われてきた [6–8]. このような単純なモデルだけではなく, 最近では口コミ情報 (病気に備えるように促す情報) がワクチン接種行動を促すのにどの程度有効かを確かめる研究 [9, 10]や, ワクチン接種の有無のほかに, マスクの着用などの中間的な予防行動が感染症蔓延を抑えるのにどの程度有効かを確かめた研究 [11–13]や, 完全免疫を獲得できない場合におけるワクチン接種でも, 感染症蔓延を抑えるのに有効かどうかを確かめる研究 [14], 複数のネットワークを持つ集団は単一ネットワークのみを持つ集団とでは, 行動原理がどのように違うかを確かめた研究 [15, 16]などがある. さらに, これらはすべて先制的ワクチン接種のみを扱っていたが, 現実には感染症の蔓延が始まってからワクチン接種を行う「遅延ワクチン接種」というものもあり, これについてのモデルも研究されている [17].

これまでのワクチン接種ゲームに関する研究では, 個人のワクチン接種行動に関する戦略

決定には、Fu ら [2]が提案したモデルで使用された PW-Fermi に基づく戦略更新ルールが一般的で、ワクチン接種ゲームにおける最適な戦略更新ルールに関する研究は少ない。この PW-Fermi に基づく戦略更新は、空間構造を持つ囚人のジレンマ (Spatial Prisoner's Dilemma, SPD) ゲームで一般的に用いられるもの [18]で、焦点となる個人がその隣人との利得差に応じて、その隣人の戦略を模倣するかどうかを決定するというものである。これは個人間で利得差を比較するため、節 2.2.3.2.2.1 で説明したように IB-RA [2]と呼ばれる。このほかにも節 2.2.3.2.2.2 と節 2.2.3.2.2.3 で説明した、個人と任意の隣人の戦略と同じ戦略を持つ社会全体の平均利得を比較する SB-RA [19, 20]や、Iwamura ら [21]によって提案された、隣人ではなく、ワクチン接種者の利得と非ワクチン接種者の利得を比較し、直接戦略を採用する、Kuga ら [7]によって DC と名付けられた、SPD ゲームで広く適用される「アスピレーションモデル」 [22]に似た戦略更新方法がある。

以上に挙げた 3 つの戦略更新の中でも、IB-RA と SB-RA は比較する利得に違いはあるものの、隣人の選択の仕方はランダムに選出する点で完全に同一である。しかし、現実社会の人々は、比較相手を隣人からランダムに選択するだろうか。ワクチン接種においては、自身と同じような感染リスクを持つ隣人の戦略を模倣しやすいはずである。このことは Edge ら [23]によって、医師が季節性のインフルエンザワクチン接種を行う際に、ほかの医師がワクチン接種を行っているかどうかを参考にする傾向があることが明らかにされていることから、正当化される。以上の点を踏まえ、本研究では PW-Fermi に基づいた新しい戦略更新ルールを定義し、このルールが感染症蔓延に対し、どのような効果を発揮するかを定量的に示す。

本章の構成は次の通りで、節 3.2 で新しい戦略更新ルールを導入したモデルの構築について説明し、節 3.3 でモデルの数値結果と結果に対する考察、そして節 3.4 で結論を述べる。

3.2 モデルの概要

本モデルでは、2011 年に Fu ら [2]によって提案されたモデルに、我々の研究グループが改良を重ねたモデル [19, 20]を基に、モデル化を進める。

ここでは、集団サイズが N のネットワーク上に配置されたエージェントの集団を考え、この集団内に季節性のインフルエンザのような感染症の蔓延と、初期感染者が現れる前にワクチン接種行動を行うと仮定する。このネットワークには Barabási と Albert アルゴリズム [24]によって生成された BA-SF を使用する。

3.2.1 ワクチン接種ゲームの概要

図 3-1 にワクチン接種ゲームの概念図を示している。




図 3-1 本モデルのワクチン接種ゲームの概念図。本モデルはローカル時間 t_l とグローバル時間 t_g の2つの異なる時間スケールを持つ。ローカル時間 t_l においては、任意のシーズン k 内で適用される時間スケールで、感染症の伝播が発生するワクチン接種はこのシーズン突入前に戦略に応じて行う。一方、グローバル時間 t_g では時間経過に伴う戦略の変化を取り扱う。図中の青い円はワクチン接種状態 V 、白い円は非ワクチン接種状態 NV を示している。状態 NV の中には感染せず感受性状態 S を保つものもいるが、感染性状態 I になり、その後回復性状態 R に状態遷移する。

グローバル時間 t_g では、シーズンが始まる前にワクチン接種キャンペーンを行っており、各エージェントが前のシーズン終了時に戦略更新で決定した戦略に基づいて、C 戦略をワクチン接種、D 戦略を非ワクチン接種としてワクチン接種を行う。つまり、C 戦略エージェントはワクチン接種状態 V となり、D 戦略エージェントは非ワクチン接種状態 NV となる。ワクチン接種では、コスト C_v を支払い、このシーズン内のみではあるが、完全免疫を獲得する。非ワクチン接種者は免疫を獲得していないので、感染症に罹患する可能性がある。

シーズン内のローカル時間 t_l では、 $t_l = 0$ において、状態 NV の中から初期感染者が I_0 人発生し、その後 Gillespie アルゴリズム [25]に従って感染症が蔓延し、収束していく。この時、状

態 NV だったエージェントは、シーズン内では感受性状態 S になり、感染したエージェントは感染性状態 I になり、その後回復性状態 R に状態遷移し、そのシーズン内では完全免疫を獲得する。そして、既往研究 [19–21] にならい、感染率 $\beta[\text{day}^{-1}\text{person}^{-1}]$ と回復率 $\gamma[\text{day}^{-1}]$ を仮定し、基本生産数 $R_0 = 2.5$ および回復率 $\gamma = 1/3$ とし節 2.2.3.2.1.2 に従って、最終感染率 FES が 0.9 となるような感染症 β を決定する。 t_l は感染状態 I のエージェントがいなくなるまで進む。

シーズンが終了すると、各エージェントは状態に応じた利得を獲得する。ワクチン接種コストは C_v で、感染したエージェントは感染コスト C_i を支払う。ここで感染コスト $C_i = 1$ とし、感染コストに対するワクチン接種コスト、つまり相対ワクチン接種コスト $C_r = C_v/C_i$ ($0 \leq C_r \leq 1$)を用いることにする。コストは支払うので、ワクチン接種エージェントは $-C_r$ を、感染したエージェントは -1 を、ワクチン接種を行わず感染しなかったエージェントは 0 を獲得する。この獲得したコストを用いて戦略更新を行い、C 戦略と D 戦略の比率が変化しなくなるまで t_g は進む。

3.2.2 戦略更新

前節で述べたように、各エージェントはシーズン終了時における状態に応じて利得を獲得し、その利得を用いて戦略更新を行う。本研究では PW-Fermi の概念を適用するところは従来モデルと同じだが、従来モデルでは対戦相手を隣人からランダムに選出していた（以降デフォルトと呼ぶ）が、本モデルでは同じような感染リスク、つまり同じような隣人数（度数）を持つ隣人が優先的に選択される。これは、例えば医者や看護師などは、より高い度数を持つエージェントとしてモデル化され、リモートワークや人とのかかわりが少ない状態で生活ができる人は、より低い度数を持つエージェントとしてモデル化することで再現できる。感染リスク、つまり度数が大きい人が、同じく度数が大きい人の情報を参照することは、医者が知り合いの医者に相談して、ワクチン接種を行うかを決定する点で理にかなっている。

しかし、この情報収集には何も自身の直接の知り合い（第 1 近傍の隣人）からのみ取得するとは限らず、知り合いの知り合い（第 2 近傍の隣人）、またはその知り合い（第 3 近傍の隣人）までを参照する可能性もある。本モデルでは、こうした第 2 近傍、または第 3 近傍以降の情報を参照する際に、参照コストはかからないと仮定する。

以上の観点から次のようにモデル化する。あるエージェント i が PW-Fermi プロセスで隣人から 1 人を対戦相手として選出するとする。この時、第 ℓ 近傍の隣人までを参照範囲とし、第 1 近傍から第 ℓ 近傍の隣人の全隣人数を $N_{i,\ell}$ とする。そして、隣人の集合を $\{X_{i,\ell}\}$ として表し、各隣人を $A_{i,1}, \dots, A_{i,N_{i,\ell}}$ とし、各隣人エージェントの次数は $k(A_{i,\ell}), \dots, k(A_{i,N_{i,\ell}})$ で表されたとする。もちろん、エージェント i の次数 $k(i)$ は第 1 近傍までの隣人数なので $k(i) = N_{i,1}$ である。この次数の集合を $\{K_{i,\ell}\} = \{k(A_{i,m} | A_{i,m} \in \{X_{i,\ell}\})\}$ とする。もう一つ、次数について集合を定義する。次数の集合 $\{K_{i,\ell}\}$ の最大値を $K_{i,\ell}^{\max}$ とすると、集合 $\{K_{i,\ell}\}$ の重複を許さない次数の集合、つまり次数の種類集合 $\{D_{i,\ell}\}$ は $1, \dots, K_{i,\ell}^{\max}$ となる。この時、任意の次数 d ($d \in \{D_{i,\ell}\}$)を持つ第 ℓ 近傍まで

の隣人の集合を $\{X_{i,\ell}^d\}$ とし、この集合の要素数（人数）を $\#\{X_{i,\ell}^d\}$ とする．つまり、第1近傍から第 ℓ 近傍の隣人の全隣人数を $N_{i,\ell}$ は $N_{i,\ell} = \sum_{d \in \{D_{i,\ell}\}} \#\{X_{i,\ell}^d\}$ となる．

ここで、エージェント i が対戦相手として次数 K_L ($K_L \in \{D_{i,\ell}\}$)を選択する確率 $P_d(K_L)$ は

$$\begin{cases} P_d(K_L) = \frac{f(K_L)}{\sum_{d \in \{D_{i,\ell}\}} f(d)} \\ f(d) = \frac{1}{|k(i) - d| + 1} \end{cases} \quad (3.1)$$

と定義される．また、次数 K_L が選択されて、その次数 K_L を持つ隣人の集合 $\{X_{i,\ell}^{K_L}\}$ からエージェント j ($j \in \{X_{i,\ell}^{K_L}\}$)が選択される確率 $P_p(j)$ は

$$P_p(j) = \frac{1}{\#\{X_{i,\ell}^{K_L}\}} \quad (3.2)$$

と定義される．つまり、式(3.1)はルーレット選択 [26]で式(3.2)はランダム選択であるといえる．

隣人を選択した後の戦略更新ルールは、IB-RA [2]と SB-RA [19, 20]の2つを採用する．DCは隣人選択を行わず、直接戦略を決定するため、今回は戦略更新ルールとしては採用しない．

Individual-based risk assessment (IB-RA)

式(3.2)で選択した隣人エージェント j の戦略 S_j を模倣する確率 $P(S_i \leftarrow S_j)$ は

$$P(S_i \leftarrow S_j) = \frac{1}{1 + \exp[-(\pi_j - \pi_i)/\kappa]} \quad (3.3)$$

で与えられる．ここで式中の π_i と π_j はそれぞれ、エージェント i と j の利得であり、利得差に対する感度 κ の値は既往研究にならい 0.1 とする．

Strategy-based risk assessment (SB-RA)

IB-RA 同様、式(3.2)で選択した隣人エージェント j の戦略 S_j を模倣する確率 $P(S_i \leftarrow S_j)$ は

$$P(S_i \leftarrow S_j) = \frac{1}{1 + \exp[-(\langle \pi_j \rangle - \pi_i)/\kappa]} \quad (3.4)$$

で与えられる．式中の π_i と κ は IB-RA と同じである． $\langle \pi_j \rangle$ はデフォルトの場合はエージェント j と同じ戦略を持つ社会全体の平均利得であるが、本モデルの場合では、エージェント j と同じ戦略かつ同じ次数を持つ社会全体の平均利得を指す．

3.2.3 MAS への導入

本モデルでは、集団サイズ N が 10^4 で、平均次数 $\langle k \rangle = 8$ の BA-SF を想定する．また本モデル内では、本モデルの戦略更新ルールが与える影響を明確にするために、すべてのシミュレーションで同じ BA-SF を用いる．前述の通り、基本生産数 $R_0 = 2.5$ で回復率 $\gamma = 1/3 [\text{day}^{-1}]$ とし、感染率 $\beta [\text{day}^{-1} \text{person}^{-1}]$ については、ワクチン接種者がいない状態で最終感染者サイズ FES が 0.9 になるような値を採用する．また、初期感染者数 I_0 は 5 とし、各相対ワクチン接種

コスト C_r に対し，初期戦略比を1:1として毎シーズン初期感染者をランダムに選出し，戦略比が変化しなくなるまでシーズンを繰り返し（これを1エピソードと呼ぶ），このエピソードを100回行い，その平均値を結果として採用する．また，結果の評価には最終感染者サイズ FES ，ワクチン接種率 VC ，社会平均利得 SAP を用いる．

3.3 結果と考察

図 3-2 にデフォルト（対戦相手をランダムに選択する）の PW-Fermi の隣人選択範囲を第 1 近傍から第 3 近傍まで広げた時の結果を示している。図から読み取れるように、 $\ell = 2$ と 3 の時では、ワクチン接種率 VC は $\ell = 1$ の時よりもやや低下し、最終感染者サイズ FES は $\ell = 1$ の時よりも $\ell = 2$ と 3 の方がわずかに大きくなっている。これにより、社会平均利得 SAP はワクチン接種率と最終感染者サイズの増減分が互いに打ち消すことで、参照範囲を広げてもほとんど変化していないことがわかる。この傾向は IB-RA と SB-RA どちらも同様に観察される。

3.3.1 同じような感染リスクを持つ隣人を PW の対戦相手として優先的に選択する効果

図 3-3 にデフォルトの $\ell = 1$ の時の結果と、本モデルの $\ell = 1, 2, 3$ の時の結果を示している。まず、左側の IB-RA の結果に注目する。本モデルの $\ell = 1$ とデフォルトを比較すると、本モデルの方が、相対ワクチン接種コスト C_r 全域で、ワクチン接種率 VC ((a-1)の結果) が著しく低いことがわかる。そのため最終感染者サイズ FES ((b-1)の結果) はデフォルトよりも悪くなっている。しかし、社会平均利得 SAP ((c-1)の結果) はほぼ同じである。本モデルの $\ell = 2$ では、ワクチン接種率 VC が $\ell = 1$ の時よりもさらに低くなっている。しかし、最終感染者サイズ FES はデフォルトに比べて若干高い程度でほとんど変わらない。したがって社会平均利得 SAP は大幅に改善されている。本モデルの $\ell = 3$ では、 $\ell = 1$ よりも低い $\ell = 2$ よりも高く、最終感染者サイズ FES はデフォルトよりも低くなっており、ワクチン接種率は高いが、最終感染者サイズが小さくなったことで、社会平均利得 SAP が $\ell = 2$ とほぼ変わらないか、良くなっている。

次に右側の SB-RA について考察する。基本的な傾向は IB-RA の時と同様である。しかし、デフォルトと比較した際の改善幅は IB-RA よりも顕著になっている。IB-RA ではデフォルトよりも低い最終感染者サイズの結果を得るのに $\ell = 3$ が必要だったが、SB-RA では $\ell = 2$ で、ほとんどの相対ワクチン接種コスト C_r の範囲で、デフォルトよりも低い結果を示している。デフォルトよりもワクチン接種率 VC が低いにもかかわらず、最終感染者サイズ FES も低いいため、社会平均利得 SAP は大幅に改善されている。したがって、SB-RA では $\ell = 2$ で十分な効果を得ることが可能で、これは IB-RA が個人ベースなため、局所的な情報しか持っていないが、SB-RA は社会平均との比較なので、より多くの情報を含んでいるため、より小さな参照範囲で十分な効果が出たと考えられる。

ではなぜ本モデルでは PW の対戦相手をランダムに選択するデフォルトに比べ、ワクチン接種率 VC と最終感染者サイズ FES が小さいにもかかわらず、より高い社会平均利得 SAP を達成することができるのだろうか。一般的には、ワクチン接種率と最終感染者サイズは、ワクチン接種率が低いほど最終感染者サイズが大きくなるという負の相関関係にある。しかし、本モデルではそうではないため、何か特定のメカニズムが背景に存在するはずである。

その特定のメカニズムとは、本モデルが PW の対戦相手として、同程度の感染リスクを持つ者、本モデルでは同程度の次数を持つ者を優先的に選択しやすいというモデルのため、高

次数を持つハブエージェントに強くワクチン接種を促すためだと考えられる。ハブエージェントは多くの隣人、つまり多くの感染経路を持つため感染しやすいのに対して、低次数のエージェントは、感染経路が少ないため感染しにくいいため、ワクチン接種を行わずにハブエージェントが作り出した集団免疫にただ乗りしたのではないかと考えられる。

感染症の大流行には「super-spreader」の存在が大きい。つまり、ワクチン接種を行わず感染状態となったハブエージェントがそれにあたり、このハブエージェントは多くの隣人に感染症を伝播し得るため、感染症大流行のトリガーになり得る。つまりハブエージェントがほかの低次数のエージェントよりも優先的にワクチン接種を行うと、感染症の大流行を未然に防ぐことが可能となる。このことは、社会平均利得SAPを最大化するために、ハブエージェントへの補助金を通してハブエージェントのワクチン接種率を高めることが、最適な政策の一つであるという研究 [27, 28] から明らかである。

もう一つ重要な点がある。感染症が社会全体に伝播することを効率的に防ぐためには、ワクチン接種者が集団内で偏って存在するのではなく、万遍無く存在することが望ましい。これは Fukuda ら [29] の研究によって明らかにされている。Fukuda らは戦略更新ルールに SB-RA を用いたワクチン接種ゲームを行った。ただし、感染伝播のネットワークには格子ネットワークを、戦略更新の隣人選択用のネットワークには BA-SF を用いた。その結果、ワクチン接種者が格子ネットワーク上にまばらに分布することで、ワクチン接種率が低くても効率的に感染症伝播を抑えることが可能であるということを発見した。この特徴は SPD ゲームにおけるネットワーク互惠と対照的な特徴といえる。SPD では C 戦略が消滅せずに生き残り続けるには、「C-cluster」と呼ばれる C 戦略の塊が重要で、この塊を生成することで、D 戦略からの搾取から身を守ることができるとされている [30]。本モデルでも SPD と同様に、Fukuda ら [29] の研究が明らかにした、ワクチン接種者がまばらに存在したことで効率的に感染症蔓延を抑えたのではなく、ハブエージェントがワクチン接種者となる「C-cluster」を形成したことで、効率的に感染症蔓延を抑えたのではないかと考えている。

以上の仮説を検証するために、図 3-4 と図 3-5 を作成した。これらの図はワクチン接種率 VC と最終感染者サイズ FES を高次数帯、中次数帯、低次数帯ごとに結果を示した図になっており、高次数帯、中次数帯、低次数帯の定義と人口比は、それぞれ、高次数帯： $k \geq 10$ (18%)、中次数帯： $9 \geq k \geq 6$ (29%)、低次数帯： $k \leq 5$ (53%) である。

まずはデフォルトのケースに注目する。デフォルトのワクチン接種率 VC は次数帯にあまり相関がない。IB-RA では対戦相手として個人を選択するため、多少高次数帯の方がワクチン接種率は高くなっているが、SB-RA ではほとんど差がないことが見て取れる。

一方、本モデルではどうだろうか。本モデルでは高次数帯のワクチン接種率 VC はデフォルトとさほど変わらないが、中次数帯と低次数帯のワクチン接種率 VC は低くなっているにもかかわらず、SB-RA では $\ell = 2$ 、IB-RA では $\ell = 3$ の時点で、すべての次数帯の最終感染者サイズ FES が低くなっている。これは、ハブエージェントが第 2 近傍、第 3 近傍の同程度の次数を持

つハブエージェントを参照し、C 戦略を模倣する、または保持しているということを証明している．その結果、ハブエージェント以外のエージェントは、ハブエージェントが作り出した集団免疫にただ乗りすることができ、「super-spreader」となり得るハブエージェントが感染しないことで、中・低次数帯のワクチン接種率が低いにもかかわらず、全体の最終感染者サイズ FES を低くすることができたといえる．




図 3-2 デフォルトの時の隣人の選択範囲を第 1 近傍から第 3 近傍まで変化させた時の結果．縦軸は上から(a-*)はワクチン接種率 VC ，(b-*)は最終感染者サイズ FES ，(c-*)は社会平均利得 SAP で，横軸は相対ワクチン接種コスト C_r を変化させた時の結果を示しており，左側の(*-1)は IB-RA，右側の(*-2)は SB-RA の時の結果を示している．また，黒，青，赤の順にそれぞれ $\ell = 1, 2, 3$ の時の結果を示している．




図 3-3 本モデルの隣人選択ルールを適用した時の結果. パネルの配置と縦軸, 横軸はデフォルトの時と同じである. 黒の破線はデフォルトの $\ell = 1$ の時の結果で, 実線の黒, 青, 赤の順にそれぞれ本モデルの $\ell = 1, 2, 3$ の時の結果を示している.




図 3-4 本モデルの隣人選択ルールを適用した時の次数の分類ごとのワクチン接種率 VC の結果. 上から(a-*)は高次数帯のワクチン接種率, (b-*)は中次数帯のワクチン接種率, (c-*)は低次数帯のワクチン接種率で, 横軸は相対ワクチン接種コスト C_r を表している. 左側の(*-1)は IB-RA, 右側の(*-2)は SB-RA の結果を示している. 黒の破線はデフォルトの $\ell = 1$ の時の結果で, 実線の黒, 青, 赤の順にそれぞれ本モデルの $\ell = 1, 2, 3$ の時の結果を示している.




図 3-5 本モデルの隣人選択ルールを適用した時の次数の分類ごとの最終感染者サイズ FES の結果. 上から(a-*)は高次数帯の最終感染者サイズ, (b-*)は中次数帯の最終感染者サイズ, (c-*)は低次数帯の最終感染者サイズで, 横軸は相対ワクチン接種コスト C_r を表している. 左側(*-1)は IB-RA, 右側(*-2)は SB-RA の結果を示している. 黒の破線はデフォルトの $\ell = 1$ の時の結果で, 実線の黒, 青, 赤の順にそれぞれ本モデルの $\ell = 1, 2, 3$ の時の結果を示している.

3.3.2 模倣の概念に従う戦略更新のための適切な情報

図 3-6 では、IB-RA と SB-RA の結果を比較している。左側の(*-1)では、Kuga ら [7]の、集団サイズが無限大の well-mixed な集団を仮定した平均場近似に基づく解析モデルの結果で、右側の(*-2)ではデフォルトの $\ell = 1$ と、本モデルの $\ell = 3$ の結果をそれぞれ示している。

まずは右側の(*-2)に注目し、デフォルトと本モデルの結果を比較する。本モデルではデフォルトに比べ、ワクチン接種率 VC と最終感染者サイズ FES をともに小さくすることで、社会平均利得 SAP を高くすることができていることを再確認することができる。これは同程度の感染リスク、すなわち次数を持つ隣人を優先的に選択する機構が、ハブエージェントへのワクチン接種を促し、低次数の多くのエージェントが集団免疫にただ乗りすることができるためである。

一方で、感染症伝播と戦略更新の情報伝播にネットワーク構造を持たない左側の(*-1)の結果では、相対ワクチン接種コスト C_r が 0.5 以下である場合、SB-RA は IB-RA よりも若干高いワクチン接種率 VC となっており、それに伴い最終感染者サイズ FES も小さくなることで社会平均利得 SAP も IB-RA よりも優れた結果を示している。これは、IB-RA が「個人同士の利得比較」であるのに対し、SB-RA が「社会平均利得と個人の利得の比較」であるため、SB-RA の方が戦略更新に対し、より有意義な情報を提供できるからである。

しかし、このような SB-RA が優れているという内容は、ネットワーク構造を持つ MAS のシミュレーション結果である、右側のデフォルト ((*-2)の破線)からは読み取ることができず、むしろ相対ワクチン接種コスト C_r が大きくなるにつれて IB-RA との差がより顕著になっている。確かに、社会平均情報（メディアを通じて提供される情報）は基盤となるネットワークが次数分布を持たない場合は非常に有効である。しかし、BA-SF のような次数分布を持ち、感染リスクに偏りがあるような集団内では、社会平均情報はむしろ逆効果となるということである。なぜなら、たまたまワクチン接種者がハブエージェントに多くいた場合や、たまたま感染症の蔓延が比較的小さくなった場合では、ただ乗りできたエージェントがたくさん存在するため、D 戦略エージェントの社会平均利得は非常に高くなる。このような場合、ハブエージェントが、この D 戦略エージェントの社会平均利得を参照してしまうと、確実に D 戦略になってしまい、ハブエージェントが「super-spreader」となり感染症の蔓延が発生してしまうためである。このように、BA-SF のように個人の感染リスクが異なる集団内においては、社会平均情報は正しい情報を伝えることができず、たまたま多くのただ乗り成功したエージェントがいた場合には、社会平均情報は 0 に引き寄せられるため、ハブエージェントに誤った情報を与えてしまう。

一方で、「個人同士の利得比較」である IB-RA では、比較相手となる D 戦略の利得は、ただ乗り成功した最大値となる 0 か、ただ乗り失敗し感染した最小値となる -1 の、2 値しか取り得ない。ハブエージェントの周りのエージェントは感染しやすいため、ワクチン接種を行っていないエージェントはただ乗り失敗し、-1 の利得を持っている場合が多く、逆にワク

チン接種を行ったエージェントは、相対ワクチン接種コスト C_r は-1以下なので、C 戦略を保持する、または模倣する可能性が高い。また、ハブエージェントから遠く離れたエージェントは、そもそも感染リスクが小さいため、D 戦略を維持しやすくなっている。このように IB-RA は SB-RA に比べ、局所的な感染リスクの情報を正しく評価できる。以上のように、IB-RA と SB-RA はそれぞれ有意義な情報を伝えやすい、つまり、得意とするネットワーク構造（well-mixed と BA-SF）を持っていることがわかる。

しかし、図 3-6 の右側の(*-2)の実線の結果である本モデルの結果では、IB-RA と SB-RA にほとんど差は見受けられない。これは前述したような SB-RA の弱点を本モデルは解消したといえる。本モデルが自身と同程度の感染リスク、つまり次数を持つ隣人を PW の対戦相手として優先的に選択する機構を持ち、さらに SB-RA の場合には、隣人と同じ戦略を持つ集団全体の社会平均情報ではなく、その選択した隣人と同じ次数と戦略を持つ社会平均情報を参照するため、IB-RA ほどではないにしても、局所的な情報を持つことができるようになったことで、このような結果になったと考えられる。したがって、本モデルの隣人優先選択方法は、IB-RA, SB-RA の戦略更新ルールにかかわらず、主にハブエージェントに対し正しく感染リスクを伝え、C 戦略、つまりワクチン接種を行わせることができるため、少ないワクチン接種率でも集団免疫を獲得するに至り、感染症の大流行を防ぐことが可能となる。




図 3-6 Kuga らの数理モデル [7]の結果と、デフォルトの $\ell = 1$ と本モデルの隣人選択ルールを適用した時の $\ell = 3$ の結果。縦軸は上から、(a-*)はワクチン接種率 VC 、(b-*)は最終感染者サイズ FES 、(c-*)は社会平均利得 SAP で、横軸は相対ワクチン接種コスト C_r を変化させた時の結果を示しており、左側の(*-1)は Kuga らの数理モデル [7]の結果で、右側の(*-2)はデフォルトの $\ell = 1$ と本モデルの隣人選択ルールを適用した時の $\ell = 3$ の結果を示している。また、黒と赤はそれぞれ IB-RA と SB-RA の結果を示しており、右側の破線がデフォルトの $\ell = 1$ で、実線が本モデルの結果を示している。

3.4 結論

ワクチン接種に伴うジレンマや感染症伝播を、より現実社会に即した形で再現するために、ワクチン接種ゲームの PW-Fermi による戦略模倣更新ルールに関する新しいモデルを確立した。このモデルでは、対戦相手を隣人からランダムに選択する従来のモデルとは異なり、対戦相手を選択する範囲を第 1 近傍に限らず、第 2、第 3 近傍まで拡張し、自身と同程度の感染リスク、すなわち次数を持つ隣人を優先的に選択する機構を取り入れたモデルである。このように偏った確率で対戦相手を選択する手法は、SPD ゲームで研究されており、Wang と Perc [31] や、その後のいくつかの手を加えたモデルの研究 [32–34] では、PW-Fermi と、対戦相手として、隣人の中でより高い利得を持つ者を優先的に選択する機構を組み合わせることで、ネットワーク互惠が顕著に強化されることが示された。つまり、C 戦略エージェントの隣人に D 戦略エージェントが存在し、対戦相手に D 戦略を選択可能な状況下で、「C-cluster」に属するほかの C 戦略エージェントを対戦相手として優先的に選択するようになり、相互協力により比較的高い利得を得るため、D 戦略を選択しにくくなるということである。

本研究で導入したメカニズムは、優先的に選択するという点は同じだが、利得が大きいものを優先的に選択するのではなく、自身と同程度の感染リスク、つまり次数を持つ隣人を優先的に選択するという点で、全く違う概念に基づいたモデルとなっている。空間構造に BASF を持つようなワクチン接種ゲームでは、ハブエージェントに、いかにしてワクチン接種を行わせるかが重要となる。このハブエージェントがワクチン接種を行っていれば、「super-spreader」が発生しにくくなるため、ハブエージェント以外のエージェントは、ハブエージェントが作り出した集団免疫にただ乗りすることが可能で、SPD のようにハブエージェント同士が「C-cluster」を構築することで、必要最低限のワクチン接種で効率的に感染症蔓延を防ぐことが可能となる。

この概念の鍵となるメカニズムは、ハブエージェントが直接の隣人だけではなく、第 2、第 3 近傍のより広範な隣人を参照することで、ほかのハブエージェントの行動を模倣する傾向があるということである。このことにより、ハブエージェントは自身の感染リスクを正しく評価するようになり、ワクチン接種を受ける可能性が高くなる。これは、現実社会におけるワクチン接種行動においても観察できる事象であり、医者は一般人よりもはるかに感染リスクが高く、多くの人と接することから、ハブエージェントとみなすことができ、家族や友人のワクチン接種行動を模倣するのではなく、同じような感染リスクにさらされているほかの医師と相談して、ワクチン接種行動を起こすかどうかを決定する傾向がある。以上の点で、本モデルは、より現実社会に即した戦略更新ルールであるといえる。

参考文献

- [1] C. T. Bauch, Imitation Dynamics Predict Vaccinating Behaviour, *Proceedings of the Royal Society B: Biological Sciences* 272, 1669 (2005).
- [2] F. Fu, D. I. Rosenbloom, L. Wang, and M. A. Nowak, Imitation Dynamics of Vaccination Behaviour on Social Networks, *Proceedings of the Royal Society B: Biological Sciences* 278, 42 (2011).
- [3] R. M. Anderson and R. M. May, *Infectious Diseases of Humans: Dynamics and Control*, Oxford University Press (1992).
- [4] J. Tanimoto, *Fundamentals of Evolutionary Game Theory and Its Applications*, Vol. 6 (Springer: Tokyo Japan, 2015).
- [5] J. Tanimoto, *Evolutionary Games with Sociophysics: Analysis of Traffic Flow and Epidemics*, Vol. 17 (Springer, Singapore, 2018).
- [6] C. T. Bauch, A. P. Galvani, and D. J. D. Earn, Group Interest versus Self-Interest in Smallpox Vaccination Policy, *Proc Natl Acad Sci U S A* 100, 10564 (2003).
- [7] K. Kuga and J. Tanimoto, Which Is More Effective for Suppressing an Infectious Disease: Imperfect Vaccination or Defense against Contagion?, *Journal of Statistical Mechanics: Theory and Experiment* 2018, 023407 (2018).
- [8] K. Kuga, J. Tanimoto, and M. Jusup, To Vaccinate or Not to Vaccinate: A Comprehensive Study of Vaccination-Subsidizing Policies with Multi-Agent Simulations and Mean-Field Modeling, *J Theor Biol* 469, 107 (2019).
- [9] K. M. A. Kabir, K. Kuga, and J. Tanimoto, Analysis of SIR Epidemic Model with Information Spreading of Awareness, *Chaos Solitons Fractals* 119, 118 (2019).
- [10] K. M. A. Kabir and J. Tanimoto, Vaccination Strategies in a Two-Layer SIR/V–UA Epidemic Model with Costly Information and Buzz Effect, *Commun Nonlinear Sci Numer Simul* 76, 92 (2019).
- [11] M. Alam, K. Kuga, and J. Tanimoto, Three-Strategy and Four-Strategy Model of Vaccination Game Introducing an Intermediate Protecting Measure, *Appl Math Comput* 346, 408 (2019).
- [12] Y. Ida and J. Tanimoto, Effect of Noise-Perturbing Intermediate Defense Measures in Voluntary Vaccination Games, *Chaos Solitons Fractals* 106, 337 (2018).
- [13] Y. Iwamura, J. Tanimoto, and E. Fukuda, Effect of Intermediate Defense Measures in Voluntary Vaccination Games, *Journal of Statistical Mechanics: Theory and Experiment* 2016, 093501 (2016).
- [14] M. Alam, M. Tanaka, and J. Tanimoto, A Game Theoretic Approach to Discuss the Positive Secondary Effect of Vaccination Scheme in an Infinite and Well-Mixed Population, *Chaos Solitons Fractals* 125, (2019).

- [15] K. M. A. Kabir and J. Tanimoto, Evolutionary Vaccination Game Approach in Metapopulation Migration Model with Information Spreading on Different Graphs, *Chaos Solitons Fractals* 120, 41 (2019).
- [16] K. M. A. Kabir and J. Tanimoto, Impact of Awareness in Metapopulation Epidemic Model to Suppress the Infected Individuals for Different Graphs, *European Physical Journal B* 92, 1 (2019).
- [17] K. M. A. Kabir and J. Tanimoto, Dynamical Behaviors for Vaccination Can Suppress Infectious Disease – A Game Theoretical Approach, *Chaos Solitons Fractals* 123, 229 (2019).
- [18] A. Yamauchi, J. Tanimoto, and A. Hagishima, What Controls Network Reciprocity in the Prisoner's Dilemma Game?, *BioSystems* 102, 82 (2010).
- [19] E. Fukuda, S. Kokubo, J. Tanimoto, Z. Wang, A. Hagishima, and N. Ikegaya, Risk Assessment for Infectious Disease and Its Impact on Voluntary Vaccination Behavior in Social Networks, *Chaos Solitons Fractals* 68, 1 (2014).
- [20] E. Fukuda and J. Tanimoto, Effects of Stubborn Decision-Makers on Vaccination and Disease Propagation in Social Networks, *International Journal of Automation and Logistics* 2, 78 (2016).
- [21] Y. Iwamura and J. Tanimoto, Realistic Decision-Making Processes in a Vaccination Game, *Physica A: Statistical Mechanics and Its Applications* 494, 236 (2018).
- [22] X. Chen and L. Wang, Promotion of Cooperation Induced by Appropriate Payoff Aspirations in a Small-World Networked Game, *Phys Rev E Stat Nonlin Soft Matter Phys* 77, (2008).
- [23] R. Edge, T. Keegan, R. Isba, and P. Diggle, Observational Study to Assess the Effects of Social Networks on the Seasonal Influenza Vaccine Uptake by Early Career Doctors, *BMJ Open* 9, (2019).
- [24] A. L. Barabási and R. Albert, Emergence of Scaling in Random Networks, *Science* (1979) 286, 509 (1999).
- [25] D. T. Gillespie, Exact Stochastic Simulation of Coupled Chemical Reactions, *J Phys Chem* 81, 2340 (1977).
- [26] A. Yamauchi, J. Tanimoto, and A. Hagishima, An Analysis of Network Reciprocity in Prisoner's Dilemma Games Using Full Factorial Designs of Experiment, *BioSystems* 103, 85 (2011).
- [27] H. F. Zhang, P. P. Shu, Z. Wang, M. Tang, and M. Small, Preferential Imitation Can Invalidate Targeted Subsidy Policies on Seasonal-Influenza Diseases, *Appl Math Comput* 294, 332 (2017).
- [28] H. Ding, J. H. Xu, Z. Wang, Y. Z. Ren, and G. H. Cui, Subsidy Strategy Based on History Information Can Stimulate Voluntary Vaccination Behaviors on Seasonal Diseases, *Physica A: Statistical Mechanics and Its Applications* 503, 390 (2018).
- [29] E. Fukuda, J. Tanimoto, and M. Akimoto, Influence of Breaking the Symmetry between Disease Transmission and Information Propagation Networks on Stepwise Decisions Concerning Vaccination, *Chaos Solitons Fractals* 80, 47 (2015).

- [30] K. M. Ariful Kabir, J. Tanimoto, and Z. Wang, Influence of Bolstering Network Reciprocity in the Evolutionary Spatial Prisoner's Dilemma Game: A Perspective, *European Physical Journal B* 91, 312 (2018).
- [31] Z. Wang and M. Perc, Aspiring to the Fittest and Promotion of Cooperation in the Prisoner's Dilemma Game, *Phys Rev E Stat Nonlin Soft Matter Phys* 82, 021115 (2010).
- [32] M. Perc and Z. Wang, Heterogeneous Aspirations Promote Cooperation in the Prisoner's Dilemma Game, *PLoS One* 5, e15117 (2010).
- [33] J. Tanimoto, M. Nakata, A. Hagishima, and N. Ikegaya, Spatially Correlated Heterogeneous Aspirations to Enhance Network Reciprocity, *Physica A: Statistical Mechanics and Its Applications* 391, 680 (2012).
- [34] J. Tanimoto, Simultaneously Selecting Appropriate Partners for Gaming and Strategy Adaptation to Enhance Network Reciprocity in the Prisoner's Dilemma, *Phys Rev E Stat Nonlin Soft Matter Phys* 89, (2014).

第4章 感染流行を抑制するための先制的ワクチン接種公的補助スキームの最適社会設計に関する研究

4.1 はじめに

2019 年から現在に至るまで猛威を振るい続けている新型コロナウイルスをはじめとし、エボラ出血熱やインフルエンザウイルスのような、致死性や感染力が強い感染症蔓延の抑制は、世界中で喫緊の課題となっている [1]. これらのウイルスは、先制的ワクチン接種を行うことで感染症の蔓延を未然に防ぎ、罹患したとしても、死亡率や重症化率を減少させる有効な手段の一つであると報告されている [2, 3]. しかし、インフルエンザの予防接種に限らず、当初は無料だった新型コロナウイルスの予防接種も、自費でワクチン接種を行う必要がある。

さらに、自費で行うワクチン接種については、その背景に社会的ジレンマの構造 [4, 5] が存在しており、これらは「ワクチン接種に伴うジレンマ」や「疫学のパラドックス」と呼ばれる。このジレンマ構造は、集団内でワクチン接種率がある閾値を超えると獲得する、集団免疫と密接な関係がある。この集団免疫が達成された集団では、集団免疫にただ乗りしようとする非ワクチン接種者が発生する。そのため、ワクチン接種を行った周りの人々のおかげで感染を免れた人々が、誤った成功体験を基にワクチン接種を行わないまま、さらにはワクチン接種を行っていた人々にも誤った成功体験を伝えるため、ワクチン接種を行わない人々が増えることで集団免疫が崩壊し、感染症の大流行が起こる。このような構造が、ワクチン接種におけるジレンマ構造として、背後に存在している。

このワクチン接種に伴うジレンマをモデル化するために、ゲーム理論の側面からワクチン接種ゲームを数多く研究してきた。この研究は、複雑な社会ネットワーク上で感染症がどのように伝播していくのか、また、個人のワクチン接種行動の決定と、その結果が社会全体で集団免疫を達成するか、という点をモデル化することで、前者は、感受性 (Susceptible) - 感染性 (Infectious) - 回復性 (Recovered) の SIR モデルによる数理疫学モデルを用いて、後者は進化ゲーム理論を用いてモデル化される。このワクチン接種ゲームは Bauch ら [6] や Fu ら [7] によって先駆的な研究が発表されて以来、多くの研究がなされている [8–14]. これらの多くの研究は、柔軟なモデルの構築のために MAS を用いてモデル化されている。そのほかにも、平均場近似を用いて空間構造を考慮した数理モデルも研究されている [15, 16]. この数理モデルの特徴は、MAS だとシミュレーションに時間がかかるが、数理モデルではシミュレーションに時間がかからないという点が挙げられる。そのため、より多くのモデルを試すことが可能で、例えば MAS の多くでは、ワクチン接種を行うと完全免疫を獲得するのに対し、数理モデルでは確率的に完全免疫を獲得するようにしたり、ワクチン接種を行う、行わない、の 2 つの戦略にプラスして、マスクを着用するなどの中間戦略を導入したりすることが可能となった。ただし、数理モデルでは、平均場近似を結果として用いるため、全体の傾向を捉えるには

十分だが、局所的な情報解析には MAS が有利である。

どちらのモデル化へのアプローチだったとしても、ワクチン接種率を高めることが最大の焦点であり、そのためには、いかにワクチン接種に伴うジレンマを解消するかが重要で、その一つのアプローチとして、税金などの公共資金を用いて、ワクチン接種に対し補助金を提供する案がある。例えば、日本では、高齢者や合併症リスクの高い人々に対し、インフルエンザや新型コロナウイルスなどのワクチン接種を対象に、補助金を受ける資格が与えられている。同時に、日本政府は医療費の増加と高齢化社会を支えるための福祉費用の増加によって、長年にわたる巨額の財政赤字に苦しんできた。もしこのような補助金が感染症の大流行を抑えるのに十分な効果を持っており、感染症が大流行した際の社会が抱えるコストに対し、補助金の税負担を含めた全コストの方が小さいのであれば、補助金政策を十分に正当化することができる。したがって、社会全体のコストを削減する補助金政策の策定と評価は、公衆衛生計画において重要であり、限られた予算内で最大の効果を引き出し、感染症に対し堅牢な社会を構築するために、必要不可欠な過程である。

この補助金政策に対しても多くの研究がなされており、この研究分野の先駆者となった Yamin と Gavius [17]は、感染症流行期間が長期間になる場合は、十分に広範なワクチン接種に対する補助金が必要であり、中・若年層が高齢者よりも優先して補助金を与えるべきと主張した。また Zhang ら [18]は MAS を用いて、この問題に取り組み、彼らのモデルは感染症伝播とワクチン接種戦略の意思決定の時間スケールが同時であると仮定し、従来のワクチン接種ゲーム [7]とは異なるアプローチを行った。この研究では、予算が許す限り完全無料のワクチン接種券を配布する政策（以降、フリーチケット政策）と、すべての個人にワクチン接種費用に対する割引券を提供する政策（以降、割引政策）を比較した。翌年に Zhang ら [19]は Fu ら [7]のワクチン接種ゲームを用いて、様々な状況でのフリーチケット政策と割引政策を比較し、2017 年にはランダムに選出されたワクチン接種補助金受給者に対し、補助金を配布する政策と、ターゲットを絞った補助金配布の効果の違いを調査した [20]。また、Tang ら [21]は興味深い補助金政策を研究した。この研究では従来の研究で行われていた、政府主導によるワクチン接種補助金政策に関する徴収課税を全員に等しく課していたのに対し、隣接する個人同士が相互にワクチン接種を支援する新しい政策を導入した。結果、彼らはこの政策の方が、従来の徴収課税よりも効率的である可能性が高いと結論付けた。Li ら [22]は SIR モデルを仮定せずに、1 シーズン内に個人が 2 回感染する可能性がある SIRS モデルを使用した補助金モデルを、数理モデルによって構築し、報告している。ほかにも Ding ら [23]はフリーチケットを高次数エージェント（ハブエージェント）に優先的に配布する場合と、ランダムに配布する政策を比較し、スケールフリー性を有するネットワーク上での感染症蔓延を、最小限に抑えるための補助金政策の有効性を研究した。この研究は、ワクチン接種の補助金政策がどのように感染症蔓延を抑制し、社会全体のコストを最小限に抑えることができるかを探求しており、異なる政策方法の比較や、ターゲットを絞った補助金配布の効果に、特に焦点を当て

ている。

ワクチン接種補助金政策導入の基本的な動機の一つに、補助金を受けたワクチン接種者が、隣接するエージェントへの自発的なワクチン接種行動を促す可能性があるという点がある。このポジティブな効果によって、適切な補助金政策を行えば、政策を主導する者たちの予想以上に低い総コストで済むかもしれない。このプラスの副作用は、Fukuda ら [12]が調査した「stubborn vaccinators」や、Matsuzawa ら [24]が調査した 2×2 ゲームの空間構造を持たせたモデルの「zealot cooperator」の効果に類似している。これら2つのエージェントたちは、戦略更新の利得差に対し、感度を持たないことを説明している。しかし、補助金を受けたワクチン接種と、前述の2つのエージェントたちとの大きな違いは、前述のエージェントたちはネットワーク上において常に同じ場所に存在するが、補助金を受けたワクチン接種者はシーズンごとに違う場所に存在するかもしれないという点である。

一方、フリーチケット政策が、自己負担でワクチン接種を受ける人々を減らすことで、感染症がかえって蔓延するかもしれないという、負の副作用をもたらす可能性があることを忘れてはならない。これは、フリーチケットが、ワクチン接種を行わないと決めていたエージェントたちに優先的に配布されるのであれば、このエージェントたちはただ乗りに成功したのと同じ状態であることから、社会に誤った成功体験を伝える可能性があり、それにより自発的にワクチン接種を行う動機がなくなってしまう、結果的にワクチン接種率が低くなってしまうかもしれないということである。

ワクチン接種に対する補助金政策を議論する上でもう一つ重要な点がある。それは感染症伝播に用いるネットワークが現実的なものであるという点である。つまりスケールフリー性を有するネットワークを導入すべきであるということだ。Cohen ら [25]によると、次数分布を持つネットワークでは、ハブノードが悪意ある攻撃に対し、特に脆弱で、このハブノードが何らかの障害を起こすと、その障害がネットワーク全体に影響を及ぼす可能性があることが報告されている。この報告は、ワクチン接種補助金の配布において、ハブエージェントを優先する政策を支持する根拠として考えられている [23, 26]。

本研究では、ハブエージェント優先政策の根本的な前提が常に有効であるかを検討することを目的とする。具体的には、異なるワクチン接種コストや補助金の規模、そのほか様々なパラメータに基づいて、様々な状況下における最適なワクチン接種政策を定量的に決定するために、MAS を用いて、Kuga ら [27]によって提案された様々なワクチン接種補助金政策を考慮した、包括的なワクチン接種ゲームのモデルを構築し、フリーチケット政策について、より深く検証を行う。割引モデルについては今後検証する予定である。

本章での構成は次の通りで、節 4.2 でフリーチケット政策を組み込んだワクチン接種ゲームモデルの概要を説明し、節 4.3 でそのモデルの結果の考察を行い、節 4.4 にて結論を述べる。

4.2 モデルの概要

本研究は、Fu ら [7]によって最初に確立されたワクチン接種ゲームを基に発展させたモデルを使用する。より正確には、Fukuda ら [10]によって発展された MAS モデルに、Kuga ら [27]が提案した補助金政策を取り入れたモデルを使用する。

また、本章以降使用する略称を予め明記しておく。まず、補助金を与えてワクチン接種を行わせる場合、ワクチン接種を受けると宣言していた C 戦略エージェントの数と、実際にワクチン接種を行った人数は、政策によっては違う場合があるので、補助金とは関係なく、自主的にワクチン接種を受けると宣言していた、C 戦略エージェントが集団に占める割合（協調率）Fraction of voluntary vaccinators を略して f_c とする。また、実際にワクチン接種を行った人の割合 Vaccination coverage を VC 、最終感染者サイズ Final epidemic size を FES 、社会平均利得 Social average payoff を SAP とする。そして、戦略更新について、2011 年に Fu ら [7]によって提案された戦略更新ルール Individual-based risk assessment を IB-RA、2014 年に Fukuda ら [10]によって提案された戦略更新ルール Strategy-based risk assessment を SB-RA、2018 年に Iwamura ら [14]によって提案された戦略更新ルール Direct commitment を DC とする。

4.2.1 スケールフリー性を持つネットワーク上でのワクチン接種ゲーム

集団サイズが N で、各エージェントがスケールフリー性を持つネットワーク上に配置されている集団を想定し、ワクチン接種ゲームを行う。スケールフリー性を持つネットワークとして、集団サイズ $N = 10^4$ の Barabási と Albert アルゴリズム [28]によって生成された BA-SF を使用する。感染症としては、既往研究 [7, 10, 14]にならい、季節性のインフルエンザを想定する。通常、インフルエンザに対するワクチン接種で獲得する免疫は、その年の株に対してのみ有効である。したがって、本モデルでもワクチン接種で得る免疫は、その時の感染症発生から、蔓延、収束までの一連の期間（これを 1 シーズンと呼ぶ）でのみ有効であるとする。したがって、本モデルは図 4-1 に示すように、感染症が蔓延するシーズンと、ワクチン接種を行うか否かの意思決定に基づきワクチン接種を行う期間の、2 つの異なる時間スケールが存在する。ワクチン接種を行う期間をワクチン接種キャンペーンと呼び、このキャンペーン中にワクチン接種を行い、その後感染症流行期間が訪れ、感染症流行が収まると来シーズンに向けたワクチン接種を行うか否かの戦略更新が行われる。この一連の流れをエピソードと呼び、社会全体の戦略比が変化しなくなるまでエピソードを繰り返し、この戦略比が変化しなくなった時を均衡状態とみなし、シミュレーションを終了する。この均衡状態になった時の、C 戦略エージェントが集団に占める割合 f_c と、実際にワクチン接種を行った人の割合 VC 、最終感染者サイズ FES 、社会平均利得 SAP を測定することで、異なる補助金政策が感染症蔓延や社会平均利得にどのような影響を与えるか、議論する。




図 4-1 本モデルのワクチン接種ゲームの概念図．本モデルはローカル時間 t_l とグローバル時間 t_g の2つの異なる時間スケールを持つ．ローカル時間 t_l においては，任意のシーズン k 内で適用される時間スケールで，感染症の伝播が発生するワクチン接種は，このシーズン突入前に戦略に応じて行う．また，補助金によってワクチン接種を行う者もこのタイミングでワクチン接種を行う．一方，グローバル時間 t_g では，時間経過に伴う戦略の変化を取り扱う．図中の薄い青い円と濃い青い円はワクチン接種状態 V を示している．薄い青色と濃い青色の違いは，前者が自主的にワクチン接種を行った者で，後者が補助金によってワクチン接種を行った者である．また，白い円は非ワクチン接種状態 NV を示している．状態 NV の中には感染せず感受性状態 S を保つ者もいるが，感染性状態 I になり，その後回復性状態 R に状態遷移する．

4.2.1.1 感染症蔓延シーズン

図 4-1 のローカル時間 t_l が 0 の時に，ワクチン接種を行っていない状態 NV のエージェントの中から，ランダムに I_0 （先行研究にならい $I_0 = 5$ ）人の初期感染者が現れる．また，この時点でワクチン接種は行っており，ワクチン接種を行った状態を V とし，この状態 V のエージェントは，そのシーズン内で完全免疫を獲得し，当該シーズン中に感染症に感染することはない．その後，ローカル時間 t_l は Gillespie アルゴリズム [29]に従って進み，感染症は SIR/V ダイナミクスに従い，感受性状態 S のエージェントが感染状態 I になり，その後回復性状態 R へと遷移していく．また，回復性状態 R になったエージェントは，そのシーズン内でのみではあるが，完全免疫を獲得する．つまり，状態 R から状態 S への遷移は起きない．

また，既往研究 [7, 10, 14]にならい，感染率 $\beta[\text{day}^{-1}\text{person}^{-1}]$ と回復率 $\gamma[\text{day}^{-1}]$ を仮定し，基本生産数 $R_0 = 2.5$ および回復率 $\gamma = 1/3$ とし，節 2.2.3.2.1.2 に従って，最終感染率 FES が 0.9 となるような感染率 β を決定する．ローカル時間 t_l は感染状態 I のエージェントがいなくなるまで進む．シーズンが終了すると，各エージェントは状態に応じた利得を獲得する．ワクチン接種コストは C_v で，感染したエージェントは感染コスト C_i を支払う．ここで，感染コスト $C_i = 1$ とし，感染コストに対するワクチン接種コスト，つまり相対ワクチン接種コスト $C_r = C_v/C_i$ ($0 \leq C_r \leq 1$)を用いることにする．コストは支払うので，ワクチン接種エージェントは $-C_r$ を，感染

したエージェントは-1を，ワクチン接種を行わず感染しなかったエージェントは0を獲得する．

4.2.1.2 ワクチン接種キャンペーン

図 4-1 に示すように，ワクチン接種を行う期間であるワクチン接種キャンペーンは，シーズン突入前に行われる．前節で述べたように，各エージェントはシーズン終了時の状態に応じた利得を獲得し，その利得に応じて，次のシーズンに向けてワクチン接種を行うか否かの戦略を決定する．これを戦略更新といい，この更新された戦略に応じてワクチン接種を行う．また，ワクチン接種を自主的に行う戦略を C 戦略，ワクチン接種を自主的に行わない戦略を D 戦略とする．ワクチン接種キャンペーンでワクチン接種を行うのは，C 戦略エージェントだけではない．政策によっては，D 戦略エージェントも補助金によるワクチン接種を行う．この時，図 4-1 では自主的にワクチン接種を行った状態を薄い青色の V ，補助金によってワクチン接種を行った状態を濃い青色の V としているが，以降の文中では前者の状態を V ，後者を V' として表現する．そしてワクチン接種を行わなかった者は状態 NV となり，シーズンに突入していく．

シーズン終了時に，先ほど述べたように，状態に応じた利得を獲得し，後に詳しく述べる戦略更新ルールに則って，各エージェントは来シーズンの戦略を決定する．図 4-1 に示すグローバル時間 t_g は，C 戦略を D 戦略の比が一定になるまで進む．

4.2.2 戦略更新

本研究では，既往研究にならい，2011 年に Fu ら [7]によって提案された戦略更新ルール Individual-based risk assessment (IB-RA)，2014 年に Fukuda ら [10]によって提案された戦略更新ルール Strategy-based risk assessment (SB-RA)，2018 年に Iwamura ら [14]によって提案された戦略更新ルール Direct commitment (DC) を採用し，以下にそれぞれのルールの概要を述べる．

4.2.2.1 Individual-based risk assessment (IB-RA)

Individual-based risk assessment (IB-RA)は個人ベースの戦略更新で，2011 年に Fu ら [7]によって提案された，ワクチン接種ゲームで最も基本的な戦略更新方法である．対戦相手 1 人をネットワーク上の自身の隣人からランダムに選出し，その相手の利得と比較し，次の戦略を決定するため，個人ベースと呼ばれる．

あるエージェント i が i の第 1 近傍の隣人からランダムに選出したエージェントを j とし，それぞれの利得を π_i ， π_j とした時，エージェント i がエージェント j の戦略を模倣する確率 $P(S_i \leftarrow S_j)$ は

$$P(S_i \leftarrow S_j) = \frac{1}{1 + \exp[-(\pi_j - \pi_i)/\kappa]} \quad (4.1)$$

で与えられる．ここで κ は $\kappa > 0$ の実数で，利得差に対する敏感度で，本研究では常に $\kappa = 0.1$ を想定する．

もし，ランダムに選出した隣人の戦略が同じだった場合は，現在の戦略を維持し，違う場合は，式(4.1)の確立に従って戦略を更新する．

4.2.2.2 Strategy-based risk assessment (SB-RA)

IB-RA は個人ベースだったが，Strategy-based risk assessment (SB-RA)は 2014 年に Fukuda ら [10]によって提案され，対戦相手を第 1 近傍の隣人からランダムに選出するところまでは IB-RA と同じだが，使用する利得が対戦相手の戦略の社会平均利得を用いる，という点が違う．対戦相手の戦略の社会平均利得を $\langle \pi_j \rangle$ とすると，エージェント i がエージェント j の戦略を模倣する確率 $P(S_i \leftarrow S_j)$ は

$$P(S_i \leftarrow S_j) = \frac{1}{1 + \exp[-(\langle \pi_j \rangle - \pi_i)/\kappa]} \quad (4.2)$$

と定義される． κ の値や，対戦相手の戦略が同じだった場合などは IB-RA の時と同じである．

4.2.2.3 Direct commitment (DC)

Direct commitment (DC)は 2018 年に Iwamura ら [14]によって提案された．DC は IB-RA や SB-RA とは異なる概念で，エージェントがランダムに選出した隣人の戦略を模倣する確率を定義するのではなく，直接どちらの戦略を採用するか確立を定義する．あるエージェント i が C 戦略を採用する確率 $P(S_i \leftarrow C)$ は

$$P(S_i \leftarrow C) = \frac{1}{1 + \exp[-(\langle \pi_C \rangle - \langle \pi_D \rangle)/\kappa]} \quad (4.3)$$

と定義される．ここで， $\langle \pi_C \rangle$ と $\langle \pi_D \rangle$ はそれぞれ，エージェント i の第 1 近傍の隣人の C 戦略エージェントと，D 戦略エージェントの平均利得を表す． κ の値は IB-RA と同じである．また，D 戦略を採用する確率 $P(S_i \leftarrow D)$

$$P(S_i \leftarrow D) = 1 - P(S_i \leftarrow C) \quad (4.4)$$

と定義される．

4.2.3 補助金政策

本研究では，既述した通り，補助金政策としてフリーチケットのみを想定している．フリーチケットを配布する対象を選定する基準は 2 つの概念の組み合わせで構成される．

一つはエージェントの戦略によるものである．つまり自主的にワクチン接種を行うと宣言していた C 戦略エージェントに優先的に配布する方法，自主的にはワクチン接種を行わない

と宣言していた D 戦略エージェントに優先的に配布する方法、そして戦略に関係なくランダムに選出したエージェントに配布する方法である。

もう一つは、エージェントの持つ隣人の数、すなわち感染するリスクに応じて優先的にフリーチケットを配布する方法である。つまり、「super-spreader」となり得るハブエージェントに優先して配布する方法、感染症を多くの人に感染させる能力はないが、人数が多い低次数のエージェントに優先して配布する方法、そしてランダムに選出したエージェントに配布する方法である。

政策はこの 2 つの概念の組み合わせなので、 3×3 の計 9 つの基準がある。また、先に説明した概念の C 戦略優先、D 戦略優先、ランダム選出を、それぞれ、C-priority, D-priority, Mix とし、後に説明した概念のハブエージェント優先、低次数エージェント優先、ランダム選出を、それぞれ、Hub-priority, Fringe-priority, Random と以降では表現する。

4.2.4 補助金のモデル化

補助金配布可能な集団サイズ N に対する割合を σ とする（以降ではこのことを補助金サイズ σ と呼ぶ）と、補助金捻出のための 1 人当たりの徴収課税額 TAX は、ワクチン接種コスト C_v を用いて、

$$TAX = \frac{\sigma N C_v}{N} = \sigma C_v \quad (4.5)$$

と定式化される。また、社会平均利得 SAP は徴収課税額 TAX も含まれるので

$$SAP = -C_v(VC - \sigma) - C_i FES - TAX \quad (4.6)$$

となる。 VC と FES はワクチン接種率と最終感染者サイズである。ここで、相対ワクチン接種コスト C_r と感染コスト $C_i = 1$ であることと、余った補助金を全エージェントに等しく還元するという仮定を用いると、式(4.6)は

$$SAP = -C_r(VC - \sigma) - FES - \sigma C_r = -C_r VC - FES \quad (4.7)$$

となり、徴収課税額 TAX は社会平均利得 SAP に影響を与えないことがわかる。また社会平均コストは $-SAP$ となる。徴収課税額 TAX は社会平均利得 SAP に影響を与えないため、補助金がワクチン接種率を高める触媒としての機能を期待することができ、補助金サイズ σ と 9 つの基準による補助金政策の与える影響を、社会平均利得 SAP を用いて議論することができる。また、徴収課税額 TAX は戦略更新に用いる個人の利得には含めない。なぜなら、全員が等しく負担するコストであり、結局は利得差を用いて戦略更新を行うため、利得差を算出した時点で打ち消し合うからである。

また、先ほども述べたが、注意すべき点として、補助金政策によっては補助金が余る可能性がある。例えば、C-priority の時に補助金サイズ σ が協調率 f_c よりも大きい場合や、D-priority の時に補助金サイズ σ が D 戦略率 $1 - f_c$ よりも大きい場合は、補助金が余ることである。この場合は既述の通り、余った補助金を全エージェントに等しく還元すること、

個人の獲得する利得や社会平均利 SAP に影響を与えないようになっており、この場合でも問題なく、社会平均利 SAP を用いて補助金政策の影響を正しく評価することができる。

4.2.5 MAS への導入

本研究では、既述した通り、集団サイズ N が 10^4 で、平均次数 $\langle k \rangle = 8$ の BA-SF ネットワークを用いる。また本モデル内では、本モデルの補助金政策の与える影響と政策による違いを明確にするために、すべてのシミュレーションで同じ BA-SF を用いる。また、基本生産数 R_0 と回復率 γ には、既述の通り、 $R_0 = 2.5$ 、 $\gamma = 1/3 [\text{day}^{-1}]$ を採用し、感染率 $\beta [\text{day}^{-1}\text{person}^{-1}]$ については、ワクチン接種者がいない状態で最終感染者サイズ FES が 0.9 になるような値を採用する。また、初期感染者数 I_0 は 5 とし、各補助金サイズ σ と相対ワクチン接種コスト C_r に対し、初期戦略比を 1:1 として毎シーズン初期感染者をランダムに選出し、戦略比が変化しなくなるまでエピソードを実行し、同じ補助金サイズ σ と相対ワクチン接種コスト C_r に対し、エピソードを 100 回行い、そのアンサンブル平均の値を、結果として採用する。また、結果の評価には協調率 f_c 、ワクチン接種率 VC 、最終感染者サイズ FES 、社会平均利得 SAP を用いる。

また、協調率 f_c とワクチン接種率 VC 、補助金サイズ σ とワクチン接種率 VC は、図 4-2 に示すような関係がある。政策によるが、最大で C 戦略で補助金を受けてワクチン接種を行った者、D 戦略で補助金を受けてワクチン接種を行った者、自主的にワクチン接種を行った者、ワクチン接種を行わなかった者の 4 つの状態の者が存在し、各割合の和は常に 1 になる。また、補助金が余った場合を除いて、補助金を受けてワクチン接種を行った者の割合は、常に補助金サイズ σ と等しくなる。




図 4-2 本モデルの補助金政策の概念図。左側に協調率 f_c とワクチン接種率 VC の関係を示しており、右側には補助金サイズ σ とワクチン接種率 VC の関係を示している。また、それぞれ上から順に、C-priority, D-priority, Mix の時を示している。青色の棒は、C 戦略で補助金を受けてワクチン接種を行った人の割合で、赤色の棒は、D 戦略で補助金を受けてワクチン接種を行った人の割合、白色の棒は自主的にワクチン接種を行った人の割合、黒色の棒はワクチン接種を行わなかった人の割合を示している。また、同じ政策（同じ段）のそれぞれの割合は、右側と左側とで同じである。

4.3 結果と考察

4.3.1 補助金なしの場合

図 4-3 に、補助金政策を取り入れていない場合の、相対ワクチン接種コスト C_r に対する最終感染者サイズ FES 、ワクチン接種率 VC 、社会平均利得 SAP の結果を各戦略更新ルールについて示している．一般的には、社会平均利得 SAP が大きく最終感染者サイズ FES が小さいことが望ましい．しかし、社会平均利得 SAP は戦略更新ルールに対し大きな差はなく、Iwamura ら [14] が主張するように、戦略更新ルールの違いは、ワクチン接種率 VC と最終感染者サイズ FES に大きな影響を与える．IB-RA と SB-RA のワクチン接種率 VC は相対ワクチン接種コスト C_r に対して単調減少傾向を示すが、DC だけは明らかに違う傾向を示している．これは DC が隣人の戦略を模倣するのではなく、自身の現在の戦略に関係なく直接戦略を決定するためである．相対ワクチン接種コスト C_r が比較的大きくなってくると、各エージェントは D 戦略によるただ乗りを試みるが、感染症が大流行して、ほとんどのエージェントがただ乗り失敗した場合、多くの D 戦略エージェントは感染してしまい、その平均利得は限りなく -1 に近くなるのに対し、ワクチン接種を行った C 戦略の利得は常に $-C_r$ なので、かなり魅力的に映り、多くのエージェントが次シーズンで C 戦略を選択する．しかし、今度は集団免疫を達成しているため、D 戦略を選択した数少ないエージェントは、ほぼ全員がただ乗り成功することになり、今度は D 戦略の平均利得が限りなく 0 に近くなるため、次のシーズンでは D 戦略を選択するエージェントが増える．このようにシーズンごとに主体となる戦略が切り替わるため、IB-RA や SB-RA とは異なる傾向を示す．いずれにせよ、社会平均利得 SAP だけをみると、戦略ごとに大きな差はなく、この補助金政策を取り入れていない状態の結果をデフォルトとして、補助金政策の効果を評価する際の基準として用いる．




図 4-3 補助金政策を行っていない時の、戦略更新ルールごとの最終感染者サイズ FES ((a)のパネル)、ワクチン接種率 VC ((b)のパネル)、社会平均利得 SAP ((c)のパネル)の相対ワクチン接種コスト C_r との関係の結果を示している．黒色が IB-RA、赤色が SB-RA、青色が DC の時の結果を示している．

4.3.2 異なる補助金政策の効果

図 4-4 から図 4-6 に、9 通りの補助金政策の結果を示している。それぞれのパネルはヒートマップで表現されており、縦軸に補助金サイズ σ 、横軸に相対ワクチン接種コスト C_r をとっている。また、結果は、協調率 f_c 、ワクチン接種率 VC 、最終感染者サイズ FES 、社会平均利得 SAP を採用しており、青色に近いほど一般的に良い結果、赤色に近いほど悪い結果となっている。補助金サイズ σ が0の時は図 4-3 の時と同じ結果を示している。また、図 4-4 から図 4-6 はそれぞれ、C-priority, D-priority, Mix 政策の時の結果を示しており、その中でも各列は Random, Hub-priority, Fringe-priority を示している。また、図 4-7 から図 4-9 に、Random 政策を基準とした Hub-priority の相対結果と、Fringe-Priority の相対結果のヒートマップを、C-priority, D-priority, Mix 政策の順で示している。ここでも青色に近いほど Random よりも良い結果で、赤色に近いほど悪い結果となっていることを示している。




図 4-4 C-priority 補助金政策の時の結果。各パネルは縦軸に補助金サイズ σ 、横軸に相対ワクチン接種コスト C_r をとっており、ヒートマップとして結果が示されている。上段から、協調率 f_c ((a-*)のパネル)、ワクチン接種率 VC ((b-*)のパネル)、最終感染者サイズ FES ((c-*)のパネル)、社会平均利得 SAP ((d-*)のパネル)を示している。また、(I)はIB-RA, (II)はSB-RA, (III)はDCの時の結果を示しており、各列の(*-1), (*-2), (*-3)はそれぞれ、Random, Hub-priority, Fringe-priority 政策時の結果が示されている。また、青色に近いほど一般的に良い結果で、赤色に近いほど一般的に悪い結果である。




図 4-5 D-priority 補助金政策の時の結果. 各パネルの配置などは, すべて図 4-4 と同じである.




図 4-6 Mix 助金政策の時の結果. 各パネルの配置などは, すべて図 4-4 と同じである.




図 4-7 C-priority 補助金政策の時の Random 政策を基準とした際の結果. 各パネルは縦軸に補助金サイズ σ , 横軸に相対ワクチン接種コスト C_r をとっており, Random 政策の結果との差を, ヒートマップとして結果が示されている. 上段から, 協調率 f_c ((a-*)のパネル), ワクチン接種率 VC ((b-*)のパネル), 最終感染者サイズ FES ((c-*)のパネル), 社会平均利得 SAP ((d-*)のパネル) を示している. また, (I)は IB-RA, (II)は SB-RA, (III)は DC の時の結果を示しており, 各列の(*-1), (*-2)はそれぞれ, Hub-priority から Random を引いた時の結果, Fringe-priority から Random を引いた時の結果を示している. また, 青色に近いほど Random 政策より良い結果で, 赤色に近いほど悪い結果である.




図 4-8 D-priority 補助金政策の時の Random 政策を基準とした際の結果. 各パネルの配置などは, すべて図 4-7 と同じである.




図 4-9 Mix 補助金政策の時の Random 政策を基準とした際の結果. 各パネルの配置などは、すべて図 4-7 と同じである.

4.3.3 ハブ優先政策と十分な補助金予算によるワクチン接種

まず、補助金サイズ σ が $\sigma \geq 0.2$ の場合について注目する.

図 4-5 と図 4-6 の Hub-priority と D-priority および Mix 政策の時の、最終感染者サイズ FES と社会平均利得 SAP (図 4-5 と図 4-6 の(c-2)と(d-2)) に注目すると、両方の結果で良い結果を示していることがわかる. この組み合わせの政策は、感染症蔓延を最も効率的に、つまり少ないワクチン接種者で抑制するため、社会平均利得も高くなっている. また、最終感染者サイズ FES に注目すると、ほぼ完全に感染症蔓延を抑え込むことに成功しているのが見て取れる. つまり、十分な量のフリーチケットがハブエージェントに優先的に配布されると、ほぼ完全に感染症蔓延を抑え込むことができることを意味している. 本研究で用いたネットワークでは、概ね $\sigma = 0.2$ と補助金サイズを確保できれば、次数の高い順にフリーチケットを配布することで、効率的に感染症蔓延を抑え込むことができる.

なぜ、D-priority および Mix 政策では優先する戦略に違いがあるのに、先のようなことがいえるのかというと、両政策とも自発的ワクチン接種者の割合 f_c が 0 に近づくからである.

なぜなら、D-priority というまでもなく、Mix においても、ハブエージェントは、自発的にワクチン接種を行わずとも、戦略に関係なくフリーチケットによってワクチン接種を行うため、感染症蔓延がほぼ起きなくなり、フリーチケットをもらえないエージェントたちも、わざわざ自発的にワクチン接種を行わなくても、感染する可能性は限りなく 0 に近いので、ワクチン接種にコストを支払うよりも、ただ乗りを狙った方が得策だからである。このように効率的に感染症蔓延を抑えるが、社会全体が D 戦略となる政策が健全であるかどうかは、判断が難しい結果であるといえる。

ただし、先ほどの D-priority, Mix にかかわらず D 戦略が完全支配する社会を作り出すのは、戦略更新ルールが IB-RA と SB-RA の時だけで、DC の場合、ほかの 2 つの戦略更新ルールに比べ、明らかに D-priority よりも Mix 政策の時の方が D 戦略の比率が小さい。これが意味するのは、DC の戦略更新を用いるような社会では、この政策はワクチン接種の無駄打ちを招くことになり、効率という観点からは、ほか 2 つの戦略更新に対しては劣るということである。なぜなら、Mix 政策は、高次数であれば、その戦略に関係なくフリーチケットを配布する政策なので、ハブエージェントに十分な量のフリーチケットを配布することができ、フリーチケット以外によるワクチン接種は、効率的に感染症蔓延を防ぐという観点において、必要ないワクチン接種だからである。つまり、フリーチケットによるワクチン接種だけで、十分に感染症蔓延を抑えることができるにもかかわらず、D 戦略が完全に支配していないということは、フリーチケット以外、つまり自発的にワクチン接種を行う者がおり、この者たちは無駄にワクチン接種を打つということになる。これは D-priority と Mix の社会平均利得 SAP （図 4-5 の(d-2)と図 4-6 の(d-2)）に注目すると、Mix の方が D-priority に比べ、若干だが社会平均利得 SAP が -1 に近いことから確認することができる。では、なぜ、DC のみで発生し、IB-RA と SB-RA はこのような状況が生じないのだろうか。これは、IB-RA と SB-RA は、比較する相手の利得の計算方法に差はあるが、どちらも対戦相手の戦略を模倣するルールなのに対し、DC は、第 1 近傍の隣人の C 戦略と D 戦略の平均利得を用いて、直接戦略を決定するという違いに起因する。IB-RA と SB-RA は、自身が D 戦略だった場合に、C 戦略の隣人の方がよい利得を持っていたとしても、そもそも対戦相手としてこの C 戦略を持つ隣人を選択しない限り、戦略が更新されることはない。一方で、DC では、自身の戦略にかかわらず、隣人の C 戦略と D 戦略の平均利得を用いて直接戦略を更新するため、C 戦略を完全に駆逐するには、隣人が全員 D 戦略にならないければならず、IB-RA と SB-RA に比べ、ずいぶん厳しい条件である。したがって、DC では、完全な D 戦略支配とはならず、IB-RA と SB-RA では C 戦略が残りやすい更新ルールのため、D 戦略支配となる。

4.3.4 低予算でのワクチン接種政策

この節では補助金サイズが小さい場合、つまり、 $\sigma = 0.1$ の場合に注目する。この補助金サイズでは、フリーチケットのみで感染症蔓延を抑え込むことは不可能で、自主的なワクチン

接種が求められる。

この補助金サイズでは、図 4-4 から図 4-6 を見るに、Mix かつ Hub-priority 政策の DC 戦略更新ルールの場合が、最終感染者サイズ FES (図 4-6 の(III)の(c-2)) と社会平均利得 SAP (図 4-6 の(III)の(d-2)) の両方で最も良い結果を示していることが見て取れる。ほかの政策の組み合わせや、ほかの更新ルールである IB-RA や SB-RA は、このケースの DC ほど良い結果は示せていない。

限られた予算、つまり $\sigma = 0.1$ で感染症蔓延を抑え込むには、フリーチケットによるワクチン接種者のほかに、自主的にワクチン接種を行うことが求められる。前節で述べたように、DC では、IB-RA や SB-RA と違い、C 戦略を駆逐することが困難なため、C 戦略が程よく残り続けることで、どうしてもフリーチケットを手に入れられない低次数の Fringe エージェントたちは、ワクチン接種を行った方が感染するよりも支払うコストが少ないと判断することで、ある程度の自主的ワクチン接種者を確保できていると考えられる。一方で、IB-RA と SB-RA では、そもそも D 戦略が支配的になりやすいため、次数を多く持つエージェントは、一度でも D 戦略になると、自身はどちらの戦略だったとしても、フリーチケットでワクチン接種を行っているため、利得は最大値の 0 となり、対戦相手がワクチン接種を自主的に行った場合は最大利得以下のため、C 戦略をとるインセンティブが働かない。したがって、フリーチケットをもらうハブエージェントは、一度でも D 戦略になると D 戦略をとり続け、この D 戦略の誤った成功体験が多くのエージェントに伝わってしまうと考えられる。

現実社会では、公衆衛生に対する政府の予算は常に不足気味で、予算は少なければ少ないほど良い。したがって $\sigma = 0.1$ の結果は $\sigma \geq 0.2$ よりも現実的な議論を行える補助金サイズであるといえる。何度もいうが、このように補助金サイズが小さく、補助金のみで集団免疫を達成できない場合は、自主的にワクチン接種を行う者を増やさなければならない。したがって、このようなケースでは、補助金は自主的にワクチン接種を行う動機を奪うのではなく、後押しするように働かなければならない。つまり、この結果は、補助金を十分に確保できない場合、政府は戦略に関係なく、ハブエージェント優先でフリーチケットを配り、さらに集団内の人々が、自身の利得と対戦相手の利得差による戦略更新ではなく、C 戦略と D 戦略の平均利得を直接判断させるような情報開示の仕方をしなければならない、ということを示唆している。

4.3.5 ハブ優先政策の妥当性

前節までで、ハブエージェントに優先的に配布する Hub-priority 政策が有効であると述べてきたが、果たしてすべてのケースでこの説は正しいのだろうか。

図 4-5 の IB-RA と SB-RA の Hub-priority と Fringe-priority (図 4-5 の(I)と(II)の(*-2)と(*-3)) の点線の三角形で囲まれた範囲に注目し比較する。このように、限られた範囲内ではあるが、協調率 f_c 、ワクチン接種率 VC 、最終感染者サイズ FES 、社会平均利得 SAP のすべて

で、Fringe-priority 政策の方が Hub-priority よりも優れた結果を示している。この違いは Random 政策の結果を基準とした、図 4-8 の Hub-priority と Random 政策の差と、Fringe-priority と Random 政策の差のヒートマップの点線で囲まれた三角形の範囲に注目すると、より明らかになる。したがって、この、補助金サイズが小さく、かつ相対ワクチン接種コストも小さい範囲では、Fringe-priority 政策の方が、Hub-priority 政策よりも社会にとってより良い結果を示すことがわかった。

一見すると逆説的にうつるこの結果の裏にはどのようなメカニズムが隠れているのだろうか。

D-priority かつ Hub-priority 政策下では、ハブエージェントは前述の通り D 戦略になり、このハブエージェントの周りにいるエージェントは、ハブエージェントが常にただ乗り成功している状況を見て、D 戦略を模倣する可能性が高い。そのため、ハブエージェントの D 戦略が爆発的に広がっていく。幸い、この三角形で囲われた範囲は相対ワクチン接種コストと補助金サイズの両方が小さいため、ハブエージェントの一部は、フリーチケットを受け取ることができず、C 戦略を維持せざるを得ないエージェントもいるため、完全に C 戦略が駆逐されることはなく、爆発的な感染症蔓延を迎えることはない。

一方、Fringe-priority 政策下では、隣人数が少ないエージェントに優先的にフリーチケットが配布され、また、この低次数のエージェントは、最低でも、全体の人数比に対し 1 割以上は確実に存在するため、D 戦略に優先的にフリーチケットを配ったとしても、ハブエージェントを含む多くのエージェントは感染症のリスクにさらされることになる。特にハブエージェントは多くの隣人と接しているため感染リスクが高い。そのため、ハブエージェントは自衛のためにワクチン接種を行わざるを得ず、そのほかのフリーチケットを受け取れなかったエージェントも、相対ワクチン接種コストが低く、ただ乗り成功する確率が低いこの状況下では、自主的にワクチン接種を行った方が得であるため、ワクチン接種率が高くなる。つまり、この、Fringe-priority かつ D-priority 政策は、状況次第では協調率 f_c を押し上げ、ワクチン接種率を高め、最終感染者サイズ FES を低くすることで、社会平均利得 SAP も良くすることができる可能性を持っているということである。

そもそも Hub-priority や D-priority 政策が受け入れられるのかという疑問が生じる人もいるだろう。Hub-priority は、いわば、医者や学校の先生、公共交通機関の運転手などに優先的にワクチン接種を補助金によって受けさせることであり、このように多くの人と接する立場の人間がワクチン接種を行っておらず、その人物に自身が接しなければならない状況を考えると、なぜワクチン接種を行っていないのか、という考えが浮かぶ人が大半であると考えられるため、一般的に広く受け入れられやすい政策であると考えられる。また、D-priority 政策では、そもそも D 戦略をとる人の中には、自身の意思にかかわらず、金銭的にワクチン接種を行う余裕がない人も含まれるため、このような人に対し優先的に福祉を提供する、すなわち

ワクチン接種をフリーチケットの配布によって接種させることも、一般的に広く受け入れられる政策であると考えられる。

以上より、フリーチケットを D-priority 政策で配布し、戦略更新ルールに DC が適用されるような社会では、Hub-priority 政策は常に有効であるとは限らず、一部の状況下では Fringe-priority が導入されるべきであるということを、この節の結果と考察は示唆している。


4.3.6 最適な補助金政策が無駄な支出をどの程度削減できるか

図 4-10 に、相対ワクチン接種コスト $C_r = 0.4$ を想定した際の、Hub-priority 政策下における異なる補助金政策の補助金サイズ σ に対する、各戦略更新ルールの最終感染者サイズ FES の結果を示している。相対ワクチン接種コスト C_r が 0.4 の時は、図 4-4 から図 4-6 によって、Mix かつ Hub-priority 補助金政策が最も効率的に感染症蔓延を抑え込むことに成功している。この政策の結果が図 4-10 に実線として示されており、点線は次数や戦略に関係なく、完全にランダムに選出した際の結果を示している。


完全ランダムに選出した場合、IB-RA と SB-RA ((a)と(b)) では、最終感染者サイズ FES は、補助金サイズ σ が中間値となる辺りで最大値をとる、凸型の傾向を示している。これは、Hub-priority 政策のもと、フリーチケットを高次数エージェントに優先的に配布すると、自発的にワクチン接種を行うエージェント数が減少してしまうため、感染症蔓延を抑え込むのに必要なワクチン接種者数を確保できなくなり、感染症が蔓延してしまうからである。一方で、DC ((c)) の場合は、完全ランダムに選出した場合、最終感染者サイズ FES は単調減少を示している。これは、この戦略更新ルールでは C 戦略を駆逐しにくい戦略更新ルールであるため、一定数のワクチン接種者を確保するに至り、感染症蔓延を比較的抑え込むことに成功したからである。

また、図中の矢印は、最終感染者サイズ FES が 0.1 の時の完全ランダムに選出した場合と Mix 政策の差を示している。これは、完全ランダムに選出した場合に比べ、どれだけ補助金の予算を減らせるかを示していると、言い換えることができ、このことから、実際に補助金政策を試してから評価を行うのではなく、シミュレーションで事前に評価を行うことの重要性がうかがえる。

(a)



(b)



(c)




図 4-10 縦軸に最終感染者サイズ FES ，横軸に補助金サイズ σ をとったグラフ．相対ワクチン接種コスト C_r は $C_r = 0.4$ の場合で，政策は，すべて Hub-priority とした時の結果であり，上段から，IB-RA (a)，SB-RA (b)，DC (c) の戦略更新ルールの場合の結果を示している．また，青丸が C-priority，赤丸が D-priority，黒の実線が Mix，黒の破線が Mix かつ Random，つまり，完全にランダム選出された場合の結果を，それぞれ示している．

4.4 結論

本研究では、進化ゲーム理論と SIR/V ダイナミクスを組み合わせた MAS モデルを使用し、様々なフリーチケットによる補助金政策をシミュレーション、評価することで、世界が直面する感染症の脅威に対抗する術を、提案、考察した。

本研究で提案したモデルでは、基盤ネットワークとしてスケールフリー性を持つネットワークを採用し、政策としては、エージェントの戦略と、エージェントの感染リスクに着目した、2つの概念の組み合わせから、計9つの政策を試し、結果、ほとんどの場合で Hub-priority 政策が、最終感染者サイズと社会平均利得の両方の面で、最も優れていることを見出した。しかし、補助金の予算が十分とはいえず、ワクチン接種者コストも感染コストに比べて十分に低い場合は、Hub-priority よりも Fringe-priority の方が優れている政策であることを発見した。

現実的な観点から、補助金の予算が非常に小さい状況は十分にあり得ることで、この場合、補助金によるフリーチケットだけでは、感染症蔓延を抑え込むに必要なワクチン接種者を十分にそろえることができず、自主的にワクチン接種を行う者を増やす必要がある。社会に適用される戦略更新ルールが、隣人の戦略を模倣せずに直接戦略を決定する DC が戦略更新ルールとなる場合は、フリーチケットによる自主ワクチン接種者を増やすことが可能で、戦略に関係なく、とにかく次数の大きいエージェントに優先的にフリーチケットを配布すると、特にこの傾向が強く出ることがわかった。

本研究で提案したモデルは、完全ランダムに選出したエージェントに対しフリーチケットを配布する方法と、最適な政策の最終感染者サイズを比較することができた。そのため、どれだけ補助金を節約できるかを予測することができ、この節約できるであろう予算を、補助金制度構築にかかわるほかの開発や整備に回すことが可能だということを示唆している。

本モデルでは、ワクチン接種を行った者は完全免疫を獲得するとしているが、実際には完全免疫を獲得するワクチン接種は少ないため、不完全免疫となるワクチン接種 [30]を考慮し、モデルを再構築することは重要なことである。また、先制的ワクチン接種だけではなく、感染症蔓延中にワクチン接種を行う後期ワクチン接種もモデルに組み込む必要がある [31]。そしてこれらを取り込んだモデルに対し、フリーチケットのみではなく、割引政策も盛り込んだモデルを構築し、評価考察を行うことが、今後の課題となる。

参照文献

- [1] R. M. Anderson and R. M. May, *Infectious Diseases of Humans: Dynamics and Control*, Oxford University Press (1992).
- [2] T. C. Reluga, C. T. Bauch, and A. P. Galvani, *Evolving Public Perceptions and Stability in Vaccine Uptake*, *Math Biosci* 204, 185 (2006).
- [3] M. L. Ndeffo Mbah, J. Liu, C. T. Bauch, Y. I. Tekel, J. Medlock, L. A. Meyers, and A. P. Galvani, *The Impact of Imitation on Vaccination Behavior in Social Contact Networks*, *PLoS Comput Biol* 8, e1002469 (2012).
- [4] J. Tanimoto, *Fundamentals of Evolutionary Game Theory and Its Applications*, Vol. 6 (Springer: Tokyo Japan, 2015).
- [5] J. Tanimoto, *Evolutionary Games with Sociophysics: Analysis of Traffic Flow and Epidemics*, Vol. 17 (Springer, Singapore, 2018).
- [6] C. T. Bauch, A. P. Galvani, and D. J. D. Earn, *Group Interest versus Self-Interest in Smallpox Vaccination Policy*, *Proc Natl Acad Sci U S A* 100, 10564 (2003).
- [7] F. Fu, D. I. Rosenbloom, L. Wang, and M. A. Nowak, *Imitation Dynamics of Vaccination Behaviour on Social Networks*, *Proceedings of the Royal Society B: Biological Sciences* 278, 42 (2011).
- [8] X.-T. Liu, Z.-X. Wu, and L. Zhang, *Impact of Committed Individuals on Vaccination Behavior*, *Phys Rev E* 86, 051132 (2012).
- [9] A. Cardillo, C. Reyes-Suárez, F. Naranjo, and J. Gómez-Gardeñes, *Evolutionary Vaccination Dilemma in Complex Networks*, *Phys Rev E* 88, 032803 (2013).
- [10] E. Fukuda, S. Kokubo, J. Tanimoto, Z. Wang, A. Hagishima, and N. Ikegaya, *Risk Assessment for Infectious Disease and Its Impact on Voluntary Vaccination Behavior in Social Networks*, *Chaos Solitons Fractals* 68, 1 (2014).
- [11] E. Fukuda, J. Tanimoto, and M. Akimoto, *Influence of Breaking the Symmetry between Disease Transmission and Information Propagation Networks on Stepwise Decisions Concerning Vaccination*, *Chaos Solitons Fractals* 80, 47 (2015).
- [12] E. Fukuda and J. Tanimoto, *Effects of Stubborn Decision-Makers on Vaccination and Disease Propagation in Social Networks*, *International Journal of Automation and Logistics* 2, 78 (2016).
- [13] Y. Ida and J. Tanimoto, *Effect of Noise-Perturbing Intermediate Defense Measures in Voluntary Vaccination Games*, *Chaos Solitons Fractals* 106, 337 (2018).
- [14] Y. Iwamura and J. Tanimoto, *Realistic Decision-Making Processes in a Vaccination Game*, *Physica A: Statistical Mechanics and Its Applications* 494, 236 (2018).
- [15] K. Kuga and J. Tanimoto, *Which Is More Effective for Suppressing an Infectious Disease: Imperfect Vaccination or Defense against Contagion?*, *Journal of Statistical Mechanics: Theory*

and Experiment 2018, 023407 (2018).

- [16] K. Kuga and J. Tanimoto, Impact of Imperfect Vaccination and Defense against Contagion on Vaccination Behavior in Complex Networks, *Journal of Statistical Mechanics: Theory and Experiment* 2018, 113402 (2018).
- [17] D. Yamin and A. Gavius, Incentives' Effect in Influenza Vaccination Policy, *Manage Sci* 59, 2667 (2013).
- [18] H.-F. Zhang, Z.-X. Wu, X.-K. Xu, M. Small, L. Wang, and B.-H. Wang, Impacts of Subsidy Policies on Vaccination Decisions in Contact Networks, *Phys Rev E* 88, 012813 (2013).
- [19] H.-F. Zhang, Z.-X. Wu, M. Tang, and Y.-C. Lai, Effects of Behavioral Response and Vaccination Policy on Epidemic Spreading - an Approach Based on Evolutionary-Game Dynamics, *Sci Rep* 4, 5666 (2014).
- [20] H. F. Zhang, P. P. Shu, Z. Wang, M. Tang, and M. Small, Preferential Imitation Can Invalidate Targeted Subsidy Policies on Seasonal-Influenza Diseases, *Appl Math Comput* 294, 332 (2017).
- [21] G.-M. Tang, C.-R. Cai, and Z.-X. Wu, Evolutionary Vaccination Dynamics with Internal Support Mechanisms, *Physica A: Statistical Mechanics and Its Applications* 473, 135 (2017).
- [22] Q. Li, M. Li, L. Lv, C. Guo, and K. Lu, A New Prediction Model of Infectious Diseases with Vaccination Strategies Based on Evolutionary Game Theory, *Chaos Solitons Fractals* 104, 51 (2017).
- [23] H. Ding, J. H. Xu, Z. Wang, Y. Z. Ren, and G. H. Cui, Subsidy Strategy Based on History Information Can Stimulate Voluntary Vaccination Behaviors on Seasonal Diseases, *Physica A: Statistical Mechanics and Its Applications* 503, 390 (2018).
- [24] R. Matsuzawa, J. Tanimoto, and E. Fukuda, Spatial Prisoner's Dilemma Games with Zealous Cooperators, *Phys Rev E* 94, 022114 (2016).
- [25] R. Cohen, K. Erez, D. ben-Avraham, and S. Havlin, Breakdown of the Internet under Intentional Attack, *Phys Rev Lett* 86, 3682 (2001).
- [26] F. Taghavian, M. Salehi, and M. Teimouri, A Local Immunization Strategy for Networks with Overlapping Community Structure, *Physica A: Statistical Mechanics and Its Applications* 467, 148 (2017).
- [27] K. Kuga, J. Tanimoto, and M. Jusup, To Vaccinate or Not to Vaccinate: A Comprehensive Study of Vaccination-Subsidizing Policies with Multi-Agent Simulations and Mean-Field Modeling, *J Theor Biol* 469, 107 (2019).
- [28] A. L. Barabási and R. Albert, Emergence of Scaling in Random Networks, *Science* (1979) 286, 509 (1999).
- [29] D. T. Gillespie, Exact Stochastic Simulation of Coupled Chemical Reactions, *J Phys Chem* 81, 2340 (1977).

- [30] X. Chen and F. Fu, Imperfect Vaccine and Hysteresis, *Proceedings of the Royal Society B: Biological Sciences* 286, 20182406 (2019).
- [31] F. Fu, N. A. Christakis, and J. H. Fowler, Dueling Biological and Social Contagions, *Sci Rep* 7, 43634 (2017).

第5章 自動運転車両と人間運転車両混在系交通流の背後に潜在する社会ジレンマの解析と自動運転システムの社会受容性に関する研究

5.1 はじめに

昨今、日本では高齢者によるアクセルペダルとブレーキペダルの踏み間違いや、高速道路上での本線逆走による死亡事故などが大きな問題となっている。また、運送業界では、残業時間の上限規制が2024年の4月から本格施行されたことに伴い、もともと懸念されていた人手不足がより深刻な問題として浮上している。これらを解決する一つの有力な案として、自動運転制御システム（Automated Vehicle Control System, AVCS）がある。このAVCSによる車両のみが走行する場合、これらの車両は「隊列走行」と呼ばれる、車両同士が通信することで可能となる、最小限の車両間隔で高速移動する塊を形成し、走行する（platoon 走行）ことができるようになる。これは、人間による運転では確実に事故を起こすような車両間隔と速度の組み合わせでの走行が可能となるため、1台当たりの道路の専有面積を大幅に減らすことが可能となり、交通渋滞の解消、それに伴う無駄なエネルギーの削減と排気ガス削減による大気汚染の抑制、移動速度向上に伴う旅行時間の削減が可能となる。このように、AVCS 車両は道路という限られた資源、つまり「公共財」を最大限に使用することが可能で、これは、AVCS 車両が自己中心的な運転、例えば、割り込みに近い車線変更や、交通量の少ない脇道へ進入するために、交通量の多い交差点で右折するなどの、非協力的な運転はせず、社会全体の効率を考えた運転を、AVCS 車両全体が実施することで供与される利益である。これはつまり、AVCS 車両は協調的な戦略とみなすことができ、この場合、人間の運転する車両は非協調的な戦略とみなすことができる。なぜなら、人間の運転する車両は、人によって程度はあるものの、基本的には、先に挙げた例のように、自己利益を追求した運転になっている可能性が高いからである。つまり、この協調的な戦略である AVCS 車両と、非協調的な人間の運転する車両が混在する交通流では、ジレンマ構造を持つ可能性があり、AVCS 車両を社会に普及させるためには、ジレンマ構造の存在の有無の確認や、存在する場合にはどのようなジレンマ構造を有しているかの解析が、非常に重要となる。

人間が運転する場合、自分勝手に運転する場合というのは、たいてい目的地に早く着きたい時である。この場合、車線が複数あるならば、車線変更を行って前方車両を追い抜くのが旅行時間短縮につながる行為となる。この車線変更を行う車両には、しばしば割り込みに近い車線変更を行う車両がいる。この行為は、他車の所有しているスペース（車間距離）を奪って自身の利得（旅行時間短縮）を高める行為であることから、例えば MAS を用いた交通流モデルである Cellular Automata モデル（CA モデル）[1–3]による交通流学とゲーム理論を結びつけた先行研究がいくつかあり、これらの研究の報告によると、頻繁な車線変更は多人数の囚人のジレンマとして分類される、深刻なジレンマを引き起こす[4–8]、とされている。ほかに

は、目的地までの経路選択問題 [9]、特にカーナビゲーションシステムを通じて提供される、特定の情報に依存した経路選択を行った場合 [10]、囚人のジレンマとは別のジレンマが生じることがあるとされている。これらのジレンマ問題が、AVCS 車両と人間の運転する車両の混合流でも引き続き発生し、場合によっては、より深刻な問題になり得ると考えられる。

そのため、AVCS 車両と人間の運転する車両の混合流に関する研究も、数多く行われている。例えば、フィールド調査に基づく研究 [11]をはじめとし、車両追従型の数理モデルであるミクロモデルを基盤とする研究 [12–15]など、幅広い研究が行われている。これらの研究の中には、各車両が連携して走行する、platoon 走行を行う AVCS に関する研究も含まれている [16–19]。しかし、既往研究には AVCS 車両と人間の運転する車両の混合流を、社会全体の効率を悪化させるジレンマ構造を持つ複雑な動的システムとして捉えた研究はなく、AVCS 車両を普及させるために、必要な解析といえる。

以上の観点から、本研究では、Adaptive Cruise Control (ACC) と協調型 ACC (Cooperative Adaptive Cruise Control, CACC) による 2 種類の自動運転車両と、人間が運転する車両が混在する交通流モデルを構築し、この混合流の背景に存在するジレンマについて解析を行うことを目的とする。

本章の構成は次の通りで、節 5.2 で CA モデルの確立と、ACC, CACC 車両を再現し、節 5.3 で AVCS 車両と人間の運転する車両が混在する 3 車線のモデルを数値実験し、節 5.4 でモデルの数値結果と結果に対する考察し、節 5.5 で結論を述べる。

5.2 モデルの概要

本研究では、図 5-1 に示す通り、人間が運転する車両と AVCS 車両の 2 種類が存在する混合流を前提とする。




図 5-1 人間が運転する車両と AVCS 車両の概念図と AVCS 車両の分類. (a)は人間が運転する車両の場合で、D 戦略であり、(b)と(c)はそれぞれ AVCS 車両で、C 戦略である. (b)と(c)の違いは、(b)は AVCS 車両の前方に D 戦略車両がいる場合で、(c)は C 戦略車両同士で走行している場合であり、前者を ACC、後者を CACC 車両と呼ぶ. また(c)の C 戦略車両の先頭車両は、前方に D 戦略車両がいるため ACC 車両に分類される.

人間が運転する車両は、既述の通り、自身の利益を最大化する運転、すなわち旅行時間短縮を目指した運転を行うため、頻繁に車線変更を行ったり、状況によっては速度超過を辞さなかったりと、周囲の車両よりも速く走行することを望んでいると仮定する. そして、この車両を表現するモデルとして、Revised Stochastic Nishinari Fukui Schadschneider (Revised S-NFS) [20] を使用する.

AVCS 車両は Adaptive Cruise Control (ACC) 車両で、レーダー探知機によって前方車両との車間距離を物理的に測りながらコントロールする機能を備えている. さらに付帯機能として、前方車両が自動運転車両の場合、この車両との局所的な情報、すなわち車間距離、加速度、速度などを無線通信などによって情報を得ることによって、platoon 走行を行うことができる. これを Cooperative Adaptive Cruise Control (CACC) と呼び、自動運転車両のうち、前方車両が人間の運転する車両だった場合を ACC、AVCS 車両だった場合は CACC となる.

また、本研究では、人間が運転する車両を D 戦略、AVCS 車両を C 戦略とよび、車線変更

を行うのは D 戦略のみとし、1 セルの長さを 7.5[m]、1 タイムステップを 1[s] とする。また、本モデルで取り扱う最大速度 $V_{\max}$ は、人間が運転する車両に対する最大速度 $V_{\max}^{\text{Humnan}}$ と AVCS 車両に対する最大速度 $V_{\max}^{\text{AVCS}}$ の 2 つが存在し、それぞれの組み合わせ $(V_{\max}^{\text{Humnan}}, V_{\max}^{\text{AVCS}})$ に対して 2 ケースを想定する。その 2 ケースとは、(5, 5) と (5, 4) であり、前者を Case 1、後者を Case 2 とし、速度自体は 0 から $V_{\max}$ まで 1 ずつの離散値をとるものとする。

5.2.1 人間が運転する車両

人間が運転する車両は、MAS を用いた CA モデルの一つである、Revised S-NFS [20] を使用し、車線変更は 2011 年に Kukida ら [21] が実装したモデルを参考に行う。この Revised S-NFS は、Kerner の三相理論 [1] をよく再現することが知られており、最も古典的で広く使用されている CA モデルの Nagel-Schreckenberg (NaSch) [22] とは異なり、Revised S-NFS は、車間距離による影響を random brake によって表現できる。また、このモデルは random brake のほかに、実際の運転でみられる、慣性によって現在の動きを保持する動き (slow to start) と、先頭車両やさらにその先の車両の動きを予測して加減速を行う動作 (quick start) も再現できる。これらは、基本図におけるメタ安定とその崩壊を表現するのに重要な働きをしている。

Revised S-NFS モデルには次の 6 つのルールが含まれ [20, 23],

Rule 1. “Acceleration”

$$v_i^{(1)} = \begin{cases} \min[V_{\max}^{\text{Humnan}}, v_i^{(0)} + 1], & g_i \geq G \vee v_i^{(0)} \leq v_{i-1}^{(0)} \\ v_i^{(0)}, & g_i < G \wedge v_i^{(0)} > v_{i-1}^{(0)} \end{cases} \quad (5.1)$$

Rule 2. “Slow to start”

$$v_i^{(2)} = \begin{cases} \begin{cases} \min[v_i^{(1)}, x_{i-S_i}^{t-1} - x_i^{t-1} - S_i] \\ \begin{cases} S_i = S, & \text{random}[0, 1) < r, \\ S_i = 1, & \text{random}[0, 1) \geq r \end{cases} \end{cases} & \text{random}[0, 1) < q \\ v_i^{(1)}, & \text{random}[0, 1) \geq q \end{cases} \quad (5.2)$$

Rule 3. “Perspective (Quick start; QS)”

$$v_i^{(3)} = \begin{cases} \min[v_i^{(2)}, x_{i-S_i}^t - x_i^t - S_i] \\ S_i \text{ is same with Rule 2.} \end{cases} \quad (5.3)$$

Rule 4. “Random brake”

$$v_i^{(4)} = \begin{cases} \begin{cases} \max[1, v_i^{(3)} - 1] \\ \begin{cases} p_i = P_1, & g_i \geq G \\ \begin{cases} p_i = P_2, & v_i^{(0)} < v_{i-1}^{(0)} \\ p_i = P_3, & v_i^{(0)} = v_{i-1}^{(0)} \\ p_i = P_4, & v_i^{(0)} > v_{i-1}^{(0)} \end{cases} & g_i < G \end{cases} \end{cases}, & \text{random}[0, 1) < 1 - p_i \\ v_i^{(3)}, & \text{random}[0, 1) \geq 1 - p_i \end{cases} \quad (5.4)$$

Rule 5. “Avoid collision”

$$v_i^{(5)} = \min[v_i^{(4)}, x_{i-1}^t - x_i^t + v_{i-1}^{(5)} - 1] \quad (5.5)$$

Rule 6. “Moving forward”

$$x_i^{t+1} = x_i^t + v_i^{(5)} \quad (5.6)$$

となっている． Rule 1 から 6 までは順番に適用されていく． また， i は車両番号で， $i - 1$ は前方車両を意味する． t は現在のタイムステップで， $t + 1$ は次タイムステップを意味する． x は車両位置を意味し， x_i^t は車両番号 i のタイムステップ t における車両位置となる． また， v は肩の数字の Rule 番号適用後の車両速度を意味しており， $v_i^{(0)}$ はタイムステップ t における速度で， $v_i^{(0)} = x_i^t - x_i^{t-1}$ である． また， g_i は車両番号 i の前方車両との車間距離を表しており， $g_i = x_{i-1} - x_i + 1$ である． G と P_1 から P_4 は車間距離の閾値と random brake 適用確率で， それぞれモデルパラメータである． また P_1 から P_4 は $P_1 > P_2 > P_3 > P_4$ の関係が成立するように設定される． q と r は閾値を表すモデルパラメータで， S もまたモデルパラメータである． また， S と S_i はそれぞれ見通し台数を表している． 本研究では， 各モデルパラメータに対し， $q = 0.99$ ， $r = 0.99$ ， $S = 2$ ， $P_1 = 0.999$ ， $P_2 = 0.99$ ， $P_3 = 0.98$ ， $P_4 = 0.01$ ， $G = 15$ を仮定する．

また， もともと Rule 5 の式(5.5)の右辺 $v_{i-1}^{(5)}$ は $v_{i-1}^{(4)}$ であったが， この式では衝突を回避するために不自然な減速が観測され， 加速しにくいモデルになっていたため， 現在の式(5.5)の形式に修正した． また， Rule 5 は， Rule 5 適用後の前方車両の速度が参照されているため， モデルを実装する際はループ構造になり， 全車両の $v^{(5)}$ が変化しなくなるまで繰り返され， Rule 5 の適用は前方から後方に順に適用する． Rule 5 は前進する際に前方車両との接触を避けるためのルールであり， Rule 6 と合わせて前進動力学に関するルールに分類され， これについての説明は後の節 5.2.4 で説明する．

横方向動力学である車線変更に関するルールには， 周囲の車両との車間距離と速度差の両方を考慮する Kukida ら [21] のルールを仮定し，

インセンティブ基準

$$gap_p^f \leq v_i^p - v_{i-1}^p \wedge gap_n^f > v_i^p - v_{i-1}^p \wedge gap_n^f > 0 \quad (5.7)$$

安全基準

$$gap_n^b \geq v_{i+1}^n - v_i^p \quad (5.8)$$

の 2 つの基準をとともに満たす時に車線変更を行う． 式中の gap は車間距離のことで， 上付き文字の f と b は， それぞれ， 前方車両と後方車両を表している． また下付き文字の p と n は現在の車線と目標とする車線（車線 p に隣接する車線）を示している． つまり， gap_n^f は目標車線の前方車両と， 自身の車両が目標車線にあったと仮定した時の車間距離を表している． また， v は速度を表しており， 上付き文字の p と n は同じく車線を， 下付き文字の i は車両番号を表しており， $i - 1$ は前方車両を表す．

インセンティブ基準は， 現在の車線を走行するよりも車線 n に移った方が， より前方に進め

るかどうかを表しており、安全基準は車線変更後に後方車両から追突される可能性がないかどうかを表している。

5.2.2 Adaptive Cruise Control (ACC) 車両

ACC 車両の場合、前方車両が人間の運転する車両のため、ACC 車両 i が手に入れられる正確な情報は、前方車両 $i-1$ との車間距離 g_i のみとなる。また、ACC 車両は人間が運転する車両ではないため、Revised S-NFS における Rule 2 から Rule 4 までのルールは必要なく、加減速のみを表現すればよい。そこで車両番号 i の速度調整後 v'_i 、現在の速度 v_i とすると、

Rule for ACC

$$v'_i = \begin{cases} \begin{cases} v_i, & g_i = 0 \\ v_i + 1, & g_i \geq 1 \end{cases} & v_i = 0 \\ \begin{cases} v_i - 1, & g_i \leq GAP_1^{v_i} \\ v_i, & GAP_1^{v_i} < g_i < GAP_2^{v_i}, \quad 1 \leq v_i \leq V_{\max}^{\text{AVCS}} - 1 \\ v_i + 1, & g_i \geq GAP_2^{v_i} \end{cases} & \\ \begin{cases} v_i - 1, & g_i \leq gp_{V_{\max}^{\text{AVCS}}}^{\text{ACC}} \\ v_i + 1, & g_i > gp_{V_{\max}^{\text{AVCS}}}^{\text{ACC}} \end{cases} & v_i = V_{\max}^{\text{AVCS}} \end{cases} \quad (5.9)$$

で与えられる。また、式中の GAP_1 ($GAP_1^{v_i} \in (gp_1^{\text{ACC}}, \dots, gp_{V_{\max}^{\text{AVCS}}-1}^{\text{ACC}})$) および $GAP_2^{v_i}$ ($GAP_2^{v_i} \in$

$(gp_2^{\text{ACC}}, \dots, gp_{V_{\max}^{\text{AVCS}}}^{\text{ACC}})$) は、産業技術報告書 [24]の値を本モデルに合わせて数値変換を行った結

果で、 $gp_1^{\text{ACC}} = 0$, $gp_2^{\text{ACC}} = 4$, $gp_3^{\text{ACC}} = 6$, $gp_4^{\text{ACC}} = 8$, $gp_5^{\text{ACC}} = 10$ と設定され、Case 1 および Case 2 における v_i と $GAP_1^{v_i}$ および $GAP_2^{v_i}$ の関係は、表 5-1 と表 5-2 に示す通り、速度 v_i によって値が切り替わる。

式(5.9)で求めた速度 v'_i は、Revised S-NFS の Rule 5 に適用する速度 $v_i^{(4)}$ にあたる。なぜなら、AVCS 車両は Revised S-NFS における Rule 1 から Rule 4 までの人間の特徴を再現したルールであり、Rule 4 終了時点での速度は、いわば、次タイムステップにおける前方車両との衝突を加味していない目標最大速度で、式(5.9)で求めた速度 v'_i もまた、前方車両と衝突を加味していない目標最大速度だからである。したがって、その後の前進動力学は衝突回避と前進処理が必要なため、これは Revised S-NFS の Rule 5 と Rule 6 にほかならないので、前進動力学には Revised S-NFS の Rule 5 と Rule 6 を使用し、式(5.9)で求めた速度 v'_i を Revised S-NFS の Rule 5 に適用する速度 $v_i^{(4)}$ に代入し、前進させる。

表 5-1 Case 1 における ACC の v_i と $GAP_1^{v_i}$ および $GAP_2^{v_i}$ の関係

v_i	$GAP_1^{v_i}$	$GAP_2^{v_i}$
0	-	-
1	gp_1^{ACC}	gp_2^{ACC}
2	gp_2^{ACC}	gp_3^{ACC}
3	gp_3^{ACC}	gp_4^{ACC}
4	gp_4^{ACC}	gp_5^{ACC}
5	-	-

表 5-2 Case 2 における ACC の v_i と $GAP_1^{v_i}$ および $GAP_2^{v_i}$ の関係

v_i	$GAP_1^{v_i}$	$GAP_2^{v_i}$
0	-	-
1	gp_1^{ACC}	gp_2^{ACC}
2	gp_2^{ACC}	gp_3^{ACC}
3	gp_3^{ACC}	gp_4^{ACC}
4	-	-

5.2.3 Cooperative Adaptive Cruise Control (CACC) 車両

CACC の場合は前節の ACC と違い、車両 i は前方を走行する車両 $i-1$ の現在のタイムステップの情報だけでなく、現タイムステップで一時的に更新された情報をすべて正確に把握することができる。そのため、CACC のルールは、車両番号 i の速度調整後を v'_i 、現在の速度を v_i とすると、

Rule for CACC

$$v'_i = \begin{cases} v_i + 1, & v_i < v'_{i-1} \\ \begin{cases} v'_{i-1}, & g_i = 0 \\ v'_{i-1} + 1, & g_i \geq 1 \end{cases}, & v_i = v'_{i-1} \\ \begin{cases} v_i - 1, & g_i < GAP^{\Delta v_i} \\ v_i, & g_i \geq GAP^{\Delta v_i} \end{cases}, & v_i > v'_{i-1} \end{cases} \quad (5.10)$$

で与えられる。また、式中の $GAP^{\Delta v_i}$ ($GAP^{\Delta v_i} \in (gp_1^{\text{CACC}}, \dots, gp_{V_{\text{max}}^{\text{CACC}}}^{\text{CACC}})$, $\Delta v_i = v_i - v_{i-1}$) は連続する 2 台の車両間における相対的な制動距離を表すモデルパラメータで、本モデルでは、 $gp_1^{\text{CACC}} = 1$, $gp_2^{\text{CACC}} = 3$, $gp_3^{\text{CACC}} = 8$, $gp_4^{\text{CACC}} = 12$, $gp_5^{\text{CACC}} = 17$ と仮定している。Case 1 および Case 2 における相対速度 Δv_i と $GAP^{\Delta v_i}$ の関係を表 5-3 に示しており、この表からもわかるように、相対速度 Δv_i によって用いる $GAP^{\Delta v_i}$ は切り替わる。

式(5.10)には、次タイムステップにおける前方車両の目標最大速度が含まれているため、先頭車両から後方車両に向けて順に v'_i は算出され、最後尾の車両の次タイムステップにおける目標最大速度が更新されたのち、その速度が先頭車両に影響を与える場合は、先頭車両の目標最大速度が変化しなくなるまでこの手順を繰り返す。

また、この式(5.10)で求めた速度 v'_i は、ACC の時と同様の理由で Revised S-NFS の Rule 5 に

適用する速度 $v_i^{(4)}$ にあたる．したがって，前進動力学には Revised S-NFS の Rule 5 と Rule 6 を使用し，式(5.10)で求めた速度 v_i' を Revised S-NFS の Rule 5 に適用する速度 $v_i^{(4)}$ に代入し，前進させる．

表 5-3 Case 1 と Case 2 における CACC の Δv_i と $GAP^{\Delta v_i}$ の関係

Δv_i	Case 1 $GAP^{\Delta v_i}$	Case 2 $GAP^{\Delta v_i}$
0	-	-
1	gp_1^{CACC}	gp_1^{CACC}
2	gp_2^{CACC}	gp_2^{CACC}
3	gp_3^{CACC}	gp_3^{CACC}
4	gp_4^{CACC}	gp_4^{CACC}
5	gp_5^{CACC}	-

5.2.4 混合流システム

本モデルでは，人間が運転する車両である D 戦略車両と，自動運転による車両である C 戦略車両の混合流システムを構築する必要がある．したがって，同じ系の中に両戦略の車両が同時に存在する．

前進動力学と横方向動力学（D 戦略である人間が運転する車両のみ許可される）は，次に示すような関係性で，単一フレームワーク内に構成される．

まず，次タイムステップにおける目標最大速度を，人間が運転する車両では Revised S-NFS の Rule 1 から Rule 4 を用いて，ACC 車両では Rule for ACC，CACC では Rule for CACC を用いて，並列更新ルールに従って算出する．その後，先頭車両から後方車両に向けて順に，横方向動力学によるインセンティブ基準を満たすかの判定を行い，先頭車両から後方車両に向けて順に，前進動力学である Revised S-NFS の Rule 5 と Rule 6 を適用し車両を前進させる．この時，Rule 5 の衝突回避機構の式(5.5)には前方車両の次タイムステップにおける車両速度の情報が含まれており，先頭車両は最後尾の車両の情報を参照するため，先頭車両が最後尾車両の影響を受ける場合は，再度先頭車両から後方車両に向けて順に Rule 5 を適用し，最後尾車両の影響を受けなくなるまでこの手順を繰り返し，全車両の式(5.5)の $v_i^{(5)}$ を決定する．そして，Rule 6 である，式(5.6)に従って全車両は前方に車両を進める．最後に横方向動力学のインセンティブ基準を満たした車両のうち，安全基準も満たした車両を車線変更させる．

5.3 数値シミュレーションの実装

本モデルでは、3車線の系を想定しており、周期境界条件を持つ、1セルの長さが7.5[m]の1周300セル（1周2.25[km]）のCAを使用する。また、1タイムステップの時間は1[s]である。また、全体の車両密度（車両が占めるセル数の割合）と協調率（C戦略比）を変化させ、その密度と協調率に応じたD戦略である人間の運転する車両と、C戦略であるAVCS車両を系内に発生させる。

一つの密度と協調率の組み合わせに対して、取得する結果は統計的な安定性を確保するために5000回の独立した試行のアンサンブル平均を採用する。一つの試行では、CエージェントとDエージェントがランダムに配置された状態から、流れが十分発達するまで1000タイムステップのシミュレーションが行われ、その後、さらに5000回のタイムステップにわたって、C戦略とD戦略の時間平均速度（以降、平均速度）と時間平均交通流量（平均交通流量）を測定する。本研究では、C戦略とD戦略それぞれの平均利得となる平均速度と、社会全体の平均利得となる平均交通流量に注目しており、特定の密度に対して協調率を変化させ、これら3つの基本値を得ることで、次節で述べるように、流れ場の背後に存在するジレンマ構造を特定する。

本モデルでは、先に述べたように、2つのケースを想定している。Case 1では、人間が運転する車両に対する最大速度 $V_{\max}^{\text{Humnan}}$ とAVCS車両に対する最大速度 $V_{\max}^{\text{AVCS}}$ の組み合わせ $(V_{\max}^{\text{Humnan}}, V_{\max}^{\text{AVCS}})$ を(5,5)とし、Case 2では(5,4)とする。また、1タイムステップが1[s]で、1セルの長さが7.5[m]なので、速度が5の時は135[km/h]で、4の時は108[km/h]である。

また、密度は、車両台数が50台から500台まで（密度0.056から0.61まで）は50台ずつ変化させ、それ以降は850台（密度0.94）まで100台ずつ変化せる。また各密度に対し、協調率は0から1まで0.1ずつ変化させる。

以上の条件でシミュレーションを行う。

5.4 結果と考察

図 5-2 は、Case 1 の場合における C 戦略と D 戦略の平均利得である平均速度と、社会全体の平均利得である平均交通流量が、協調率に対して、すなわち AVCS 車両の普及に対して、どのような関係性を持っているかを示している。また、(a)から(c)の順に低、中、高密度における結果をそれぞれ示している。

低密度（図 5-2 の(a)）の場合、どの線も協調率に対してほとんど影響を受けていないのが見て取れる。これは、非常に低い密度では戦略間の相互干渉が発生しないためと考えられる。なぜなら、戦略に関係なく最大速度である 5 を維持して走行できているからである。したがって、この流れ場にあるゲーム構造を、Tanimoto ら [6]による研究の用語を借りて、「ニュートラルゲーム」と呼ぶこととする。

次に中密度（図 5-2 の(b)）に注目すると、協調率が低い場合は、D 戦略の平均速度の方が C 戦略の平均速度よりも高い値を示していることが見て取れる。しかし、協調率が高くなると両者に大きな差はない。この事実は、多人数ゲームにおける Stag Hunt (SH) 型のジレンマ構造が存在し、2つの安定な均衡点が存在することを示唆している。つまり、初期の協調率に応じて、すべてが C 戦略か D 戦略になることを意味している。これを AVCS 車両の普及に置き換えて考えると、現時点では AVCS 車両の普及率はほぼ 0 であるため、安定な均衡点は、全車両が D 戦略になることを示している。これは協調率が低く、自由に車線変更を頻繁に行うことができる間は、自身で運転した方が早く目的地に到達できるため、AVCS 車両に乗り換えるだけのインセンティブが働かないことを示しており、ゆえに AVCS 車両普及に関しては非常に悲観的な結果といえる。ゲーム構造に戻ると、この環境におけるナッシュ均衡（すなわち、全車両が D 戦略の状態）は、社会全体の平均利得が最も高い社会的最適状態（すなわち、全車両が C 戦略の状態）と一致しないことが、図 5-2 の(b)の灰色の三角形と円の密度の不一致からわかる。つまり、このことは、この密度における流れ場の背景に、社会的ジレンマ構造が存在していることの、明確な証拠である。

また、高密度（図 5-2 の(c)）における流れ場に注目すると、中密度(b)の流れ場ほどではないにしろ、依然として SH 型のジレンマ構造が存在することが見て取れる。

図 5-3 は、Case 2 における C 戦略と D 戦略の平均速度と、平均交通流量と協調率の関係性を、図 5-2 の時同様、密度ごとに示した図である。中密度（図 5-3 の(b)）に注目すると、Case 1 の中密度や高密度（図 5-2 の(b)と(c)）と比較しても、協調率が低い場合では、D 戦略と C 戦略の平均速度の差がより大きくなっている、つまり D 戦略をとるインセンティブがより強く働くことから、より SH 型のジレンマ構造に陥りやすくなっていることがわかる。しかし、低密度（図 5-3 の(a)）ではまったく違う傾向を示している。この環境における流れ場では、D 戦略比が大きくなるにつれて、D 戦略の平均速度が C 戦略の平均速度を大きく上回り、それに伴って社会全体の平均利得である平均交通流量も増加している。これは単純に、Case 2 における人間が運転する車両の最大速度 $V_{\max}^{\text{Human}}$ と AVCS 車両の最大速度 $V_{\max}^{\text{AVCS}}$ に乖離があり、人

間が運転する車両の最大速度の方が高く設定されているため、速度の遅い C 戦略車両が少ない間は、邪魔する車両がいらないため最大速度で走行することが可能だからである。この環境におけるナッシュ均衡の時の密度と、社会に最適な交通流量をもたらす密度が一致しており、それが、全車両が D 戦略の時であることが図 5-3 の(a)から見て取れる。したがって、この環境における流れ場を支配しているゲーム構造は、社会的ジレンマ構造が存在しない D-dominate Trivial game (D 戦略の明示的支配ゲーム)といえる。なぜなら、人間が運転する車両のみで構成される環境こそが、個人と社会にとって最良の状態だからである。

図 5-4 は、いくつかの先行研究 [25, 26]によって導入された社会効率欠損率 (Social Efficiency Deficit, SED) を示している。この社会効率欠損率 SED は、社会的ジレンマの状況を厳密に定量化することができ、社会的に最適な状態となる理想的な状況と、ナッシュ均衡で表される進化的動態がもたらす状況の間の乖離を定量的に測定するため、社会的ジレンマが存在しない場合は 0 を示す。なぜなら社会的に最適な状況とナッシュ均衡が一致しているからである。しかし、社会効率欠損率 SED が 0 ではなく、特に増大するような場合は、進化的動態によって、系が悪い状況、つまりナッシュ均衡に閉じ込められているため、社会的に最適な状況との乖離が存在する。つまり、社会にとって欠損を招いており、この欠損を解決するためのインセンティブが強く働く状況であることを示しているため、社会効率欠損率 SED は社会的ジレンマの強度と、ある程度関連がある。なぜある程度なのかというと、いくつかの既往研究 [27-29]によると、ジレンマ強度の厳密な数学的定義は、節 2.1.3 で説明した 2×2 ゲームでのみ可能であることが証明されているため、 2×2 ゲーム以外における厳密な定義ができないからである。しかし、ジレンマの状況を評価するための定量的な指標としては機能し、少なくともゲームにジレンマ構造が含まれているかどうかを厳密に定量化することができるため、ある程度関連があるといえる。以上より、本研究における社会効率欠損率 SED を

$$SED = \frac{q_{SO} - q_{NE}}{q_{SO}} \quad (5.11)$$

と定義する。式中の q_{SO} と q_{NE} はそれぞれ、社会的最適状態における交通流量とナッシュ均衡で観察された交通流量を示している。

図 5-2 と図 5-3 で既に議論したように、Case 1 と Case 2 の低密度環境における流れ場では、社会的ジレンマ構造はまったく存在しない。そのメカニズムは両者で異なり、Case 1 ではニュートラルゲーム、Case 2 では D-dominate Trivial game に分類され、いずれにせよ、すべての車両において人間が運転する車両の現実社会に AVCS 車両を導入することによる社会的利益を定量的に議論する際に、何も影響を与えない環境といえる。しかしながら、ある一定の閾値を超えた密度では、社会効率欠損率 SED は、図 5-4 からわかるように、両ケースで単調増加を示す。社会効率欠損率 SED が 0 ではない、すなわち、社会的ジレンマ構造が存在することを示しており、このジレンマ構造は、図 5-2 と図 5-3 で議論したように、2 つの安定均衡を持つ多人数ゲームにおける SH 型となることを述べた。つまり、AVCS 車両の普及を 0 から始めな

ければならない場合、自由市場に任せても自然には普及しないことを示唆している。さらに重要な点は、社会的に最適な状況をわかっていながらも、それを達成できない状況は、より高い交通密度でさらに深刻化するという点である。図 5-2 と図 5-3 からわかるように、協調率が 1 の高密度における流れ場が、最も交通流量が高く、この時の社会効率欠損率 SED は限りなく 1 に近く、いかに理想と乖離が生じているかがわかる。これは AVCS 車両のみであれば CACC ルールに従うことで platoon 走行を実現できるため、密度による影響を限りなく排除でき、理想的な交通流を維持したまま走行できるからである。AVCS 車両が社会的に効率的な状態に達する仕組みは、個々の利益をある程度犠牲にしてでも公共の利益を最も重視すべき、という知見に基づいている。このような知見は、社会福祉問題など、さまざまな状況で広く観察され、一般的に、公共財ゲームの特徴を持つ社会的ジレンマ構造を有する。

これまでの考察により、自由市場に任せた場合、AVCS 車両の自然普及は非常に悲観的ということが明らかになった。

では、AVCS 車両を普及させるにはどのようにすればよいのだろうか。図 5-2 と図 5-3 で観察された社会的ジレンマ構造は SH 型のジレンマ構造であり、初期状態の協調率によって、どちらか一方の戦略に帰着されることがわかっている。つまり、初期状態における協調率が臨界値よりも十分に大きければ、あとは勝手に C 戦略である AVCS 車両が普及し、ほぼすべての車両が AVCS 車両になるということである。したがって、例えば、政府による補助金制度などを通して、D 戦略しかない現在の状況に対し、AVCS 車両を購入するだけの動機とメリットを与えてやり、初期状態における AVCS 車両の数を増やせば、あとは自然に AVCS 車両が普及する可能性が高いことを示唆している。




図 5-2 Case 1 の協調率と平均速度および平均交通流量の関係を表した図。図中の青い線と赤い線は C 戦略と D 戦略の平均速度，黒い線は社会全体の平均利得である平均交通流量を表している。それぞれのパネルは、左から順に、低(a)，中(b)，高(c)密度の時の結果で、図中の灰色の三角形は、初期協調率がほぼ 0 と仮定した場合のナッシュ均衡の密度を示しており、灰色の円は社会的に最適な交通流量が観察される密度を示している。




図 5-3 Case 2 の協調率と平均速度および平均交通流量の関係を表した図．書式は図 5-2 と同じである．




図 5-4 Case1 と Case 2 の社会効率欠損率 SED と密度の関係を表した図．黒色とオレンジの線は、それぞれ、Case 1 と Case 2 を表している．

5.5 結論

現在の、すべての車両において人間が運転する車両である社会に、自動協調運転システム AVCS を搭載した車両が、どのように普及するかを再現するために、人間が運転する車両と自動追尾型の ACC による AVCS 車両と、platoon 走行を可能とする協調自動追尾型の CACC による AVCS 車両が混在する、3 車線系の CA モデルを構築した。

人間が運転する車両を D 戦略、AVCS 車両を C 戦略として、両者の平均利得である平均速度と、社会全体の平均利得となる平均交通流量を評価することで、特定の交通密度における流れ場の背後に、社会ジレンマ構造が存在するかを確認し、社会的最適状態と社会的均衡状態間の乖離を表す社会効率欠損率 SED を用いて定量化することで、より確実にジレンマ構造が存在することを示した。

そのジレンマ構造とは、異なる戦略間の干渉が発生しない低密度の環境を除いて、Stag Hunt 型のジレンマ構造が存在することが確認された。このジレンマ構造では、初期状態に依存して、最終的にどちらか一方の戦略が支配的となるため、人間が運転する車両が支配する現実の流れ場における AVCS 車両の普及は難しく、特に、自由に車線変更可能な人間が運転する車両の平均速度が、常に AVCS 車両の平均速度を上回るような状況下では、絶望的ということがわかった。

このような社会的ジレンマ構造を克服するための一つの案として、政府による補助金制度を用いて、初期状態における AVCS 車両を増やすことが挙げられる。この補助金制度により、初期状態の AVCS 車両が増えることで、ジレンマの構造上、自然に AVCS 車両が普及するようになり、その結果、AVCS 車両のみが実現することができる、platoon 走行が可能となる社会を実現することができる。したがって、本研究は、外部による AVCS 車両購入のインセンティブを増加させることによって、より高い交通流量を実現する理想的な社会創造が可能である、ということを示唆することができた。

参照文献

- [1] B. S. Kerner, *The Physics of Traffic: Empirical Freeway Pattern Features, Engineering Applications, and Theory* (Springer: Heidelberg Berlin, 2004).
- [2] J. Tanimoto, *Fundamentals of Evolutionary Game Theory and Its Applications*, Vol. 6 (Springer: Tokyo Japan, 2015).
- [3] J. Tanimoto, *Evolutionary Games with Sociophysics: Analysis of Traffic Flow and Epidemics*, Vol. 17 (Springer, Singapore, 2018).
- [4] A. Yamauchi, J. Tanimoto, A. Hagishima, and H. Sagara, *Dilemma Game Structure Observed in Traffic Flow at a 2-to-1 Lane Junction*, Phys Rev E Stat Nonlin Soft Matter Phys 79, 036104 (2009).
- [5] M. Nakata, A. Yamauchi, J. Tanimoto, and A. Hagishima, *Dilemma Game Structure Hidden in Traffic Flow at a Bottleneck Due to a 2 into 1 Lane Junction*, Physica A: Statistical Mechanics and Its Applications 389, 5353 (2010).
- [6] J. Tanimoto, T. Fujiki, Z. Wang, A. Hagishima, and N. Ikegaya, *Dangerous Drivers Foster Social Dilemma Structures Hidden behind a Traffic Flow with Lane Changes*, Journal of Statistical Mechanics: Theory and Experiment 2014, 11027 (2014).
- [7] J. Tanimoto, S. Kukida, and A. Hagishima, *Social Dilemma Structures Hidden behind Traffic Flow with Lane Changes*, Journal of Statistical Mechanics: Theory and Experiment 2014, 07019 (2014).
- [8] Y. Iwamura and J. Tanimoto, *Complex Traffic Flow That Allows as Well as Hampers Lane-Changing Intrinsically Contains Social-Dilemma Structures*, Journal of Statistical Mechanics: Theory and Experiment 2018, (2018).
- [9] J. Tanimoto and K. Nakamura, *Social Dilemma Structure Hidden behind Traffic Flow with Route Selection*, Physica A: Statistical Mechanics and Its Applications 459, 92 (2016).
- [10] J. Tanimoto and H. Sagara, *Social Diffusive Impact Analysis Based on Evolutionary Computations for a Novel Car Navigation System Sharing Individual Information in Urban Traffic Systems*, The Journal of Navigation 64, 711 (2011).
- [11] R. Fu, Z. Li, Q. Sun, and C. Wang, *Human-like Car-Following Model for Autonomous Vehicles Considering the Cut-in Behavior of Other Vehicles in Mixed Traffic*, Accid Anal Prev 132, 105260 (2019).
- [12] S.-C. Lo and C.-H. Hsu, *Cellular Automata Simulation for Mixed Manual and Automated Control Traffic*, Math Comput Model 51, 1000 (2010).
- [13] B. S. Kerner, *Physics of Automated Driving in Framework of Three-Phase Traffic Theory*, Phys Rev E 97, 042303 (2018).
- [14] Z. Yao, R. Hu, Y. Wang, Y. Jiang, B. Ran, and Y. Chen, *Stability Analysis and the Fundamental*

- Diagram for Mixed Connected Automated and Human-Driven Vehicles*, Physica A: Statistical Mechanics and Its Applications 533, 121931 (2019).
- [15] W.-X. Zhu and H. M. Zhang, *Analysis of Mixed Traffic Flow with Human-Driving and Autonomous Cars Based on Car-Following Model*, Physica A: Statistical Mechanics and Its Applications 496, 274 (2018).
 - [16] J. Sau, J. Monteil, and M. Bouroche, *State-Space Linear Stability Analysis of Platoons of Cooperative Vehicles*, Transportmetrica B: Transport Dynamics 7, 18 (2019).
 - [17] Y. J. Zhou, H. B. Zhu, M. M. Guo, and J. L. Zhou, *Impact of CACC Vehicles' Cooperative Driving Strategy on Mixed Four-Lane Highway Traffic Flow*, Physica A: Statistical Mechanics and Its Applications 540, 122721 (2020).
 - [18] L. Ye and T. Yamamoto, *Modeling Connected and Autonomous Vehicles in Heterogeneous Traffic Flow*, Physica A: Statistical Mechanics and Its Applications 490, 269 (2018).
 - [19] L. Ye and T. Yamamoto, *Evaluating the Impact of Connected and Autonomous Vehicles on Traffic Safety*, Physica A: Statistical Mechanics and Its Applications 526, 121009 (2019).
 - [20] S. Kokubo, J. Tanimoto, and A. Hagishima, *A New Cellular Automata Model Including a Decelerating Damping Effect to Reproduce Kerner's Three-Phase Theory*, Physica A: Statistical Mechanics and Its Applications 390, 561 (2011).
 - [21] S. Kukida, J. Tanimoto, and A. Hagishima, *Analysis of the Influence of Lane Changing on Traffic-Flow Dynamics Based on the Cellular Automaton Model*, International Journal of Modern Physics C 22, 271 (2011).
 - [22] K. Nagel and M. Schreckenberg, *A Cellular Automaton Model for Freeway Traffic*, Journal de Physique I France 2, 2221 (1992).
 - [23] J. Tanimoto and X. An, *Improvement of Traffic Flux with Introduction of a New Lane-Change Protocol Supported by Intelligent Traffic System*, Chaos Solitons Fractals 122, 1 (2019).
 - [24] 高速道路における適正な車両間隔に関する調査研究 報告書, 公益財団法人高速道路調査会 道路・交通工学研究部会 高速道路における適正な車両間隔に関する調査研究委員会.
 - [25] Md. R. Arefin, T. Masaki, K. M. A. Kabir, and J. Tanimoto, *Interplay between Cost and Effectiveness in Influenza Vaccine Uptake: A Vaccination Game Approach*, Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences 475, 20190608 (2019).
 - [26] K. M. A. Kabir and J. Tanimoto, *Modelling and Analysing the Coexistence of Dual Dilemmas in the Proactive Vaccination Game and Retroactive Treatment Game in Epidemic Viral Dynamics*, Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences 475, 20190484 (2019).
 - [27] J. Tanimoto and H. Sagara, *Relationship between Dilemma Occurrence and the Existence of a*

Weakly Dominant Strategy in a Two-Player Symmetric Game, Biosystems 90, 105 (2007).

- [28] Z. Wang, S. Kokubo, M. Jusup, and J. Tanimoto, *Universal Scaling for the Dilemma Strength in Evolutionary Games*, Phys Life Rev 14, 1 (2015).
- [29] H. Ito and J. Tanimoto, *Scaling the Phase-Planes of Social Dilemma Strengths Shows Game-Class Changes in the Five Rules Governing the Evolution of Cooperation*, R Soc Open Sci 5, 181085 (2018).

第6章 人間の刺激 - 反応機構を包含した新たな連続系自己駆動粒子モデルによる追従模型の構築と交通流解析に関する研究

6.1 はじめに

現実の道路の流れ場を高い精度で再現する交通流モデルの開発は、stop-and-go 波やそのほかの重要な特徴を出現させる動力学を適切に考慮することで、例えば、自動運転制御システムや都市交通の正確な制御を行うことによる無駄なエネルギー消費の削減や、大気汚染物質排出を減少させるための技術開発や評価の重要な基盤となる。そのため、交通流の研究は古くから行われており、20 世紀中ごろでは、主に流体力学を用いることで再現できると考えられていた [1–4]。このモデルでは、交通流をパイプ内の水流に見立てるというマクロな考え方、すなわち Eulerian 的視点に基づいており、連続体としての厳密な定式化を行っている [2–4]。一方、物理学には別の視点があり、それはミクロな考え方、すなわち Lagrangian 的視点と呼ばれる、各車両の前進運動を正確かつ個別に考慮する視点がある。したがって、その定式化には、Newton の第二法則、つまり運動方程式を用いる [2–4]。つまり、ミクロな考え方では、交通流を多くの自己駆動粒子の流れと捉え、一方でマクロな考え方では、交通流を連続体の流れとして捉える。いくつかのマクロな考え方では、適切にモデル化することで、修正 KdV (mKdV) 方程式に基づき Soliton 理論による kink–antikink 解の形で、正確な解析解を提供できる [5, 6]。ミクロまたはマクロな考え方にかかわらず、モデルの核は、それぞれの理論（流体力学または Newton の法則）に完全に裏付けされた支配方程式のセットである。さらに、これらの方程式は時空間において連続なシステムとして表現されるべきであり、このような手法を用いて再現されたモデルによって得られた解析解、特にマクロな概念に基づいたモデルによる解は、交通流の数学的構造を解明することに一役買う。

また、1990 年代にはコンピューターの急速な成長によって、強力な解析ツールを提供するようになった、Multi Agent Simulation (MAS) を用いた交通流モデルが、再度交通流解析に注目を浴びさせた。MAS を用いた交通流モデルの特徴は、例えば、車線変更や運転手の意思決定などの局所的な状況をシミュレーションに組み込むことを可能にした点であり、より現実の交通流を再現できることが可能であるため、交通流解析に再度注目を浴びさせることになった [7, 8]。MAS を用いた交通流モデルの中で一般的なモデルである、cellular automaton (CA) モデル [9–11] は、巨視的な概念に基づく、全体を一つの流体として捉えるモデルとは違い、粒子一つ一つ、つまり、車両一台一台を自走する粒子として捉え、時間と速度の従属変数である位置について、超離散化の手法を用いることで、時間と速度だけではなく、空間（すなわち道路）も離散化して扱う。その結果、モデルの概念をそのままプログラムコードに変換することでアルゴリズムの実装が可能となり、例えば、車線の減少に伴う合流地点の流れ場や、車線変更に伴う社会的ジレンマ構造の解析や解明など、特定の状況下を比較的容易に再現すること

が可能で、多くの CA を派生させた研究が行われてきた [12–19].

このように、CA モデルは柔軟性に優れており、現実の交通流で観察することができる様々な現象、つまり、車線変更や、慣性によって現在の動きを保持する動き (slow to start)、先頭車両やさらにその先の車両の動きを予測して加減速を行う動作 (quick start) を再現できるほか、車間距離による影響を random brake によって表現できる [8–10]. これらのドライバーの現象を取り込んだモデルは、現実の交通流で観察されたフィールド測定データと比較され、その再現性の高さが確認されている [20, 21]. しかし、このような検証は、通常、基本図などのグローバルな評価指標に焦点をあてているため、どの CA モデルも局所的な車両の動きは現実のそれとはかけ離れている場合がある. 例えば、quick start を考慮した CA モデルでは、車両が前方車両に対し、自動追随システムを搭載した自動運転車両のように、まったくの時間差なく、加速度と速度ともに寸分の狂いなく完璧に追随する様子が多く確認される. しかし、これは、人間が運転する限り不可能な話であり、これらの現実離れした現象は CA モデルが時空間ともに離散化されているためであり、表現できる解像度が低すぎることに起因する問題と考えられる. したがって、この欠点を克服するには、時空間ともに連続系のモデルを構築する必要がある.

また、既存の CA モデルは、すべて、いわゆる追従モデル [22, 23] に基づいており、これは基本的に最適速度 (optimal velocity, OV) モデルに根差している [23]. OV モデルは、ドライバーが常に前方車両との車間距離に基づいて、いわゆる OV 関数を通して求めた最適速度を目標として、その速度に合うように速度を調節することを前提としたモデルである. この OV モデルを基本として、ドライバーの様々な速度調節動作を反映するために、OV 項以外の追加事項を取り入れた、多くの派生モデルが登場し、例えば、前方車両との速度差を考慮する全速度差 (full velocity difference, FVD) モデル [24–27] などがある. 最近では FVD 概念を、25 台の車列を用いて実測した実験結果に一致するように、ドライバーが望む最大および最小の時間差を考慮するように改良した、高度な FVD モデルが開発された [28]. このようなモデルには、OV 項を含む様々な項に重みが割り当てられことで、高度なモデル化を可能としている. しかし、これらの多くのモデルでは、様々な項の重みに用いた数値に対する物理的な根拠が欠けているという共通の問題を持っている. ここで疑問になるのが、ドライバーは、それぞれの項、つまり車間距離差や速度差などを、常にそれぞれの重みで同時に考慮し、加速度、および速度を決定しているのだろうか、という点である.

この疑問を解決するためには、物理的な人間の刺激に対する非線形応答を取り入れる必要がある [29, 30]. しかし、これらのモデルも、マクロもしくはミクロな視点に基づくのか、連続体モデルまたは MAS に基づくのかにかかわらず、既存のモデル同様、速度調整イベントを小さな時間間隔で連続して発生していると仮定している. 果たして人間は、この仮定のように、常に車両を制御しているのだろうか.

以上の既往モデルに対する疑問が、本研究の動機となっている. 人間は自動運転とは異なる

り、情報処理能力の限界によって、様々な要因を同時に考慮することはできない。また、常に車両の制御を行うこともしない。我々は車両の制御が確率的なイベントとして引き起こされると理解している。したがって、本研究で提唱するモデルは、車両制御は、ドライバーが環境の変化を認識した時に、つまり確率過程によって発生し、その際に、ドライバーは現在の速度を、その認知した環境に適応するように「最適」な速度に調節しようとする、という大原則に基づいたモデルである。この最適な速度は、OV モデルの OV とは異なる。また、環境の変化の認識とは、前方車両との車間距離や、現在の速度と最適な速度との速度差を認識することである。本研究では、これらのことを考慮した時空間ともに連続なモデルを構築することを目指す。そこで、まずは数理モデルにより時空間連続系のモデルを構築し、その後、このモデルを時間において離散化することで、MAS を用いて、このモデルを実装する方法を説明し、基本図や局所的な車両の動きを解析することで、本モデルの有用性を評価する。

本章の構成は次の通りで、節 6.2 で本モデルに関する予備的情報を提示し、節 6.3 では時空間連続系で提示された本モデルの数学的枠組みを説明し、節 6.4 では構築された数理モデルが時間離散システムでどのように実装されるかを説明し、節 6.5 では本モデルの数値結果と結果に対する考察を行い、節 6.6 で結論を述べる。

6.2 導入

6.2.1 モデルの基本概念

本モデルはミクロ視点に基づいて、つまり車両 1 台ずつに注目してモデルを構築する。そこで、本モデルでは、各ドライバーが自車の速度を前方車両との位置関係に基づいて加減速を行うことで、速度調節を行うものと仮定する。また、この時速度調節に用いる情報は、ドライバーの認識情報を基とする。そして、本モデルで最も重要な点は、多くの既往モデルとは異なり、車間距離や速度の変化に関する認識が常に発生するわけではなく、突発的に発生すると仮定する点である。これは、現実の道路を運転するドライバーは、自動運転制御システムを搭載した車両とは異なり、短い時間間隔で常に速度調節を行っているのではなく、断続的に速度調節を行っていることに基づいた考え方である。つまり、高速道路などでは特に顕著に表れるが、車間距離や速度による周りの運転環境が変わらない限り、ドライバーは現状を維持しようとする傾向があるということである。以上の点を踏まえ、本モデルでは、ドライバーが運転する環境の変化を認識するイベントが、確率過程によってモデル化されると仮定し、このイベントが発生した際に速度調節を行うものと仮定する。

では、どのようにして確率過程を記述するのだが、それは人間の身体への刺激（入力）と反応（出力）の関係を考えることで体系化する。本モデルでいう刺激（入力）は、車間距離や速度といった物理的特性で測定される、ドライバーを取り囲む環境の変化を指す。これに対し、反応（出力）は環境変化に対する認識の程度で、入力に対する応答曲線を用いることで、0 から 1 の範囲で定量化することができる。また、人間の刺激に対する応答曲線は強い非線形性を示すことがよく知られており、心理学の知見によれば、刺激（入力）と反応（出力）の関係は凸性を示しており、ある一定の大きさを超える、または下回る刺激に対しては、そこから刺激が大きく、または小さくなろうと、そこまで反応は変わらないという傾向があるといわれている。物理的刺激に対する人間の反応を支配する、最もよく知られた心理物理関係の一つである Weber-Fechner の法則 [31] も、この原理に従っている。以上の特性を表現するために、本モデルでは Fermi 関数を採用する。この関数は、特に進化ゲーム理論の分野において、戦略の決定を行う人間の意思決定プロセスを表現するのに広く使用されており [2, 3]、人間の物理刺激に対する反応をよく表す関数であるといえる。

以上より、本モデルは Fermi 関数を用いて環境変化の認識の程度を定量化し、その認識の程度に基づく確率過程により、速度調節イベントが発生し、速度調節イベントが発生しない限りは現在の加速度を維持すると仮定し、モデルを構築する。

6.2.2 使用する用語

本モデルでは、車両の先端の位置と、前方車両との車間距離を $x[m]$ と $g[m]$ と表す。また速度と加速度は、それぞれ、 $v[m/s]$ 、 $a[m/s^2]$ と表す。また、速度については、いかなる場合でも $v \geq 0$ が成立し、後退することはないものとする。そして時間を $t[s]$ とし、時間を変数に持つ

変数は小文字で、定数は大文字で表記するものとする．そして前方車両を示す場合は、上付き文字 F がつけられる（例、 v^F ）．また、減速度という用語は、負の加速度の絶対値を表す言葉として用いる．

表 6-1 と表 6-2 に、それぞれ、車両関係の定数とドライバー関係の定数で用いる記号の一覧をまとめている．これらの定数を車両ごとに設定することで、多くの車両やドライバーの特徴を再現することが可能となる．

表 6-1 車両関係の定数

定数	定義
速度関係（単位、[m/s]	
$V_{\max}$	車両の最大速度
加速度関係（単位、[m/s ²]	
$A_{\max}^+$	車両の最大加速度
$A_{\max}^-$	車両の最大減速度
$A_{\text{resistance}}^-$	自由走行時のタイヤ接地抵抗による減速度
長さ（単位、[m]	
ℓ	車両長

表 6-2 ドライバー関係の定数

定数	定義
速度関係（単位、[m/s]	
V_{cruise}	巡航速度（ $V_{\text{cruise}} \leq V_{\max}$ ）
$V_{b \rightarrow a}^+$	ブレーキペダルからアクセルペダルに最も早く踏みかえる時の閾値速度
$V_{b \rightarrow a}^-$	ブレーキペダルからアクセルペダルに最も遅く踏みかえる時の閾値速度
$V_{a \rightarrow b}^+$	アクセルペダルからブレーキペダルに最も早く踏みかえる時の閾値速度
$V_{a \rightarrow b}^-$	アクセルペダルからブレーキペダルに最も遅く踏みかえる時の閾値速度
V_{margin}^+	前方車両を最も短い時間で観察しなければならない時の閾値速度
V_{margin}^-	前方車両を最も長く時間をかけて観察できる時の閾値速度
速度差関係（単位、[m/s]	
$\delta V_{\text{cruise}}^+$	ドライバーが、現在の車両速度が巡航速度 V_{cruise} を上回っていることを確実に認識する時の巡航速度との速度差の大きさ（ $\delta V_{\text{cruise}}^+ > 0$ ）
$\delta V_{\text{cruise}}^-$	ドライバーが、現在の車両速度が巡航速度 V_{cruise} を下回っていることを確実に認識する時の巡航速度との速度差の大きさ（ $\delta V_{\text{cruise}}^- > 0$ ）
δV_{stop}^+	ドライバーが、車両が完全停止していないことを確実に認識する最大速度（ $\delta V_{\text{stop}}^+ > 0$ ）
δV_{stop}^-	ドライバーが、車両が完全停止していないことを確実に認識する最小速度（ $\delta V_{\text{stop}}^- > 0$ ）
加速度関係（単位、[m/s ²]	
$A_{\text{acceptable}}^+$	最大許容加速度（ $A_{\text{acceptable}}^+ < A_{\max}^+$ ）
$A_{\text{acceptable}}^-$	最大許容減速度（ $A_{\text{acceptable}}^- < A_{\max}^-$ ）
A_{strong}^-	強めの減速度（ $A_{\text{strong}}^- < A_{\text{acceptable}}^-$ ）

A_{normal}^-	通常の減速度 ($A_{normal}^- < A_{strong}^-$)
$A_{F_{normal}}^-$	想定される前方車両の減速度
車間距離関係 (単位, [m])	
$G_{closest}$	最小車間距離 ($G_{closest} > 0$)
G_{cruise}	巡航車間距離の最小車間距離 ($G_{cruise} > 0$)
$G_{influenced}$	前方車両の影響を受ける最大車間距離の最小車間距離 ($G_{influenced} > 0$)
時間関係 (単位, [s])	
$T_{b \rightarrow a}^+$	ブレーキペダルからアクセルペダルに最も早く踏みかえる時に要す時間
$T_{b \rightarrow a}^-$	ブレーキペダルからアクセルペダルに最も遅く踏みかえる時に要す時間
$T_{a \rightarrow b}^+$	アクセルペダルからブレーキペダルに最も早く踏みかえる時に要す時間
$T_{a \rightarrow b}^-$	アクセルペダルからブレーキペダルに最も遅く踏みかえる時に要す時間
T_{margin}^+	前方車両を最も短い時間で観察しなければならない時に要す時間
T_{margin}^-	前方車両を最も長く時間をかけて観察できる時に要す時間
認識関数関係 (単位, [—])	
F_g	運転者が最適な間隔からのずれを認識する際の認識機能の臨界値 ($1 > F_g \geq f_g(0)$)

6.2.3 本モデルの概要

ドライバーはどのようにして運転環境の変化を認識するのだろうか．本モデルでは，ドライバーが最初に変化を認識するのは，前方車両との車間距離だと仮定している．これは速度とは違い，通常は前方車両を見ながら運転しているため，視覚的に変化を捉えやすいということに起因している．ここで前方車両との車間距離の時間 1 回微分

$$\frac{dg}{dt} = \frac{d}{dt}(x^F - x - \ell^F) = v^F - v$$

を考える．この式から，ドライバーは，車間距離が広がった，すなわち，前方車両の方が速く走行している場合に加速する可能性があるといえる．では，ドライバーはどの程度加速するのだろうか．前方車両との車間距離が大きければより大きな加速度をもって加速できるが，近ければ小さな加速度を用いるだろう．この加減速は，ある速度を目指して行われるもので，このある速度とは，前方車両との速度差や車間距離を加味した目標とする速度で，この目標速度よりも現在の速度との差が大きければ，より大きな加速度，もしくは減速度を用いて車両をコントロールし，差が小さければ小さな加減速を用いて車両をコントロールするだろう．ここでいう目標速度は，OV モデルの最適速度 OV [23] と基本的には同じ考え方だが，算出方法は全く違う．また，本モデルは，ドライバーが車間距離の変化を確率的に認識すると仮定しているが，これは OV モデルと決定的に違う点であり，ドライバーはこの変化を認識した時のみ，速度の調節を行う（場合によっては現在の加速度を維持する）．また，確率的に認識する差は車間距離のみではない．先ほどの目標速度と現在の速度差も確率的に認識し，この差を認識した時もまた，速度調節を行う．

以上の流れを要約すると，

- (i) ドライバーは前方車両との車間距離の変化(車間距離差と呼ばれ節 6.3.2 で説明)を確率的に認識する。この認識が発生すると、ドライバーは目標速度を設定し、加減速を行うことで車両速度を調節する。
- (ii) (i)の確率過程とは別に、独立した過程として、ドライバーは目標速度と現在の速度の速度差を確率的に認識する(節 6.3.1 で説明)。この認識が発生すると、ドライバーは現在の速度を調節する。
- (iii) ドライバーが実際に速度調節を行うまでには、ペダルの踏みかえ時間が発生する場合があるため、ペダルの踏みかえ時間も考慮する。

以上の流れが図 6-1 に示されている。




図 6-1 節 6.2.3 の(i)～(iii)までの流れを視覚的に表した図。 (i)に対応する要素は赤色で、 (ii)は黄色、 (iii)は青色で強調されており、それぞれ本文の説明に対応している。

6.3 連続系のモデル設計

本節では、数式によってモデルを体系化する．節 6.2.3 では、前方車両がいる場合を想定して説明を行ってきたが、先に前方車両がいない場合を想定し、その後前方車両がいる場合に拡張する．

前方車両がいない場合では、ドライバーは常に巡航速度 V_{cruise} を目標速度とし、目標速度と現在の速度との差を認識した際に速度調節を行う．つまり、節 6.2.3 の(ii)と(iii)のみで速度調整は行われる．一方、前方車両がいる場合は、この目標速度は車間距離差を認識することで更新され、速度調整が行われる．そのため、先に速度差の認識を説明する．

6.3.1 速度差の認識

6.3.1.1 速度差の認識関数, f_v

既述の通り、本モデルでは Fermi 関数を用いて、ドライバーの目標速度と現在の速度との速度差（刺激）と、その認識度（反応）との関係を定義する．認識度を 0 から 1 の範囲で定量化したいので、速度差の認識関数 $f_v(\Delta v(t))$ を

$$\left\{ \begin{array}{l} f_v(\Delta v(t)) = \frac{1}{1 + \exp[-N_v(\Delta v(t))/\kappa]} \\ N_v(\Delta v(t)) = \text{sgn}_v(\Delta v(t)) \frac{2}{\delta v(v_{target}(t))} \Delta v(t) - 1 \\ \delta v(v_{target}(t)) = \begin{cases} \frac{\delta V_{cruise}^- - \delta V_{stop}^-}{V_{cruise}} v_{target}(t) + \delta V_{stop}^-, & \Delta v(t) \leq 0 \\ \frac{\delta V_{cruise}^+ - \delta V_{stop}^+}{V_{cruise}} v_{target}(t) + \delta V_{stop}^+, & \Delta v(t) > 0 \end{cases} \\ \text{sgn}_v(\Delta v(t)) = \begin{cases} -1, & \Delta v(t) \leq 0 \\ 1, & \Delta v(t) > 0 \end{cases} \\ \Delta v(t) = v(t) - v_{target}(t) \end{array} \right. \quad (6.1)$$

と定義する．この速度差の認識関数 $f_v(\Delta v(t))$ の一例を図 6-2 に示しており、この図からわかるように、目標速度 v_{target} の前後で単調減少から単調増加に移行する、下に凸の曲線を描く．ここで、式中の N_v は速度差を $[-1, 1]$ に正規化し、 δv は速度差に対する感度範囲を 1 次関数で定義している．また、定数 V_{cruise} , δV_{cruise}^+ , δV_{cruise}^- , δV_{stop}^+ , δV_{stop}^- は表 6-2 に記載されている、ドライバーの固有値である．また、既往研究 [32] にない、 $\kappa = 0.1$ を仮定しており、この速度差の認識関数 f_v は、 $\Delta v(t)$ が $\delta v(v_{target}(t))$ に近づくと 1 に漸近する．




図 6-2 式(6.1)の速度差の認識関 $f_v(\Delta v(t))$ の一例. 図中の青, 赤, 黒の線は, それぞれ, 目標速度数 $v_{target} = 40[\text{km/h}]$, $80[\text{km/h}]$, $100[\text{km/h}]$ の時を示しており, ほかのパラメータは次のように設定されている. $\kappa = 0.1$, $V_{cruise} = 100[\text{km/h}]$, $(\delta V_{cruise}^+, \delta V_{cruise}^-) = (10[\text{km/h}], 15[\text{km/h}])$ および $(\delta V_{stop}^+, \delta V_{stop}^-) = (3[\text{km/h}], 0.1[\text{km/h}])$ である.

6.3.1.2 速度差の認識確率, P_v

次に, 節 6.3.1.1 で定義した速度差の認識率 f_v を用いて, 速度差の認識確率 P_v を定義する. ここで, イベントが発生する頻度を $1 - f_v$ の関数で表すとする, この関数は速度差が増加すると頻度が低下し, 速度差が減少すると頻度が増加するため, 現実のドライバーは速度差が小さくなるにつれて繊細な調節を行うという見識と一致する. したがって, この $1 - f_v$ は物理的な観点から確率密度関数の相似関係を持つ関数と解釈できる. よって, ドライバーが前回速度差を認識した時刻を t_0 とし, 時刻 t_0 から時刻 t までに速度差を認識する確率 $P_v(\Delta v(t))$ を

$$\left\{ \begin{aligned} P_v(\Delta v(t)) &= \begin{cases} \int_{\Delta v(t_0)}^{\Delta v(t)} q_v(\Delta v) d\Delta v, & \Delta v(t_0) < \Delta v(t) \\ \int_{\Delta v(t)}^{\Delta v(t_0)} q_v(\Delta v) d\Delta v, & \Delta v(t_0) \geq \Delta v(t) \end{cases} \\ q_v(\Delta v(t)) &= \begin{cases} \frac{1 - f_v(\Delta v(t))}{S_v(\Delta v(t))}, & \Delta v(t) \geq -v_{target}(t) \\ 0, & \Delta v(t) < -v_{target}(t) \end{cases} \\ S_v(\Delta v(t)) &= \int_{-\infty}^{\infty} (1 - f_v(\Delta v(t))) d\Delta v \end{aligned} \right. \quad (6.2)$$

と定義する．ここで，確率密度関数 $q_v(\Delta v)$ が $\Delta v(t) < -v_{target}(t)$ の範囲において0になっているのは，本モデルが後退を許容しないモデルであるからである．

6.3.1.3 速度差の認識状態, I_v

ドライバーが目標速度と現在の速度の速度差を認識している状態を $I_{Recognized}$ ，認識していない状態を I_{Not} とし，この状態を表す関数を I_v とすると，

$$I_v(t) = \begin{cases} I_{Recognized}, & \text{with the probability } P_v(\Delta v(t)) \\ I_{Not}, & \text{with the probability } 1 - P_v(\Delta v(t)) \end{cases} \quad (6.3)$$

となる．

6.3.2 車間距離差の認識

6.3.2.1 ペダルの踏みかえにかかる時間と速度の関係

本モデルは既述の通りペダルの踏みかえ時間を考慮する．

まず，ドライバーがアクセルペダルからブレーキペダルに足を踏みかえる場合を考える．ドライバーは，速度が大きいほど，潜在的なリスクを回避するために，ブレーキペダルへ素早く踏みかえる傾向がある．したがって，速度に対し，踏みかえに要する時間は，単調減少の関係を仮定することができる．この関係を表すために線形関数を仮定するが，ドライバーの物理的応答速度を考慮すると，この線形関係には最小と最大の反応時間が存在する可能性があると考えられる．

次に，ドライバーがブレーキペダルからアクセルペダルに足を踏みかえる場合を考える．ここでも先ほどと同様の仮定を適用できる．つまり，渋滞中など何度もペダルの踏みかえをしなければならない場合などは，ドライバーは意図的に踏みかえ時間を長くして，高頻度の踏みかえを避ける傾向にあるということだ．このことによって，ドライバーは渋滞時のスムーズな運転を再現しようとする．

以上の考察より，ペダルの踏みかえに要する時間 τ_n を，速度の関数として

$$\tau_n(v) = \begin{cases} T_n^-, & v < V_n^- \\ \frac{\delta T_n}{\delta V_n}(v - V_n^-) + T_n^-, & V_n^- \leq v \leq V_n^+ \\ T_n^+, & v > V_n^+ \end{cases} \quad (6.4)$$

$$\begin{cases} \delta T_n = T_n^+ - T_n^- \\ \delta V_n = V_n^+ - V_n^- \end{cases}$$

と定義する．ここで，下付き文字の n は，アクセルペダルからブレーキペダルへの踏みかえ($a \rightarrow b$)，またはブレーキペダルからアクセルペダルへの踏みかえ($b \rightarrow a$)を表す．また，例えば $n \equiv a \rightarrow b$ の場合における $T_{a \rightarrow b}^+$ ， $T_{a \rightarrow b}^-$ ， $V_{a \rightarrow b}^+$ ， $V_{a \rightarrow b}^-$ は表 6-2 に示す通り，ドライバー固有の定数である．

6.3.2.2 3つの前方車両との車間距離

ドライバーが前方車両との車間距離の変化を認識するためには、次の3つの車間距離を定義する必要がある。

1. 前方車両との衝突を回避することができる最小の車間距離である、最小安全車間距離 $g_{closest}$ 。
2. ドライバーが維持して走行しようとする車間距離である、巡航車間距離 g_{cruise} 。
3. 前方車両の影響を受ける最も大きい車間距離である、前方車両の影響を受ける最大車間距離 $g_{influenced}$ 。

これらの3つの車間距離には $g_{closest} < g_{cruise} < g_{influenced}$ の関係が成立する必要があることに注意が必要である。

6.3.2.2.1 最小安全車間距離, $g_{closest}$

最小安全車間距離とは、前方車両が急にブレーキを踏み、完全停止するような場面において、自車両が衝突を回避して安全に完全停止できる車間距離を意味する。図6-3に最小安全車間距離の概念図を示している。この図に示されている、 d_{free} は減速することを決定してから、実際にブレーキペダルを踏み込むまでの間に進む自由走行距離で、 d_{brake} はブレーキペダルを踏み込んでから完全停止するまでに進む制動距離である。この2つの距離の和が停止距離 d_{stop} となる。また、前方車両がブレーキペダルを踏み込んでから停止するまでの距離を d_{brake}^F とし、両車両が完全停止した時の最小車間距離を表6-2に示す通り $G_{closest}$ とすると、最小安全車間距離 $g_{closest}$ は $g_{closest} + d_{brake}^F = d_{free} + d_{brake} + G_{closest}$ の関係を満たすので、 $g_{closest}$ について整理すると、 $g_{closest} = d_{stop} - d_{brake}^F + G_{closest}$ となる。




図 6-3 最小安全車間距離 $g_{closest}$ を構成する d_{free} , d_{brake} , d_{stop} , d_{brake}^F , $G_{closest}$ についての概念図。

以上より，前節 6.3.2.1 の式(6.4)で定義したペダルの踏みかえ時間 $\tau_n(v)$ を用いて，最小安全車間距離 $g_{closest}(t)$ を

$$\left\{ \begin{array}{l} g_{closest}(t) = \max[G_{closest}, d_{stop}(t) - d_{brake}^F(t) + G_{closest}] \\ \left\{ \begin{array}{l} d_{stop}(t) = d_{free}(t) + d_{brake}(t) \\ \left\{ \begin{array}{l} d_{free}(t) = v(t)\tau_{n \equiv a \rightarrow b}(v(t)) \\ d_{brake}(t) = \frac{v(t)^2}{2A_{strong}^-} \end{array} \right. \\ d_{brake}^F(t) = \frac{(v^F(t))^2}{2A_{acceptable}^-} \end{array} \right. \end{array} \right. \quad (6.5)$$

と定義する．ここで， A_{strong}^- と $A_{acceptable}^-$ は表 6-2 に定義されるドライバー固有の定数である．

また，式(6.5)中の $\max$ 関数は，最小安全車間距離が常に $G_{closest}$ 以上であることを保証するものである．

$d_{brake}^F(t)$ の定義に前方車両の減速度ではなく最大許容減速度 $A_{acceptable}^-$ が使用されていることに注意が必要である．これは，自動運転制御システムを用いた車両とは違い，ドライバーは前方車両の減速度を正確に知る術がないため，自身の最大許容減速度で代用し，予想していることを表している．

また，自身の制動距離 $d_{brake}(t)$ に用いる減速度が，表 6-1 の車両の持つ最大減速度 A_{max}^- ではないことにも注意が必要である．なぜなら，この車間距離は安全に停止できる距離なので，余裕のない，ただただ衝突を回避するブレーキである，いわゆるパニックブレーキではないからである．そのため， A_{strong}^- は自身が余裕を持って減速できる最大減速度となる．

6.3.2.2.2 巡航車間距離， g_{cruise}

巡航車間距離とは，ドライバーが維持しようとする理想的な車間距離を表わす．この車間距離の概念は，最小安全車間距離 $g_{closest}$ の概念と似ており，定量化にあたり最小安全車間距離 $g_{closest}$ の時に用いた， d_{brake} と d_{stop} と区別するために，プライム記号を用いる．本モデルでは，巡航車間距離 g_{cruise} を

$$\left\{ \begin{array}{l} g_{cruise}(t) = \max[g_{closest}(t) + G_{cruise}, g_{cruise}'(t)] \\ \left\{ \begin{array}{l} g_{cruise}'(t) = d_{stop}'(t) - d_{brake}^F'(t) \\ \left\{ \begin{array}{l} d_{stop}'(t) = d_{free}(t) + d_{brake}'(t) \\ d_{brake}'(t) = \frac{v(t)^2}{2A_{normal}^-} \end{array} \right. \\ d_{brake}^F'(t) = \frac{(v^F(t))^2}{2A_{Fnormal}^-} \end{array} \right. \end{array} \right. \quad (6.6)$$

と定義する．式中の A_{normal}^- ， $A_{Fnormal}^-$ および G_{cruise} は表 6-2 に定義されるドライバー固有の定数である．また，式中の $\max$ 関数は巡航車間距離 g_{cruise} が最短安全車間距離 $g_{closest}$ よりも常に G_{cruise} 以上大きいことを保証するためのものである．

6.3.2.2.3 前方車両の影響を受ける最大車間距離, $g_{influenced}$

前方車両の影響を受ける最大車間距離とは、その名の通り、前方車両の影響を受ける最大の車間距離で、この車間距離を超えると、ドライバーは前方車両をいないものとして扱う。前方車両の影響を受けるのは、前方車両の加速や減速が自身に影響を与えるということなので、巡航車間距離 g_{cruise} に影響を与えるかどうかを判断する猶予時間に、速度を乗算した車間距離を足した車間距離と定義する。また、この猶予時間は速度によって変化し、上限と下限の時間があると考えられるため、表 6-2 の T_{margin}^+ , T_{margin}^- , V_{margin}^+ , V_{margin}^- を用いて、前方車両の影響を受ける最大車間距離 $g_{influenced}$ を

$$\begin{cases} g_{influenced}(t) = \max[g_{cruise}(t) + G_{influenced}, g_{influenced}'(t)] \\ \begin{cases} g_{influenced}'(t) = g_{cruise}(t) + v(t)\tau_{margin}(v(t)) \\ \tau_{margin}(v(t)) = \begin{cases} T_{margin}^-, & v(t) < V_{margin}^- \\ \frac{\delta T_{margin}}{\delta V_{margin}}(v(t) - V_{margin}^-) + T_{margin}^-, & V_{margin}^- \leq v(t) \leq V_{margin}^+ \\ T_{margin}^+, & v(t) > V_{margin}^+ \end{cases} \\ \delta T_{margin} = T_{margin}^+ - T_{margin}^- \\ \delta V_{margin} = V_{margin}^+ - V_{margin}^- \end{cases} \end{cases} \quad (6.7)$$

と定義する。式中の $\max$ 関数は、前方車両の影響を受ける最大車間距離 $g_{influenced}$ が常に巡航車間距離 g_{cruise} よりも、表 6-2 の $G_{influenced}$ 以上大きいことを保証するためのものである。

6.3.2.3 車間距離差の認識関数, f_g

節 6.3.1.1 の速度差の認識率 f_v では、目標速度と現在の速度の速度差を認識する程度を表す関数として定義した。そこで、車間距離差には現在の車間距離と巡航車間距離の差を用い（以降、車間距離差はすべて現在の車間距離と巡航車間距離の差を意味するものとする）て、最小安全車間距離から、前方車両の影響を受ける最大車間距離までの間の車間距離に感度を持つ、Fermi 関数を用いた認識関数が車間距離差の認識関数 f_g となる。また、車間距離と巡航車間距離の差を $\Delta g(t) = g(t) - g_{cruise}(t)$ と定義し、感度の範囲は下限を $\delta g^-(t) = g_{cruise}(t) - g_{closest}(t)$, 上限を $\delta g^+(t) = g_{influenced}(t) - g_{cruise}(t)$ とすると、 $-\delta g^-(t) \leq \Delta g(t) \leq \delta g^+(t)$ となる。したがって、車間距離差の認識関数 $f_g(\Delta g(t))$ を

$$\begin{cases} f_g(\Delta g(t)) = \frac{1}{1 + \exp[-N_g(\Delta g(t))/\kappa]} \\ \begin{cases} N_g(\Delta g(t)) = \text{sgn}_g(\Delta g(t)) \frac{2}{\delta g(t)} \Delta g(t) - 1 \\ \delta g(t) = \begin{cases} \delta g^-(t) = g_{cruise}(t) - g_{closest}(t), & \Delta g(t) \leq 0 \\ \delta g^+(t) = g_{influenced}(t) - g_{cruise}(t), & \Delta g(t) > 0 \end{cases} \\ \text{sgn}_g(\Delta g(t)) = \begin{cases} -1, & \Delta g(t) \leq 0 \\ 1, & \Delta g(t) > 0 \end{cases} \\ \Delta g(t) = g(t) - g_{cruise}(t) \end{cases} \end{cases} \quad (6.8)$$

と定義する.

6.3.2.4 車間距離差の認識確率, P_g

続いて, 車間距離差を認識する確率 P_g を定義する. 基本的な概念は節 6.3.1.2 の速度差の認識確率 P_v と同様である. しかし, 速度差の認識確率との決定的な違いは, 速度に関してはスピードメーターを見れば正確かつ瞬時に速度差を認識できるが, 車間距離の認識に関しては, 完全にドライバーの感覚任せである. そのため「このくらいの車間距離ならちょっと近い気がするが, 大丈夫だろう」と思いこんで, 意図的に車間距離の変化の認識を排除する可能性があり, この「大丈夫だろう」の範囲は車両の速度に依存する可能性がある. この範囲を表現するのに用いるのが表 6-2 のドライバー固有の閾値 F_g である. この閾値 F_g は $F_g \geq f_g(\Delta g)|_{\Delta g=0}$ を満たす値である. したがって, 前回, 車間距離差を認識した時の時刻 t_0 から現時刻 t における車間距離差の認識確率 $P_g(\Delta g(t))$ は, 確率密度関数 $q_g(\Delta g(t))$ を $\Delta g(t_0)$ から $\Delta g(t)$ まで積分すると得られるので,

$$\begin{cases} P_g(\Delta g(t)) = \begin{cases} \int_{\Delta g(t_0)}^{\Delta g(t)} q_g(\Delta g(t)) d\Delta g, & \Delta g(t_0) < \Delta g(t) \\ \int_{\Delta g(t)}^{\Delta g(t_0)} q_g(\Delta g(t)) d\Delta g, & \Delta g(t_0) \geq \Delta g(t) \end{cases} \\ \begin{cases} q_g(\Delta g(t)) = \begin{cases} \frac{1 - q'_g(\Delta g(t))}{S_g(\Delta g(t))}, & g(t) \geq g_{closest}(t) \\ 0, & g(t) < g_{closest}(t) \end{cases} \\ S_g(\Delta g(t)) = \int_{-\infty}^{\infty} (1 - q'_g(\Delta g(t))) d\Delta g \\ q'_g(\Delta g(t)) = \begin{cases} 0, & f_g(\Delta g(t)) < F_g \\ f_g(\Delta g(t)) \geq F_g, & f_g(\Delta g(t)) \geq F_g \end{cases} \end{cases} \end{cases} \quad (6.9)$$

となる. また, $g(t) < g_{closest}(t)$ の範囲で $q_g(\Delta g(t))$ が 0 になっているのは, 車間距離が時間とともに小さくなる場合, $g(t) = g_{closest}(t)$ になった時点で, 絶対に車間距離の変化を認識し, ブレーキをかけさせるためである. したがって, どのような状況においても, ドライバーは, 最小安全車間距離 g_{cruise} よりも小さな車間距離を維持することはできない.

6.3.2.5 車間距離差の認識状態, I_g

節 6.3.1.3 の速度差の認識状態を表す関数 I_v と同様に, 車間距離差の変化を認識した状態を $I_{Recognized}$, 認識していない状態を I_{Not} として, 車間距離差の認識状態を表す関数 I_g は

$$I_g(t) = \begin{cases} I_{Recognized}, & \text{with the probability } P_g(\Delta g(t)) \\ I_{Not}, & \text{with the probability } 1 - P_g(\Delta g(t)) \end{cases} \quad (6.10)$$

である.

6.3.3 目標速度

この節では、ドライバーが目標速度を再定義するプロセスを説明する。これまでの議論で、時刻 t における現在の車間距離 $g(t)$ が、前方車両の影響を受ける最大車間距離 $g_{influenced}(t)$ 以上の場合 ($g(t) \geq g_{influenced}(t)$) では、前方車両はいないものとしてドライバーは状況を捉えることができるので、目標速度は巡航速度 V_{cruise} になる。では、現在の車間距離が巡航車間距離の場合 ($g(t) = g_{cruise}(t)$) はどうだろうか。この場合は、前方車両と全く同じ速度で走行することができれば、巡航車間距離を維持して走行することができるため、目標速度は $v^F(t)$ となる。同様に、現在の車間距離が最小安全車間距離の場合 ($g(t) = g_{closest}(t)$) はどうだろうか。この場合は、直ちにブレーキをかけなければならない、目標速度は0となる。当然、 $g(t) < g_{closest}(t)$ も目標速度は0なので、 $g(t) \leq g_{closest}(t)$ の場合では目標速度は常に0である。

では、現在の車間距離 $g(t)$ が $g_{closest}(t) \leq g(t) \leq g_{influenced}(t)$ を満たす場合、目標速度はどのように変化するのだろうか。それぞれ、目標速度の上限と下限は V_{cruise} と0なので、その間を線形補間すればよいのだろうか。答えは否で、目標速度は車間距離に依存しているはずだ。また、その車間距離もドライバーの目視に依存しているため、本モデルでは車間距離差の認識率 f_g に比例すると仮定する。

したがって、車間距離差を認識した時刻 t において更新する目標速度 $v_{target}^{Recognized}(t)$ を

$$\begin{cases} v_{target}^{Recognized}(t) = \min[V_{cruise}, v_{target}^{Recognized'}(t)] \\ v_{target}^{Recognized'}(t) = \begin{cases} 0, & g(t) < g_{closest}(t) \\ v^F(t)(1 - f_g(\Delta g(t))), & g(t) \geq g_{closest}(t) \wedge \Delta g(t) \leq 0 \\ (V_{cruise} - v^F(t))f_g(\Delta g(t)) + v^F(t), & \Delta g(t) > 0 \end{cases} \end{cases} \quad (6.11)$$

と定義する。式中の $\min$ 関数は、目標速度 $v_{target}^{Recognized}(t)$ が巡航速度 V_{cruise} 以下になることを保証するためのものである。

一方で、車間距離差の変化を認識しなかった場合は目標速度の更新は起きない。

これらの議論から、目標速度 $v_{target}(t)$ が更新される動的方程式は

$$\begin{cases} v_{target}(t) = v_{target}^{Recognized}(t), & I_g(t) = I_{Recognized} \\ \frac{d}{dt} v_{target}(t) = 0, & I_g(t) = I_{Not} \end{cases} \quad (6.12)$$

となる。

6.3.4 目標加速度

次に、目標速度に対し、どのような加速度をもって速度を調節するか、目標加速度を定義する。物理学に基づいて考えると、加速度は基本的に、速度の差を経過時間で除したものであり、速度差 $\Delta v = v(t) - v_{target}(t)$ の符号に依存し、加速か減速かが決定される。 $\Delta v < 0$ であれば加速し、 $\Delta v > 0$ であれば減速することで目標速度に近づけることができる。加速か減速かは Δv の符号で判断できることがわかったが、実際には、どのような加速度の大きさを用いて

調節しているのだろうか．当然，最大加速度で加速し，最大減速度をもってして減速するわけではなく，滑らかに車両が進むよう，細かく加減速を行っている．この加減速度の大きさは，前方車両との車間距離が大きければ素早く加速，またはゆっくり減速し，逆に車間距離が小さければゆっくり加速，または素早く減速する．車間距離が大きい，または小さい時に，大きな加速度，もしくは大きな減速度で速度を調節する場合は，基本的に目標速度と現在の速度との速度差は大きい．では，車間距離が巡航車間距離に近く，目標速度とも速度差があまりない時はどうだろうか．この場合は，小さな加減速度をもってして，速度を調節するはずである．したがって，ドライバーは，目標速度との速度差が大きければ大きな加速度または減速度を用い，差が小さければ小さな加速度または減速度をもって速度を調節しようとする，と仮定することができる．以上より，目標加速度は，速度差および車間距離差の認識率 f_v と f_g の両方から影響を受けると考えられることから，速度差もしくは車間距離差を認識した時刻 t における目標加速度 $a_{target}^{Recognized}(t)$ を，速度差および車間距離差の認識率 f_v と f_g を用いて，

$$\begin{cases} a_{target}^{Recognized}(t) = \begin{cases} -A_{acceptable}^-, & g(t) < g_{closest}(t) \\ \begin{cases} \min[A_{acceptable}^+, a'_{max}(t)] f_v(\Delta v(t)) \\ a'_{max}(t) = \max[-A_{acceptable}^-, a_{max}(t)] \end{cases}, & g(t) \geq g_{closest}(t) \end{cases} \\ a_{max}(t) = \begin{cases} a^F(t) (1 - f_g(\Delta g(t))), & \Delta v(t) < 0 \wedge \Delta g(t) \leq 0 \\ |A_{acceptable}^+ - a^F(t)| f_g(\Delta g(t)) + a^F(t), & \Delta v(t) < 0 \wedge \Delta g(t) > 0 \\ -(A_{strong}^- - A_{normal}^-) f_g(\Delta g(t)) - A_{normal}^-, & \Delta v(t) \geq 0 \wedge \Delta g(t) \leq 0 \\ (A_{normal}^- - A_{resistance}^-) f_g(\Delta g(t)) - A_{normal}^-, & \Delta v(t) \geq 0 \wedge \Delta g(t) > 0 \end{cases} \end{cases} \quad (6.13)$$

と定義する．式中の $A_{acceptable}^+$ ， $A_{acceptable}^-$ ， A_{strong}^- ， A_{normal}^- は表 6-2 に示す通り，ドライバー固有の定数である．また， $A_{resistance}^-$ は表 6-1 に示す通り車両固有の定数で，アクセルペダルもブレーキペダルも踏み込んでいない自由走行時に，地面との接地抵抗によって自然に減速する時の減速度である．また， $\min$ 関数および $\max$ 関数は，目標加速度 $a_{target}^{Recognized}(t)$ が $-A_{acceptable}^-$ から $A_{acceptable}^+$ までの範囲内に収まることを保証するものである．

そして，先ほどの目標速度同様に，ドライバーが速度差や車間距離差を認識しなければ，現在の加速度を維持するため，目標加速度 $a_{target}(t)$ が更新される動的方程式は

$$\begin{cases} a_{target}(t) = a_{target}^{Recognized}(t), & I_v(t) = I_{Recognized} \vee I_g(t) = I_{Recognized} \\ \frac{d}{dt} a_{target}(t) = 0, & I_v(t) = I_{Not} \wedge I_g(t) = I_{Not} \end{cases} \quad (6.14)$$

となる．

6.3.5 ペダルの踏みかえに必要な時間

まずは，足の位置の状態を表す関数 $S_{FP}(t)$ を定義する．この状態には，アクセルペダル上にある状態 S_{Accel} ，ブレーキペダル上にある状態 S_{Brake} ，どこにもない状態の自由状態 S_{Free} の 3 つの状態がある．そして，時刻 t における目標加速度を達成するために必要な足の位置を表す

目標状態関数 $S_{FP}^{target}(t)$ を

$$S_{FP}^{target}(t) = \begin{cases} S_{FP}(t), & I_v(t) = I_{Not} \wedge I_g(t) = I_{Not} \\ S_{Accel}, & a_{target}(t) > -A_{resistance}^- \wedge (I_v(t) = I_{Recognized} \vee I_g(t) = I_{Recognized}) \\ S_{Free}, & a_{target}(t) = -A_{resistance}^- \wedge (I_v(t) = I_{Recognized} \vee I_g(t) = I_{Recognized}) \\ S_{Brake}, & a_{target}(t) < -A_{resistance}^- \wedge (I_v(t) = I_{Recognized} \vee I_g(t) = I_{Recognized}) \end{cases} \quad (6.15)$$

と定義する.

次に, ドライバーが速度差もしくは車間距離差を認識した時, すなわち $I_v(t) = I_{Recognized} \vee I_g(t) = I_{Recognized}$ の場合に, ペダルを踏みかえるために必要な時間を表す $\tau_{change}^{Recognized}(t)$ を定義する. これを, 式(6.4)と式(6.15)を用いて

$$\tau_{change}^{Recognized}(t) = \begin{cases} 0, & S_{FP}^{target}(t) = S_{FP}(t) \vee S_{FP}^{target}(t) = S_{Free} \\ \tau_{n \equiv a \rightarrow b}(v(t)), & S_{FP}^{target}(t) = S_{Brake} \wedge S_{FP}(t) = S_{Accel} \\ \tau_{n \equiv b \rightarrow a}(v(t)), & S_{FP}^{target}(t) = S_{Accel} \wedge S_{FP}(t) = S_{Brake} \\ \min[\tau_{n \equiv a \rightarrow b}(v(t)), t - t_{SC}], & S_{FP}^{target}(t_{last}) = S_{Accel} \wedge (*) \\ \frac{\tau_{n \equiv a \rightarrow b}(v(t))}{2}, & S_{FP}^{target}(t_{last}) = S_{Free} \wedge (*) \\ \min[\tau_{n \equiv b \rightarrow a}(v(t)), t - t_{SC}], & S_{FP}^{target}(t_{last}) = S_{Brake} \wedge (**) \\ \frac{\tau_{n \equiv b \rightarrow a}(v(t))}{2}, & S_{FP}^{target}(t_{last}) = S_{Free} \wedge (**) \end{cases} \quad (6.16)$$

$$(*) \equiv S_{FP}^{target}(t) = S_{Brake} \wedge S_{FP}(t) = S_{Free}$$

$$(**) \equiv S_{FP}^{target}(t) = S_{Accel} \wedge S_{FP}(t) = S_{Free}$$

と定義する. 式中の時刻 t_{last} と t_{SC} はそれぞれ, 最後に加速度を変更しようと試みた時刻と, 最後にペダルを踏みかえるために足を離した時刻を表している. この時刻 t_{last} は $I_v(t)|_{t=t_{last}} = I_{Recognized} \vee I_g(t)|_{t=t_{last}} = I_{Recognized}$ を満たし, かつ $t_{last} < t$ を満たす時刻である. また, 時刻 t_{SC} はペダルを踏みかえ始めた時刻なので, $t - t_{SC}$ はペダルを踏みかえようとして経過した時間を表しており, こちらは t_{last} と違い, 目的のペダルに足を置くまではリセットされないため, $t_{SC} \leq t_{last}$ の関係となっている. 式(6.16)の7つの条件分岐は, 上から順に, 次のような場合を想定している. 1つ目はペダルの踏みかえが必要ない, もしくは足を離せばよいだけの時を示している. 2つ目はアクセルペダルからブレーキペダルへ, 3つめは逆の場合を想定している. 残りの4つは, それぞれ, 前回の踏みかえがまだ終わっておらず, $\min$ 関数がある方は, 踏みかえの途中で足を元に戻す場合を想定しており, $\min$ 関数がない方は, 最初から両方のペダルから足を離しており, 惰性で走行している最中に加速または減速の必要が出た場合に素早く反応できることを想定している.

このペダルの踏みかえに必要な時間もまた, どちらかの差を認識しない限り変化しないため, ペダルの踏みかえに必要な時間 $\tau_{change}(t)$ が更新される動的方程式は

$$\tau_{change}(t) = \begin{cases} \tau_{change}(t_{last}), & I_v(t) = I_{Not} \wedge I_g(t) = I_{Not} \\ \tau_{change}^{Recognized}(t), & I_v(t) = I_{Recognized} \vee I_g(t) = I_{Recognized} \end{cases} \quad (6.17)$$

となる.

6.3.6 基礎方程式

次に、各車両の前進運動を説明するモデルの支配方程式を定義し、

$$\begin{cases} \frac{d^2}{dt^2} x(t) = a(t) = \begin{cases} a_{target}(t), & (\tau_{change}(t) = 0 \vee t - t_{sc} \geq \tau_{change}(t)) \wedge (*) \\ -A_{resistance}^-, & \tau_{change}(t) > 0 \wedge t - t_{sc} < \tau_{change}(t) \wedge (*) \\ 0, & v(t) = 0 \wedge S_{FP}^{target}(t) \neq S_{Accel} \end{cases} \\ (*) \equiv v(t) > 0 \vee S_{FP}^{target}(t) = S_{Accel} \end{cases} \quad (6.18)$$

とする．上 2 つの条件分岐は、現在の速度が 0 よりも大きい場合や、ドライバーが加速しようとしている場合を扱っており、中段の分岐は、その中でも、ペダルの踏みかえ中を表現している．一番下の分岐は、速度が 0 でアクセルペダルを踏んでいない時で、加速度が 0 になる．このことにより、車両は後退しない．

この式(6.18)の基礎方程式に従い、各車両の位置は時間とともに独立して前進運動を行う．

6.4 モデルの時間離散化

6.4.1 時間離散化

節 6.3 で数式を用いてモデルを体系化した，ここでは体系化したモデルを時間について離散化することで，MAS による実装を可能とする．時間離散ステップサイズを $\Delta t[s]$ とし，この時間をシミュレーションにおける 1 タイムステップサイズとする．各車両はこの 1 タイムステップ内では線形一様運動を行うと仮定するため， Δt 後の速度と位置は

$$\Delta t_v(a, v) = \max[v + a\Delta t, 0], \quad (6.19)$$

$$\Delta t_x(a, v, x) = \begin{cases} x, & \Delta t_v(a, v) = 0 \wedge a = 0 \\ x - \frac{v^2}{2a}, & \Delta t_v(a, v) = 0 \wedge a \neq 0 \\ x + v\Delta t + \frac{1}{2}a(\Delta t)^2, & \Delta t_v(a, v) > 0 \end{cases} \quad (6.20)$$

となる．

以降，時間離散システムの一般表記に従い，現時刻 t と，次のタイムステップ時刻 $t + \Delta t$ のそれぞれのタイムステップを， t と $t + 1$ と表記することとする．したがって，例えば速度では， $v(t)$ と $v(t + \Delta t)$ は，それぞれ， v_t と v_{t+1} と表されることになる．

6.4.2 速度差の時間離散化による確立的認識

速度差を確率的に認識するための離散的な取り扱いは，累積分布関数を定義することで，タイムステップ t における速度差を認識する確率 $Z_v(\Delta v_t)$ を定義することが可能となる．MAS の実装では，特定のタイムステップ t で認識が発生するかどうかは，一様乱数と速度差の認識確率 $Z_v(\Delta v_t)$ を比較することで可能となる．ただし，積分の向きに注意が必要で， $\Delta v_t - \Delta v_{t-1}$ に依存する．以上より，タイムステップ t における速度差の認識確率 $Z_v(\Delta v_t)$ は

$$\begin{cases} Z_v(\Delta v_t) = \begin{cases} Z_v^+(\Delta v_t), & \Delta v_t > \Delta v_{t-1} \\ Z_v^-(\Delta v_t), & \Delta v_t \leq \Delta v_{t-1} \end{cases} \\ \begin{cases} Z_v^+(\Delta v_t) = \int_{-\infty}^{\Delta v_t} q_v(\Delta v) d\Delta v \\ Z_v^-(\Delta v_t) = \int_{\Delta v_t}^{\infty} q_v(\Delta v) d\Delta v \end{cases} \end{cases} \quad (6.21)$$

となる．MAS 実装時の速度差を認識したかどうかの状態を表す関数 I_v は，一様乱数を用いて

$$\begin{cases} I_{v_t} = \begin{cases} I_{Recognized}, & Z_v(\Delta v_t) \geq R_{v_t} \\ I_{Not}, & Z_v(\Delta v_t) < R_{v_t} \end{cases} \\ \begin{cases} R_{v_{t+1}} = \begin{cases} \text{random}(0, 1], & Z_v(\Delta v_t) \geq R_{v_t} \\ R_{v_t}, & Z_v(\Delta v_t) < R_{v_t} \end{cases} \\ R_{v_0} = \text{random}(0, 1] \end{cases} \end{cases} \quad (6.22)$$

となる．

また，式(6.21)の累積分布関数を積分すると

$$\begin{cases}
Z_v^+(\Delta v_t) = \begin{cases} \frac{\delta v_t^-}{A_{v_t}} \ln \frac{1 + \exp[-N_v(\Delta v_t)/\kappa]}{1 + \exp[-N_v^-/\kappa]}, & \Delta v_t \leq 0 \\ 1 - \frac{\delta v_t^+}{A_{v_t}} \ln(1 + \exp[-N_v(\Delta v_t)/\kappa]), & \Delta v_t > 0 \end{cases} \\
Z_v^-(\Delta v_t) = \begin{cases} 1 - \frac{\delta v_t^-}{A_{v_t}} \ln \frac{1 + \exp[-N_v(\Delta v_t)/\kappa]}{1 + \exp[-N_v^-/\kappa]}, & \Delta v_t \leq 0 \\ \frac{\delta v_t^+}{A_{v_t}} \ln(1 + \exp[-N_v(\Delta v_t)/\kappa]), & \Delta v_t > 0 \end{cases} \\
\begin{cases} A_{v_t} = (\delta v_t^- + \delta v_t^+) \ln(1 + \exp[1/\kappa]) - \delta v_t^- \ln(1 + \exp[-N_v^-/\kappa]) \\ N_v^- = N_v(-v_{target_t}) \end{cases}
\end{cases} \quad (6.23)$$

となる．ここで， δv_t^- および δv_t^+ は $\Delta v_t \leq 0$ および $\Delta v_t > 0$ における式(6.1)の $\delta v(v_{target_t})$ のことを指す．

以下の[Proof]で式(6.23)が式(6.21)の積分結果になっていることを示す．

[Proof]

まずは，式(6.2)の全面積 $S_v(\Delta v(t))$ を求める．時間離散後を S_{v_t} と表すとする，式(6.2)より

$$\begin{aligned}
S_{v_t} &= \int_{-\infty}^{\infty} (1 - f_v(\Delta v)) d\Delta v \\
&= \int_{-v_{target_t}}^{\infty} \frac{\exp[-N_v(\Delta v)/\kappa]}{1 + \exp[-N_v(\Delta v)/\kappa]} d\Delta v.
\end{aligned}$$

また，式(6.1)から $N_v(\Delta v_t)$ は次のような関係を得ることができる．

$$\frac{d}{d\Delta v_t} N_v(\Delta v_t) = \begin{cases} \frac{-2}{\delta v_t^-}, & \Delta v_t \leq 0 \\ \frac{2}{\delta v_t^+}, & \Delta v_t > 0 \end{cases}$$

また $N_v^- \equiv N_v(-v_{target_t})$ とすると， S_{v_t} は

$$\begin{aligned}
S_{v_t} &= \frac{\delta v_t^-}{-2} \int_{N_v^-}^{-1} \frac{\exp[-N_v(\Delta v)/\kappa]}{1 + \exp[-N_v(\Delta v)/\kappa]} dN_v(\Delta v) + \frac{\delta v_t^+}{2} \int_{-1}^{\infty} \frac{\exp[-N_v(\Delta v)/\kappa]}{1 + \exp[-N_v(\Delta v)/\kappa]} dN_v(\Delta v) \\
&= \frac{\kappa}{2} \left(\delta v_t^- [\ln|1 + \exp[-N_v(\Delta v)/\kappa]|]_{N_v^-}^{-1} + \delta v_t^+ \lim_{R \rightarrow \infty} ([\ln|1 + \exp[-N_v(\Delta v)/\kappa]|]_R^{-1}) \right) \\
&= \frac{\kappa}{2} \left(\delta v_t^- \ln \frac{1 + \exp[1/\kappa]}{1 + \exp[-N_v^-/\kappa]} + \delta v_t^+ \lim_{R \rightarrow \infty} \left(\ln \frac{1 + \exp[1/\kappa]}{1 + \exp[-R/\kappa]} \right) \right) \\
&= \frac{\kappa}{2} \left(\delta v_t^- \ln \frac{1 + \exp[1/\kappa]}{1 + \exp[-N_v^-/\kappa]} + \delta v_t^+ \ln(1 + \exp[1/\kappa]) \right) \\
&= \frac{\kappa}{2} \left((\delta v_t^- + \delta v_t^+) \ln(1 + \exp[1/\kappa]) - \delta v_t^- \ln(1 + \exp[-N_v^-/\kappa]) \right)
\end{aligned}$$

となる.

ここで, $A_{v_t} \equiv (\delta v_t^- + \delta v_t^+) \ln(1 + \exp[1/\kappa]) - \delta v_t^- \ln(1 + \exp[-N_{v_t}^-/\kappa])$ と定義すると, $\Delta v_t \leq 0$ における $Z_v^+(\Delta v_t)$ は

$$\begin{aligned} Z_v^+(\Delta v_t) &= \frac{1}{S_{v_t}} \int_{-\infty}^{\Delta v_t} \frac{\exp[-N_v(\Delta v)/\kappa]}{1 + \exp[-N_v(\Delta v)/\kappa]} d\Delta v \\ &= \frac{2}{\kappa A_{v_t}} \frac{\delta v_t^-}{2} \int_{N_{v_t}^-}^{N_v(\Delta v(t))} \frac{\exp[-N_v(\Delta v)/\kappa]}{1 + \exp[-N_v(\Delta v)/\kappa]} dN_v(\Delta v) \\ &= \frac{\delta v_t^-}{A_{v_t}} [\ln|1 + \exp[-N_v(\Delta v)/\kappa]|]_{N_{v_t}^-}^{N_v(\Delta v_t)} \\ &= \frac{\delta v_t^-}{A_{v_t}} \ln \frac{1 + \exp[-N_v(\Delta v_t)/\kappa]}{1 + \exp[-N_{v_t}^-/\kappa]} \end{aligned}$$

となる.

同様に, $\Delta v_t > 0$ における $Z_v^+(\Delta v_t)$ は次のように計算される.

$$\begin{aligned} Z_v^+(\Delta v_t) &= \delta v_t^- \ln \frac{1 + \exp[1/\kappa]}{1 + \exp[-N_{v_t}^-/\kappa]} + \frac{\delta v_t^+}{\kappa A_{v_t}} \int_{-1}^{N_v(\Delta v_t)} \frac{\exp[-N_v(\Delta v)/\kappa]}{1 + \exp[-N_v(\Delta v)/\kappa]} dN_v(\Delta v) \\ &= \delta v_t^- \ln \frac{1 + \exp[1/\kappa]}{1 + \exp[-N_{v_t}^-/\kappa]} - \frac{\delta v_t^+}{A_{v_t}} [\ln|1 + \exp[-N_v(\Delta v)/\kappa]|]_{-1}^{N_v(\Delta v_t)} \\ &= \delta v_t^- \ln \frac{1 + \exp[1/\kappa]}{1 + \exp[-N_{v_t}^-/\kappa]} + \frac{\delta v_t^+}{A_{v_t}} \ln \frac{1 + \exp[1/\kappa]}{1 + \exp[-N_v(\Delta v(t))/\kappa]} \end{aligned}$$

また, $Z_v^+(\Delta v_t) = 1 - Z$ となるような Z は

$$Z = 1 - \left(\delta v_t^- \ln \frac{1 + \exp[1/\kappa]}{1 + \exp[-N_{v_t}^-/\kappa]} + \frac{\delta v_t^+}{A_{v_t}} \ln \frac{1 + \exp[1/\kappa]}{1 + \exp[-N_v(\Delta v(t))/\kappa]} \right) \text{ となる.}$$

両辺に A_{v_t} を乗算すると,

$$\begin{aligned} Z A_{v_t} &= A_{v_t} - \delta v_t^- \ln(1 + \exp[1/\kappa]) - \delta v_t^+ \ln \frac{1 + \exp[1/\kappa]}{1 + \exp[-N_v(\Delta v_t)/\kappa]} \\ &= (\delta v_t^- + \delta v_t^+) \ln(1 + \exp[1/\kappa]) - \delta v_t^- \ln(1 + \exp[-N_{v_t}^-/\kappa]) \\ &\quad - (\delta v_t^- + \delta v_t^+) \ln(1 + \exp[1/\kappa]) + \delta v_t^- \ln(1 + \exp[-N_{v_t}^-/\kappa]) \\ &\quad + \delta v_t^+ \ln(1 + \exp[-N_v(\Delta v_t)/\kappa]) \\ &= \delta v_t^+ \ln(1 + \exp[-N_v(\Delta v_t)/\kappa]) \end{aligned}$$

となる. これの両辺を A_{v_t} で除すると, Z は

$$Z = \frac{\delta v_t^+}{A_{v_t}} \ln(1 + \exp[-N_v(\Delta v_t)/\kappa]) \text{ となる.}$$

したがって, $\Delta v_t > 0$ における $Z_v^+(\Delta v_t)$ は $Z_v^+(\Delta v_t) = 1 - Z$ より

$$Z_v^+(\Delta v_t) = 1 - \frac{\delta v_t^+}{A_{v_t}} \ln(1 + \exp[-N_v(\Delta v_t)/\kappa])$$

となる.

まとめると

$$\begin{cases} Z_v^+(\Delta v_t) = \begin{cases} \frac{\delta v_t^-}{A_{v_t}} \ln \frac{1 + \exp[-N_v(\Delta v_t)/\kappa]}{1 + \exp[-N_v^-/\kappa]}, & \Delta v_t \leq 0 \\ 1 - \frac{\delta v_t^+}{A_{v_t}} \ln(1 + \exp[-N_v(\Delta v_t)/\kappa]), & \Delta v_t > 0 \end{cases} \\ \begin{cases} A_{v_t} = (\delta v_t^- + \delta v_t^+) \ln(1 + \exp[1/\kappa]) - \delta v_t^- \ln(1 + \exp[-N_v^-/\kappa]) \\ N_v^- = N_v(-v_{target_t}) \end{cases} \end{cases}$$

を得る.

また, $Z_v^-(\Delta v_t)$ は $Z_v^-(\Delta v_t) = 1 - Z_v^+(\Delta v_t)$ であることは自明なため, 証明は省略する.

以上より, 式(6.23)は確かに式(6.21)を積分した結果になっている.

[Quod Erat Demonstrandum]

6.4.3 車間距離差の時間離散化による確率的認識

車間距離差の変化の認識確率 $P_g(\Delta g(t))$ を離散的に扱うためには, 速度差の時と同様に累積分布関数を定義し, それを同様に, $\Delta g_t - \Delta g_{t-1}$ の符号で積分の方向が変化することに留意して積分を行うと, タイムステップ t における車間距離差の時間離散化による認識確率 $Z_g(\Delta g_t)$ は

$$\begin{cases} Z_g(\Delta g_t) = \begin{cases} Z_v^+(\Delta g_t), & \Delta g_t > \Delta g_{t-1} \\ Z_v^-(\Delta g_t), & \Delta g_t \leq \Delta g_{t-1} \end{cases} \\ \begin{cases} Z_g^+(\Delta g_t) = \int_{-\infty}^{\Delta g_t} q_g(\Delta g) d\Delta g \\ Z_g^-(\Delta g_t) = \int_{\Delta g_t}^{\infty} q_g(\Delta g) d\Delta g \end{cases} \end{cases} \quad (6.24)$$

となる. また MAS 実装時における車間距離差の変化を認識したかどうかの状態を表す関数 I_g は, 一様乱数を用いて

$$\begin{cases} I_{g_t} = \begin{cases} I_{Recognized}, & Z_g(\Delta g_t) \geq R_{g_t} \\ I_{Not}, & Z_g(\Delta g_t) < R_{g_t} \end{cases} \\ \begin{cases} R_{g_{t+1}} = \begin{cases} \text{random}(0, 1], & Z_g(\Delta g_t) \geq R_{g_t} \\ R_{g_t}, & Z_g(\Delta g_t) < R_{g_t} \end{cases} \\ R_{g_0} = \text{random}(0, 1] \end{cases} \end{cases} \quad (6.25)$$

となる.

また, 式(6.24)の累積分布関数を積分すると

$$\begin{cases}
Z_g^+(\Delta g_t) = \begin{cases} 0, & \Delta g_t < -\delta g_t^- \\ \frac{\delta g_t^-}{A_{g_t}} \ln \frac{1 + \exp[-N_{g_c}/\kappa]}{1 + \exp[-1/\kappa]}, & f_g(\Delta g_t) < F_g \wedge \Delta g_t \geq -\delta g_t^- \\ \frac{\delta g_t^-}{A_{g_t}} \ln \frac{1 + \exp[-N_g(\Delta g_t)/\kappa]}{1 + \exp[-1/\kappa]}, & f_g(\Delta g_t) \geq F_g \wedge -\delta g_t^- \leq \Delta g_t \leq 0 \\ 1 - \frac{\delta g_t^+}{A_{g_t}} \ln(1 + \exp[-N_g(\Delta g_t)/\kappa]), & f_g(\Delta g_t) \geq F_g \wedge \Delta g_t > 0 \end{cases} \\
Z_g^-(\Delta g_t) = \begin{cases} 1, & \Delta g_t < -\delta g_t^- \\ \frac{\delta g_t^+}{A_{g_t}} \ln(1 + \exp[-N_{g_c}/\kappa]), & f_g(\Delta g_t) < F_g \wedge \Delta g_t \geq -\delta g_t^- \\ 1 - \frac{\delta g_t^-}{A_{g_t}} \ln \frac{1 + \exp[-N_g(\Delta g_t)/\kappa]}{1 + \exp[-1/\kappa]}, & f_g(\Delta g_t) \geq F_g \wedge -\delta g_t^- \leq \Delta g_t \leq 0 \\ \frac{\delta g_t^+}{A_{g_t}} \ln(1 + \exp[-N_g(\Delta g(t))/\kappa]), & f_g(\Delta g_t) \geq F_g \wedge \Delta g_t > 0 \end{cases} \\
\begin{cases} A_{g_t} = (\delta g_t^- + \delta g_t^+) \ln(1 + \exp[-N_{g_c}/\kappa]) - \delta g_t^- \ln(1 + \exp[-1/\kappa]) \\ N_{g_c} = \kappa \ln\left(\frac{F_g}{1 - F_g}\right) \end{cases}
\end{cases} \quad (6.26)$$

となる.

以下の[Proof]で式(6.26)が式(6.24)の積分結果になっていることを示す.

[Proof]

まず, 式(6.9)の全面積 $S_g(\Delta g(t))$ を S_{g_t} として計算する. そこで, $f_g(\Delta g) = F_g$ となる時の正の Δg を Δg_c^+ , 負の Δg を Δg_c^- とおくと, S_{g_t} は

$$\begin{aligned}
S_{g_t} &= \int_{-\infty}^{\infty} (1 - q'_g(\Delta g)) d\Delta g \\
&= \int_{-\delta g_t^-}^{\Delta g_c^-} (1 - f_g(\Delta g)) d\Delta g + \int_{\Delta g_c^+}^{\infty} (1 - f_g(\Delta g)) d\Delta g \\
&= \int_{-\delta g_t^-}^{\Delta g_c^-} \frac{\exp[-N_g(\Delta g)/\kappa]}{1 + \exp[-N_g(\Delta g)/\kappa]} d\Delta g + \int_{\Delta g_c^+}^{\infty} \frac{\exp[-N_g(\Delta g)/\kappa]}{1 + \exp[-N_g(\Delta g)/\kappa]} d\Delta g
\end{aligned}$$

と計算される.

また, $N_g(\Delta g_t)$ は式(6.8)から

$$\frac{d}{d\Delta g_t} N_g(\Delta g_t) = \begin{cases} \frac{-2}{\delta g_t^-}, & \Delta g_t \leq 0 \\ \frac{2}{\delta g_t^+}, & \Delta g_t > 0 \end{cases}$$

と式変形できる.

また、式(6.8)の $f_g(\Delta g_t) = F_g$ となる時の N_g を N_{g_c} とすると、

$$F_g = \frac{1}{1 + \exp[-N_{g_c}/\kappa]} \Leftrightarrow \exp[-N_{g_c}/\kappa] = \frac{1 - F_g}{F_g} \quad (\because F_g \geq f_g(0) > 0)$$

を得る。両辺に対し対数をとると

$$N_{g_c} = \kappa \ln \left(\frac{F_g}{1 - F_g} \right)$$

となり、このことより S_{g_t} は

$$\begin{aligned} S_{g_t} &= \int_{-\delta g_t^-}^{\Delta g_t^-} \frac{\exp[-N_g(\Delta g)/\kappa]}{1 + \exp[-N_g(\Delta g)/\kappa]} d\Delta g + \int_{\Delta g_t^+}^{\infty} \frac{\exp[-N_g(\Delta g)/\kappa]}{1 + \exp[-N_g(\Delta g)/\kappa]} d\Delta g \\ &= -\frac{\delta g_t^-}{2} \int_1^{N_{g_c}} \frac{\exp[-N_g(\Delta g)/\kappa]}{1 + \exp[-N_g(\Delta g)/\kappa]} d\Delta g + \frac{\delta g_t^+}{2} \int_{N_{g_c}}^{\infty} \frac{\exp[-N_g(\Delta g)/\kappa]}{1 + \exp[-N_g(\Delta g)/\kappa]} d\Delta g \\ &= \frac{\kappa}{2} \left(\delta g_t^- [\ln|1 + \exp[-N_g(\Delta g)/\kappa]|]_1^{N_{g_c}} + \delta g_t^+ \lim_{R \rightarrow \infty} ([\ln|1 + \exp[-N_g(\Delta g)/\kappa]|]_R^{N_{g_c}}) \right) \\ &= \frac{\kappa}{2} \left(\delta g_t^- \ln \frac{1 + \exp[-N_{g_c}/\kappa]}{1 + \exp[-1/\kappa]} + \delta g_t^+ \lim_{R \rightarrow \infty} \left(\ln \frac{1 + \exp[-N_{g_c}/\kappa]}{1 + \exp[-R/\kappa]} \right) \right) \\ &= \frac{\kappa}{2} \left(\delta g_t^- \ln \frac{1 + \exp[-N_{g_c}/\kappa]}{1 + \exp[-1/\kappa]} + \delta g_t^+ \ln(1 + \exp[-N_{g_c}/\kappa]) \right) \\ &= \frac{\kappa}{2} \left((\delta g_t^- + \delta g_t^+) \ln(1 + \exp[-N_{g_c}/\kappa]) - \delta g_t^- \ln(1 + \exp[-1/\kappa]) \right) \end{aligned}$$

と計算される。

ここで、 $A_{g_t} \equiv (\delta g_t^- + \delta g_t^+) \ln(1 + \exp[-N_{g_c}/\kappa]) - \delta g_t^- \ln(1 + \exp[-1/\kappa])$ と定義すると、

$-\delta g_t^- \leq \Delta g_t \leq 0$ かつ $f_g(\Delta g_t) \geq F_g$ の範囲における $Z_g^+(\Delta g_t)$ は、

$$\begin{aligned} Z_g^+(\Delta g_t) &= \frac{1}{S_{g_t}} \int_{-\infty}^{\Delta g_t} \frac{\exp[-N_g(\Delta g)/\kappa]}{1 + \exp[-N_g(\Delta g)/\kappa]} d\Delta g \\ &= \frac{1}{S_{g_t}} \int_{-\delta g_t^-}^{\Delta g_t} \frac{\exp[-N_g(\Delta g)/\kappa]}{1 + \exp[-N_g(\Delta g)/\kappa]} d\Delta g \\ &= \frac{2}{\kappa A_{g_t}} \frac{\delta g_t^-}{-2} \int_1^{N_g(\Delta g_t)} \frac{\exp[-N_g(\Delta g)/\kappa]}{1 + \exp[-N_g(\Delta g)/\kappa]} dN_g(\Delta g) \\ &= \frac{\delta g_t^-}{A_{g_t}} [\ln|1 + \exp[-N_g(\Delta g)/\kappa]|]_1^{N_g(\Delta g_t)} \\ &= \frac{\delta g_t^-}{A_{g_t}} \ln \frac{1 + \exp[-N_g(\Delta g_t)/\kappa]}{1 + \exp[-1/\kappa]} \end{aligned}$$

となる。

また、 $-\delta g_t^- \leq \Delta g_t \leq 0$ かつ $f_g(\Delta g_t) < F_g$ と $\Delta g_t > 0$ かつ $f_g(\Delta g_t) < F_g$ の範囲では

$$Z_g^+(\Delta g_t) = \frac{\delta g_t^-}{A_{g_t}} \ln \frac{1 + \exp[-N_{g_c}/\kappa]}{1 + \exp[-1/\kappa]}$$

となる．このことより， $\Delta g_t > 0$ かつ $f_g(\Delta g_t) \geq F_g$ の範囲の $Z_g^+(\Delta g_t)$ は

$$\begin{aligned} Z_g^+(\Delta g_t) &= \frac{\delta g_t^-}{A_{g_t}} \ln \frac{1 + \exp[-N_{g_c}/\kappa]}{1 + \exp[-1/\kappa]} + \frac{\delta g_t^+}{\kappa A_{g_t}} \int_{N_{g_c}}^{N_g(\Delta g_t)} \frac{\exp[-N_g(\Delta g)/\kappa]}{1 + \exp[-N_g(\Delta g)/\kappa]} d\Delta g \\ &= \frac{\delta g_t^-}{A_{g_t}} \ln \frac{1 + \exp[-N_{g_c}/\kappa]}{1 + \exp[-1/\kappa]} - \frac{\delta g_t^+}{A_{g_t}} [\ln |1 + \exp[-N_g(\Delta g)/\kappa]|]_{N_{g_c}}^{N_g(\Delta g_t)} \\ &= \frac{\delta g_t^-}{A_{g_t}} \ln \frac{1 + \exp[-N_{g_c}/\kappa]}{1 + \exp[-1/\kappa]} - \frac{\delta g_t^+}{A_{g_t}} \ln \frac{1 + \exp[-N_g(\Delta g_t)/\kappa]}{1 + \exp[-N_{g_c}/\kappa]} \end{aligned}$$

となる．

速度差の認識確率の証明時同様に， $Z_g^+(\Delta g_t) = 1 - Z$ となる Z について，両辺に A_{g_t} を乗算すると，

$$\begin{aligned} Z A_{g_t} &= A_{g_t} - \delta g_t^- \ln \frac{1 + \exp[-N_{g_c}/\kappa]}{1 + \exp[-1/\kappa]} + \delta g_t^+ \ln \frac{1 + \exp[-N_g(\Delta g_t)/\kappa]}{1 + \exp[-N_{g_c}/\kappa]} \\ &= \delta g_t^+ \left(\ln(1 + \exp[-N_{g_c}/\kappa]) + \ln \frac{1 + \exp[-N_g(\Delta g_t)/\kappa]}{1 + \exp[-N_{g_c}/\kappa]} \right) \\ &= \delta g_t^+ \ln(1 + \exp[-N_g(\Delta g_t)/\kappa]) \end{aligned}$$

を得る．そして両辺を A_{g_t} で除すると， Z は

$$Z = \frac{\delta g_t^+}{A_{g_t}} \ln(1 + \exp[-N_g(\Delta g_t)/\kappa])$$

となる．

以上より， $\Delta g_t > 0$ かつ $f_g(\Delta g_t) \geq F_g$ における $Z_g^+(\Delta g_t)$ は $Z_g^+(\Delta g_t) = 1 - Z$ より

$$Z_g^+(\Delta g_t) = 1 - \frac{\delta g_t^+}{A_{g_t}} \ln(1 + \exp[-N_g(\Delta g_t)/\kappa])$$

となる．

まとめると

$$Z_g^+(\Delta g_t) = \begin{cases} 0, & \Delta g_t < -\delta g_t^- \\ \frac{\delta g_t^-}{A_{g_t}} \ln \frac{1 + \exp[-N_{g_c}/\kappa]}{1 + \exp[-1/\kappa]}, & f_g(\Delta g_t) < F_g \wedge \Delta g_t \geq -\delta g_t^- \\ \frac{\delta g_t^-}{A_{g_t}} \ln \frac{1 + \exp[-N_g(\Delta g_t)/\kappa]}{1 + \exp[-1/\kappa]}, & f_g(\Delta g_t) \geq F_g \wedge -\delta g_t^- \leq \Delta g_t \leq 0 \\ 1 - \frac{\delta g_t^+}{A_{g_t}} \ln(1 + \exp[-N_g(\Delta g_t)/\kappa]), & f_g(\Delta g_t) \geq F_g \wedge \Delta g_t > 0 \end{cases}$$

$$\begin{cases} A_{g_t} = (\delta g_t^- + \delta g_t^+) \ln(1 + \exp[-N_{g_c}/\kappa]) - \delta g_t^- \ln(1 + \exp[-1/\kappa]) \\ N_{g_c} = \kappa \ln\left(\frac{F_g}{1 - F_g}\right) \end{cases}$$

となる.

$Z_g^-(\Delta g_t)$ については $Z_g^-(\Delta g_t) = 1 - Z_g^+(\Delta g_t)$ であることが自明なため、証明は省略する.

以上より、式(6.26)が式(6.24)の積分した結果になっている.

[Quod Erat Demonstrandum]

6.4.4 衝突回避機構

節 6.3 では数式を使って時空間連続系のモデルを構築した. しかしそのままでは MAS に実装できないので、時間について離散化を施してきた. ここで問題になるのが、時間離散化による衝突の可能性である. 時空間連続の時は、絶対に衝突しないモデルであったが、特定の条件がそろえば、時間離散化したモデルでは衝突が起こる可能性があるため、衝突回避機構が必要となる. 特定の条件とは、式(6.25)における乱数 R_g が1に限りなく近い数字をとり、車間距離が最小安全車間距離よりもわずかに大きく、かつ認識確率 Z_g が乱数 R_g よりもわずかに小さく、認識イベントが発生しなかった場合だ. このような場合において、次のタイムステップまでの、 Δt の間に、本来は認識イベントが発生するはずだったが、時間を離散化したことにより、このイベントは Δt 後に起こるため、 Δt 後のタイムステップでは、車間距離が最小安全車間距離よりも小さくなってしまい、衝突が起こってしまう場合がある. これは時間を離散化したことにより発生する問題である.

この予期しない「誤った衝突」を回避するために、各車両について、現在の加速度が次のタイムステップでも維持されるとして、各車両の次のタイムステップでの車間距離と最小安全車間距離を予測し、もしも予測した結果、最小安全車間距離を割ると見込まれる場合は、予め減速を開始する関数を組み込む.

そこで、状態関数 E を導入し、これは車間距離が次のタイムステップで最小安全車間距離よりも小さくなるかどうかを示す. 具体的には、状態関数 E は緊急対応が必要な状態 $E_{Emergency}$ か、安全な状態 E_{Safety} を示す. 時刻 t における状態関数 E 、すなわちタイムステップ t における状態関数 E_t を、式(6.19)で定義された $\Delta t_v(a, v)$ 、式(6.20)で定義された $\Delta t_x(a, v, x)$ 、および式(6.4)

で定義された $\tau_n(v)$ を用いて,

$$\begin{cases} E_t = \begin{cases} E_{Safety}, & g_t^{ex} \leq g_{closest_t}^{ex} \\ E_{Emergency}, & g_t^{ex} > g_{closest_t}^{ex} \end{cases} \\ \begin{cases} g_t^{ex} = x_t^{exF} - x_t^{ex} + \ell^F \\ x_t^{ex} = \Delta t_x(a_{t-1}, v_{t-1}, x_{t-1}) \\ x_t^{exF} = \Delta t_x(-A_{acceptable}^-, v_{t-1}^F, x_{t-1}^F) \end{cases} \\ \begin{cases} g_{closest_t}^{ex} = v_t^{ex} \tau_{n \equiv a \rightarrow b}(v_t^{ex}) + \frac{(v_t^{ex})^2}{2A_{strong}^-} - \frac{(v_t^{exF})^2}{2A_{acceptable}^-} + G_{closest} \\ v_t^{ex} = \Delta t_v(a_t, v_{t-1}) \\ v_t^{exF} = \Delta t_v(-A_{acceptable}^-, v_{t-1}^F) \end{cases} \end{cases} \quad (6.27)$$

と定義する. ここで, 式中の ℓ^F は表 6-1 で定義される前方車両の車の長さで, $A_{acceptable}^-$, A_{strong}^- および $G_{closest}$ は表 6-2 で定義されるドライバー固有の定数である.

「誤った衝突」が予測される場合, すなわち $E_t = E_{Emergency}$ となる場合は, 前述の通り事前の減速が必要となる. そのためには, 式(6.25)の I_g を $I_{Recognized}$ にする必要があり, 式(6.25)は

$$\begin{cases} I_{g_t} = \begin{cases} I_{Recognized}, & Z_g(\Delta g_t) \geq R_{g_t} \vee E_t = E_{Emergency} \\ I_{Not}, & Z_g(\Delta g_t) < R_{g_t} \wedge E_t = E_{Safety} \end{cases} \\ \begin{cases} R_{g_{t+1}} = \begin{cases} \text{random}(0, 1], & Z_g(\Delta g_t) \geq R_{g_t} \vee E_t = E_{Emergency} \\ R_{g_t}, & Z_g(\Delta g_t) < R_{g_t} \wedge E_t = E_{Safety} \end{cases} \\ R_{g_0} = \text{random}(0, 1] \end{cases} \end{cases} \quad (6.28)$$

と書き直される.

次に, 節 6.3 および節 6.4 で導入した目標速度と目標加速度を次のように修正する.

$$v_{target_t} = \begin{cases} \min[V_{cruise}, v_t^F], & E_t = E_{Emergency} \\ v_{target_t}^{Recognized}, & E_t = E_{Safety} \end{cases}, \quad (6.29)$$

$$\begin{cases} a_{target_t} = \begin{cases} a_{emergency_t}, & E_t = E_{Emergency} \\ a_{target_{t-1}}, & I_{v_t} = I_{Not} \wedge I_{g_t} = I_{Not} \wedge E_t = E_{Safety} \\ a_{target_t}^{Recognized}, & (I_{v_t} = I_{Recognized} \vee I_{g_t} = I_{Recognized}) \wedge E_t = E_{Safety} \end{cases} \\ a_{emergency_t} = \begin{cases} -A_{accpetable}^-, & S_{FP_t} \neq S_{Brake} \\ -\frac{v_{t-1}^2}{2\left(g_t + \frac{(v_{t-1}^F)^2}{2A_{accpetable}^-} - G_{closest}\right)}, & S_{FP_t} = S_{Brake} \end{cases} \end{cases}. \quad (6.30)$$

ここで, v_{target_t} , a_{target_t} , $v_{target_t}^{Recognized}$ および $a_{target_t}^{Recognized}$ は, それぞれ, $v_{target}(t)$, $a_{target}(t)$,

$v_{target}^{Recognized}(t)$ および $a_{target}^{Recognized}(t)$ を時間離散化した時の表記である. また, 式(6.30)からもわかるように, $a_{emergency_t}$ は足がブレーキペダルにある場合は, 前方車両が完全停止した際に自身の車両が前方車両の後方 $G_{closest}$ にて完全停止できる時の減速度で減速し, 足がブレーキペダルにない場合は許容できる最大減速度で減速する.

6.5 結果と考察

6.5.1 基本図の再現性

本モデルを実装した MAS によって得られたデータから、交通流量と交通密度からなる基本図を使用して、1996 年に東名高速道路で実測されたデータから作成された基本図 [33] と比較することで、本モデルの基本図の再現性を確認する。

MAS に実装する際、長さが10[km]の環状道路、すなわち周期境界条件を適用し、1 タイムステップは $\Delta t = 0.05[s]$ とし、節 6.3 および節 6.4 のモデルを実装した。

MAS を用いた数値実験から交通流量と交通密度を得る際に、東名高速道路での実測方法 [33] と同じになるよう、道路上の任意の計測地点を距離が6.9[m]になるよう 2 地点用意し、この 2 地点の車両通過台数である交通流量を計測し、2 地点の通過時刻の差から速度を算出し、その速度から密度を算出する。また、交通流量に関しては、5 分を単位時間として計測し、交通流密度はこの 5 分間に通過した車両の平均速度を用いて算出する。また、この 5 分間の計測に関して、系内の車両数（すなわち全体の道路に占める車両の割合（全体の車両密度））を一定に保ち、1 つのシミュレーションエピソードに対し、4 回（20 分間分）繰り返し測定する。基本図には、この計測で得た交通流量と交通密度（局所密度）を 1 つの円としてプロットし、実測データとまったく同じ方法 [33] で表示する。各シミュレーションエピソードは、系内の車両の初期配置や各ドライバーの固有値の一部が異なる、独立した初期条件から 5 回計測され、同じ全体の車両密度に対し、プロットは 20 プロット作成される。

また、全体の車両密度は 0 から 0.5 まで 1 台ずつ増やしてシミュレーションを行い、車両とドライバーの固有値である表 6-1 と表 6-2 を、それぞれ、表 6-3 と表 6-4 に示す値を用いてシミュレーションを行う。

実測データによる基本図を再現するために、モデルパラメータの最適な組み合わせを見つけるべく、予備シミュレーションを行い、その結果得られた値が表 6-4 に示されている。特に、 A_{strong}^- と A_{normal}^- , $A_{F_{normal}}^-$, N_{gc} は、各ドライバーは均一の値を持つのではなく、表に示される範囲内でランダムな値として割り当てられる。それ以外の値は、すべて、ドライバーにかかわらず一定の値を想定しており、また、車両に関しては同一車両を想定しているため、各車両でばらつきはない。

表 6-3 車両関係の定数の設定値

定数	設定値
$V_{\max}$	183[km/h]
$A_{\max}^+$	4.085[m/s ²]
$A_{\max}^-$	9.995[m/s ²]
$A_{resistance}^-$	0.278[m/s ²]
ℓ	4.435[m]

表 6-4 ドライバー関係の定数の設定値

定数	設定値	定数	設定値
速度関係		時間関係	
V_{cruise}	100[km/h]	$T_{b \rightarrow a}^+$	0.5[s]
$V_{b \rightarrow a}^+$	70[km/h]	$T_{b \rightarrow a}^-$	0.7[s]
$V_{b \rightarrow a}^-$	20[km/h]	$T_{a \rightarrow b}^+$	0.3[s]
$V_{a \rightarrow b}^+$	70[km/h]	$T_{a \rightarrow b}^-$	0.7[s]
$V_{a \rightarrow b}^-$	20[km/h]	T_{margin}^+	1.5[s]
V_{margin}^+	70[km/h]	T_{margin}^-	3.0[s]
V_{margin}^-	40[km/h]		
速度差関係		加速度関係	
δV_{cruise}^+	10[km/h]	$A_{acceptable}^+$	1.667[m/s ²]
δV_{cruise}^-	10[km/h]	$A_{acceptable}^-$	9.0[m/s ²]
δV_{stop}^+	3.0[km/h]	A_{strong}^-	[6.0, 8.0][m/s ²]
δV_{stop}^-	0.1[km/h]	A_{normal}^-	[2.0, 3.0][m/s ²]
		$A_{Fnormal}^-$	[1.5, 3.0][m/s ²]
車間距離関係		認識関数関係	
$G_{closest}$	1.5[m]	N_{g_c}	[-1.0, -0.1][—]
G_{cruise}	2.5[m]		
$G_{influenced}$	6.0[m]		

また、図 6-4 に本モデルによる MAS によって得られた交通流量 q と局所密度 ρ の関係を表す基本図を示している。この図 6-4 の赤いプロットは全体の車両密度が 0.3 以上のデータで、この範囲の車両密度が発生するような時期は、例えばお盆などの特殊な時期にしか発生せず、実測データ [33]には含まれていないと考えられる範囲となる。したがって、実測データ [33]と本モデルを比較した基本図である図 6-5 には、図 6-4 の赤と水色の全体の車両密度が 0.3 以上のデータは含めていない。

実測データ [33]と本モデルを比較した基本図である図 6-5 に注目すると、自由相（図 6-4 の青色の楕円で囲われた範囲）、メタ安定相（図 6-4 の緑色の楕円で囲われた範囲）の出現、メタ安定相崩壊と混合相（図 6-4 の黄色の楕円で囲われた範囲）の出現、渋滞相（図 6-4 の灰色の楕円で囲われた範囲）のどの部分をとっても、実測データ [33]の特徴を再現することができしており、プロットの描画範囲も実測データ [33]から大きく外れたプロットはないことがわかる。このことにより、本モデルは stop-and-go 波を再現できていることが示唆される。




図 6-4 MAS による交通流量 q と局所密度 ρ の関係を表す基本図．赤色のプロットは全体の車両密度が 0.3 以上のデータで，黒の円は 0.3 未満のデータである．青，緑，黄色，灰色の楕円で囲われた領域は，それぞれ，自由相，メタ安定相，混合相，そして渋滞相の各フェーズを表している．また，黄色と水色のプロットと各番号は時空間図（表 6-5）に対応している．




図 6-5 MAS（赤色のプロット）と実測データ [33]（黒色のプロット）による交通流量 q と局所密度 ρ の関係を表す基本図．

6.5.2 流れ場の特徴

以下の表 6-5 に、図 6-4 の黄色と水色でプロットされた 11 の代表的な流れ場の基本図の情報と、時空間図の図表番号を載せている。

表 6-5 11 の代表的な流れ場の基本図の情報と時空間図の図表番号

プロット番号	$\rho(1/\text{km})$	$q(1/5\text{min})$	相	図表番号
1	21.41	186	メタ安定相	図 6-6
2	20.23	148	混合相	図 6-7
3	16.52	128	混合相	図 6-8
4	33.00	128	混合相	図 6-9
5	26.60	108	混合相	図 6-10
6	45.61	110	混合相	図 6-11
7	32.16	82	渋滞相	図 6-12
8	51.14	83	渋滞相	図 6-13
9	40.86	16	渋滞相	図 6-14
10	90.94	22	渋滞相	図 6-15
11	152.41	23	渋滞相	図 6-16

図 6-6 のプロット番号 1 のメタ安定相の時空間図に注目すると、全車両が滑らかに前方車両に追従して走行していることがわかる。また、図 6-7 から図 6-16 までの時空間図に注目すると、実測データ [33] と本モデルを比較した基本図である図 6-5 で示唆された **stop-and-go** 波が、よく再現できていることが見て取れる。加えて、完全停止している部分が時間に対して後方車両へと伝播している様子も見て取れる。そして、現実の道路でたびたび見られるように、一部の区間ではスムーズに流れるが、別の地点では渋滞が発生し **stop-and-go** 波が確認でき、完全に流れが停止している部分も見受けられるなど、同じ流れ場でも別々の相を再現できていることが確認できる。




図 6-6 プロット番号 1 の時空間図.




図 6-7 プロット番号 2 の時空間図.




図 6-8 プロット番号 3 の時空間図.




図 6-9 プロット番号 4 の時空間図.




図 6-10 プロット番号 5 の時空間図.




図 6-11 プロット番号 6 の時空間図.




図 6-12 プロット番号 7 の時空間図.




図 6-13 プロット番号 8 の時空間図.




図 6-14 プロット番号 9 の時空間図.




図 6-15 プロット番号 10 の時空間図.




図 6-16 プロット番号 11 の時空間図.

6.5.3 局所的流れ場の再現性

前節では、時空間図を用いて、本モデルの再現性の高さを確認してきた。この節では、より局所的な流れ場を再現できているか、既往研究 [29] にならい、定常状態の流れ場の先頭車両が突然減速し、その後速度を回復した時の後続車両への影響を確認することで、評価する。

図 6-17 にその結果を示している。具体的なシナリオは次の通りで、先頭車両は人間ではなくボットが運転する（つまり、常に速度を調節する）車両で、目標速度（巡航速度）を $80[\text{km/h}]$ としており、その後方に 74 台の人間が運転する車両が続く。この後方の人間が運転する車両は本モデルのダイナミクスに従って運転する。この車列の流れ場が安定した状態になった時刻を $t = 0$ とし、 $t = 100[\text{s}]$ から $t = 100 + 10[\text{s}]$ にかけて先頭車両は $80[\text{km/h}]$ から $65[\text{km/h}]$ まで減速する。その後、 $t = 110[\text{s}]$ から $t = 110 + 10[\text{s}]$ にかけて先頭車両は $65[\text{km/h}]$ から $72[\text{km/h}]$ まで速度を回復する。以上のシナリオに対し、後方に続く人間が運転する車両に対し 2 ケースを想定する。一つは巡航速度 $V_{\text{Cruise}} = 82[\text{km/h}]$ （図 6-17 の左のパネル (*-1)）で、もう一つは巡航速度 $V_{\text{Cruise}} = 100[\text{km/h}]$ （図 6-17 の右のパネル (*-2)）である。また、図 6-17 の上段 (a-*) の速度変化の図は、先頭車両から 10 台分の速度変化を載せている。

どちらのケースにおいても、先頭車両の突然の減速が後続車両に大きな影響を与えていることがわかる。特に右側のパネルの巡航速度 $V_{\text{Cruise}} = 100[\text{km/h}]$ の場合は、より大きな影響を与えていることがわかる。これは、早く目的地に到達したいドライバーが、前方の局所的な渋

滞に対し、極端な速度応答を示すため、このことは現実の道路でもよく観察される事象である。この図 6-17 は、本モデルがそのような局所的な流れ場をよく再現していることを示唆している。




図 6-17 先頭車両をある地点で減速させ、その後速度を回復させた時の先頭車両と後続車両 9 台の速度の時間変化 (a-*) と時空間図 (b-*)。左のパネル (*-1) と右のパネル (*-2) では、全車両の目標速度 V_{cruise} をそれぞれ 82[km/h] と 100[km/h] に設定した時の結果である。時空間図の赤いプロットは先頭車両を表している。

6.6 結論

本章では，ミクロな概念に基づく時空間連続系の新たな交通流モデルを開発し，実測データと比較することでその再現度の高さから有用性を確認し，さらに局所的な流れ場を解析することで，本モデルの有用性を再確認した．

一方で，本モデルは前方車両の影響のみを考慮しており，長時間の運転によるドライバーの疲労や，雨などの環境の変化による道路状況の変化，交通信号機などの影響もすべて無視した単一車線モデルなため，より現実の道路を再現するために，これらの影響を取り入れ，さらには複数車線系に拡張することを今後の展望とする．

参考文献

- [1] R. Haberman, *Mechanical Vibrations, Population Dynamics, and Traffic Flow*, Society for Industrial and Applied Mathematics (Prentice Hall (New Jersey), 1977).
- [2] J. Tanimoto, *Evolutionary Games with Sociophysics: Analysis of Traffic Flow and Epidemics*, Vol. 17 (Springer, Singapore, 2018).
- [3] J. Tanimoto, *Fundamentals of Evolutionary Game Theory and Its Applications*, Vol. 6 (Springer: Tokyo Japan, 2015).
- [4] B. S. Kerner, *Introduction to Modern Traffic Flow Theory and Control: The Long Road to Three-Phase Traffic Theory* (Springer: Berlin Heidelberg, Berlin Heidelberg, 2009).
- [5] T. S. Komatsu and S. I. Sasa, *Kink Soliton Characterizing Traffic Congestion*, Phys Rev E 52, 5574 (1995).
- [6] T. Nagatani, *Thermodynamic Theory for the Jamming Transition in Traffic Flow*, Phys Rev E 58, 4271 (1998).
- [7] K. Nagel and M. Schreckenberg, *A Cellular Automaton Model for Freeway Traffic*, Journal de Physique I France 2, 2221 (1992).
- [8] S. Sakai, K. Nishinari, and S. Iida, *A New Stochastic Cellular Automaton Model on Traffic Flow and Its Jamming Phase Transition*, J Phys A Math Gen 39, 15327 (2006).
- [9] B. S. Kerner and S. L. Klenov, *Phase Transitions in Traffic Flow on Multilane Roads*, Phys Rev E Stat Nonlin Soft Matter Phys 80, 056101 (2009).
- [10] S. Kokubo, J. Tanimoto, and A. Hagishima, *A New Cellular Automata Model Including a Decelerating Damping Effect to Reproduce Kerner's Three-Phase Theory*, Physica A: Statistical Mechanics and Its Applications 390, 561 (2011).
- [11] S. Kukida, J. Tanimoto, and A. Hagishima, *Analysis of the Influence of Lane Changing on Traffic-Flow Dynamics Based on the Cellular Automaton Model*, International Journal of Modern Physics C 22, 271 (2011).
- [12] A. Yamauchi, J. Tanimoto, A. Hagishima, and H. Sagara, *Dilemma Game Structure Observed in Traffic Flow at a 2-to-1 Lane Junction*, Phys Rev E Stat Nonlin Soft Matter Phys 79, 036104 (2009).
- [13] M. Nakata, A. Yamauchi, J. Tanimoto, and A. Hagishima, *Dilemma Game Structure Hidden in Traffic Flow at a Bottleneck Due to a 2 into 1 Lane Junction*, Physica A: Statistical Mechanics and Its Applications 389, 5353 (2010).
- [14] J. Tanimoto and H. Sagara, *Social Diffusive Impact Analysis Based on Evolutionary Computations for a Novel Car Navigation System Sharing Individual Information in Urban Traffic Systems*, The Journal of Navigation 64, 711 (2011).
- [15] J. Tanimoto, T. Fujiki, Z. Wang, A. Hagishima, and N. Ikegaya, *Dangerous Drivers Foster Social*

- Dilemma Structures Hidden behind a Traffic Flow with Lane Changes*, Journal of Statistical Mechanics: Theory and Experiment 2014, 11027 (2014).
- [16] J. Tanimoto, S. Kukida, and A. Hagishima, *Social Dilemma Structures Hidden behind Traffic Flow with Lane Changes*, Journal of Statistical Mechanics: Theory and Experiment 2014, 07019 (2014).
 - [17] J. Tanimoto and K. Nakamura, *Social Dilemma Structure Hidden behind Traffic Flow with Route Selection*, Physica A: Statistical Mechanics and Its Applications 459, 92 (2016).
 - [18] Y. Iwamura and J. Tanimoto, *Complex Traffic Flow That Allows as Well as Hampers Lane-Changing Intrinsically Contains Social-Dilemma Structures*, Journal of Statistical Mechanics: Theory and Experiment 2018, (2018).
 - [19] J. Tanimoto and X. An, *Improvement of Traffic Flux with Introduction of a New Lane-Change Protocol Supported by Intelligent Traffic System*, Chaos Solitons Fractals 122, 1 (2019).
 - [20] J. Tanimoto, T. Fujiki, S. Kukida, N. Ikegaya, and A. Hagishima, *Acquisition of the Field Measurement Data Relating to Lane Change Actions*, International Journal of Modern Physics C 26, 1 (2015).
 - [21] E. Fukuda, J. Tanimoto, Y. Iwamura, K. Nakamura, and A. Mitsuhiro, *Field Measurement Analysis to Validate Lane-Changing Behavior in a Cellular Automaton Model*, Phys Rev E 94, 052209 (2016).
 - [22] G. F. Newell, *Nonlinear Effects in the Dynamics of Car Following*, Oper Res 9, 209 (1961).
 - [23] M. Bando, K. Hasebe, A. Nakayama, A. Shibata, and Y. Sugiyama, *Dynamical Model of Traffic Congestion and Numerical Simulation*, Phys Rev E 51, 1035 (1995).
 - [24] R. Jiang, Q. Wu, and Z. Zhu, *Full Velocity Difference Model for a Car-Following Theory*, Phys Rev E 64, 017101 (2001).
 - [25] B. Yu, H. Zhou, L. Wang, Z. Wang, and S. Cui, *An Extended Two-Lane Car-Following Model Considering the Influence of Heterogeneous Speed Information on Drivers with Different Characteristics under Honk Environment*, Physica A: Statistical Mechanics and Its Applications 578, 126022 (2021).
 - [26] X. Wang, M. Liu, Y. Ci, and L. Wu, *Effect of Front Two Adjacent Vehicles' Velocity Information on Car-Following Model Construction and Stability Analysis*, Physica A: Statistical Mechanics and Its Applications 607, 128196 (2022).
 - [27] X. Li, Y. Xiao, X. Zhao, X. Ma, and X. Wang, *Modeling Mixed Traffic Flows of Human-Driving Vehicles and Connected and Autonomous Vehicles Considering Human Drivers' Cognitive Characteristics and Driving Behavior Interaction*, Physica A: Statistical Mechanics and Its Applications 609, 128368 (2023).
 - [28] J. Tian, H. M. Zhang, M. Treiber, R. Jiang, Z. Gao, and B. Jia, *On the Role of Speed Adaptation*

and Spacing Indifference in Traffic Instability: Evidence from Car-Following Experiments and Its Stochastic Model, Transportation Research Part B: Methodological 129, 334 (2019).

- [29] M. Shang, S. Wang, and R. Stern, *A Two-Condition Continuous Asymmetric Car-Following Model for Adaptive Cruise Control Vehicles*, IEEE Transactions on Intelligent Vehicles 9, 3975 (2024).
- [30] Y. Xue, L. Wang, B. Yu, and S. Cui, *A Two-Lane Car-Following Model for Connected Vehicles Under Connected Traffic Environment*, IEEE Transactions on Intelligent Transportation Systems PP, 1 (2024).
- [31] P. A. van der Helm, *Weber-Fechner Behavior in Symmetry Perception?*, Atten Percept Psychophys 72, 1854 (2010).
- [32] J. Tanimoto, *Sociophysics Approach to Epidemics*, Vol. 23 (Springer: Singapore, 2021).
- [33] 雄規杉山, 交通流の物理, 日本流体力学会誌「ながれ」 22, 95 (2003).

第7章 総括結論

本研究では、Multi Agent Simulation (MAS) を用いて、ワクチン接種ゲームおよび交通流モデルを通して、複雑社会システムの解析に関する研究を行った。

その結果、MAS は拡張性が高く、柔軟に、様々なモデルを再現することができ、現実の複雑社会システムを解析する上で、非常に強力なツールを提供することがわかった。具体的には、次のような研究を通して、この結論を得た。

第 3 章でワクチン接種ゲームを用いて、現実の人間のネットワーク構造を模擬したネットワーク上で MAS を用いて、感染症を多くの人にばらまいてしまう可能性のある、多くの隣人を持つハブエージェントに着目し、どのように、ワクチン接種を行うか否かの戦略を決定しているかを確認した。このハブエージェントにあたる人というのは、具体的には、医者や学校の先生、公共交通機関の運転手などが該当する。そして、これらに該当する人たちは、既往研究によると、親しい友人や家族に相談して、感染のリスクとワクチン接種のコストを比較するのではなく、医者は医者同士など、自身と同じような感染リスクを持つ者の動向に注目する、と報告されている。そこで、そのようなモデルを構築し、どのような影響を与えるかを確認した。結果、医者などの感染リスクが高い者が、より積極的にワクチン接種を行うことで、少ないワクチン接種者でも集団免疫を達成することとなり、感染者数を少なく抑えることが可能だということがわかった。そして、この同じような感染リスクを持つ人との比較で、参照する隣人の範囲を広げた結果、さらに少ないワクチン接種者数で効率的に感染症蔓延を防ぐことができることがわかった。つまり、メディアなどが感染症に対し情報発信する際に、感染リスク別に情報を発信すると、より効率的に感染症蔓延を防ぐことが可能だということを示唆した。

第 4 章では、同じくワクチン接種ゲームを MAS に実装して、感染症蔓延を未然に防ぐために、先制的ワクチン接種公的補助スキームの最適社会設計に関する研究として、ワクチン接種を無料で摂取することができるフリーチケットを配布する政策を想定し、モデルを構築した。このモデルでは、全部で 9 つの公的補助スキームを用意し、それぞれが社会全体にどのような影響を与えるか、解析を行った。結果、全体の傾向として、ハブエージェントに対し優先的に、本人の意思とは関係なく、フリーチケットによる強制ワクチン接種が有効であることがわかった。また、本人の意思とは無関係にフリーチケットを配布した場合、チケット受給者は D 戦略になることもわかった。なぜなら、この政策下におけるフリーチケットを使用したワクチン接種は、免疫にただ乗りしたのと利得的に同じことであるため、このフリーチケットによってワクチン接種を行ったハブエージェントの誤った成功体験が、多くの隣人に影響を与えることになり、自発的なワクチン接種者を根絶してしまうからである。そのため、十分なフリーチケットを用意できない、つまり、集団免疫に必要なだけのフリーチケットを用意できない場合は、もともと感染リスクが高く、自発的にワクチン接種を行う可能性が高い

ハブエージェントに対し、フリーチケットを配布するよりも、隣人数は少ないが、とにかく人数が多い低次数のエージェントにフリーチケットを配ってワクチン接種を行わせた方が、集団内のワクチン接種率も高くなり、感染症の蔓延を防ぐことが可能だということがわかった。

第5章では、MASによるCAモデルの一つである、Revised S-NFS モデルを使って、自動運転車両と人間運転車両が混在する交通流の背後に潜在する社会ジレンマの解析と、自動運転システムの社会受容性に関する研究を行った。この自動運転車両は、追従機能 (Adaptive Cruise Control, ACC) を備えており、車載レーダーなどを用いて前方車両との車間距離を測定し、適切な加減速を自動で行うことができる。また、自動運転車両の前方の車両も自動運転車両だった場合、協調型 ACC (Cooperative Adaptive Cruise Control, CACC) となり、前方車両の自動運転車両のすべての情報を、通信によって瞬時に得ることが可能で、前方車両と全く同じ動きを即座に再現することができるため、車間距離を、人間が運転する車両では絶対に再現できないような距離で走行することが可能となり、platoon 走行を行うことができる。この platoon 走行は、自動運転車両のいわば究極体で、旅行時間短縮、ひいてはエネルギー消費量削減にもつながる技術である。このように、メリットの多い自動運転だが、現実の社会のように自動運転車両の普及が進んでいない場合、法定速度の厳守や車線変更禁止などの制約があるような自動運転車両よりも、速度超過や車線変更も自由にできる人間が運転する車両の方が、メリットが大きいと、ゲーム理論の観点から自動運転車両の普及は難しいことがわかった。一方で、道路上の車両台数が増加し、自動運転車両がその車両の大半を占め、速度超過や車線変更ができないような状況下では、自身が運転するよりも、自動運転車両の方が platoon 走行可能となるため、渋滞そのものが発生しにくくなり、メリットがデメリットを上回るため、自動運転車両の普及が可能だということがわかった。以上のような解析の結果、自動運転車両の普及の背後には、初期状態の比率に応じて比率の大きい方に吸引される、Stag Hunt 型のジレンマ構造が存在していることがわかり、自動運転車両の普及に対し、自由市場に任せたままでは普及せず、公的補助などの外部補助によって自動運転車両の台数を増やすことで、ある閾値を超えると自然に自動運転車両が支配的になる可能性を示唆することができた。

第6章では、人間の刺激に対する反応機構を包含した新たな時空間連続系自己駆動粒子モデルによる追従モデルの構築と交通流解析に関する研究を、MAS を用いて行った。第5章の自動運転車両のように、車や物流に関する技術革新は目覚ましいものがあり、そのような背景から、現実の交通流をよく再現するモデルの構築が必要不可欠なものとなっている。これまで様々な交通流モデルが提案されており、その中でも、時空間連続系のモデルとなると、多くのモデルがマクロな概念に基づくものとなっており、全体の流れ場を再現するモデルである。このモデルは、交通流を支配する数学的解析は可能だが、局所的な流れ場の再現はできず、現実の交通流を模擬したシミュレーションを行うという点では不向きである。一方、車両1台ずつに着目するミクロな概念に基づくモデルは、細部までモデル化し、シミュレーションを行うという点で向いている。しかし、これまでの多くのミクロモデルは、MAS 導入時に時間

と速度の離散化だけではなく、従属変数である空間（位置）についても離散化（超離散化）を施しており、全体の流れ場の再現という点ではある程度再現できているが、やはり局所的な流れ場の再現という点では、この離散化に伴う解像度の低さが原因で、あまり良い結果は得られていない。そこで、本章では人間の刺激に対する反応を基に確率的に速度を調節する時空間連続系の数学モデルを構築し、そのモデルを、MAS を用いて実装しシミュレーションを行い、実測データと比較を行った結果、より再現度の高いモデルを構築することに成功した。また、局所的な流れ場の再現においても、その再現度の高さがうかがえる結果を得ることに成功した。

このように MAS を通して様々なモデルの構築、解析を行ってきた。総括として、少なくとも本研究を通して、ワクチン接種ゲームや交通流に関しては、MAS は複雑社会システムを再現することができ、解析ツールとして非常に強力であるといえる。さらに、人間の刺激に対する反応を定量化する Fermi 関数や、ゲーム理論を組み合わせることで、一つ一つのエージェントがあるルールに従って動いた結果、全体に大きな影響を与える複雑な社会システムを再現できることも、改めて確認することができた。

一方で、今回の研究で扱った複雑社会システムは、人間社会の極一部のシステムにとどまっており、複雑社会システムの象徴的問題ともいえる、人間の経済活動と環境破壊の問題の解析には程遠い。この問題に関しては、それぞれの分野を極めただけでは本質的な問題を暴くことはできず、それらを包含するシステムの構築が不可欠である。経済活動は基本的に自己利益の追求であり、環境問題解決には、しばしばこの自己利益追求とは真反対のことをしなければならないことが多く、環境問題解決に取り組もうとすると、多額の費用がかかる。一方で、環境問題解決の枠組みを無視する、非協力的な集団の方が無駄な費用をかけていないため、枠組みを遵守する方と比べ、儲けることが可能となる場合が多い。そのため、社会にとっての最適行動と、個人にとっての最適行動に乖離が存在する。このように、環境問題の解決には、明らかにジレンマ構造が存在しており、この問題を解決するためには、そのジレンマ構造をより詳しく解析し、打開策を模索するほかない。

今回の一連の研究を通して、MAS にはその懐の深さが垣間見えた。MAS は、その名の通り、複数のエージェントを用意し、全体をシミュレーションするものである。また、このエージェントに対しルールを記述することで、Agent 間の相互作用の結果が全体に反映されるシミュレーションであるため、環境問題の解決に対して親和性が高いと思われる。また、ワクチン接種ゲームのように、数理疫学とゲーム理論の融合のような、異種理論同士の橋渡しも可能で、様々なことに応用が利く体系といえる。今後の展望として、ほかにも様々な人間社会のモデルを MAS によって再現し、解析することで、環境問題解決の糸口を見つけたい。

最後に、本論文が Multi Agent Simulation による複雑社会システムの解析に対し、少しでもその発展に寄与することを祈願し、総括を終える。

謝辞

学部 4 年生から現在まで、多くの方々に支えられてきましたが、指導教員である谷本潤教授に特に感謝しております。研究室の志望動機もプログラミングがしたいからという理由だったこともあり、理論は後回しで、プログラムコードを先に完成させてしまい、その体系を言語化する際、非常に多くのご助力をいただきました。また、先生の勧めで、ワクチン接種ゲームだけではなく、交通流の研究もすることができ、自分でも満足のいく成果を出せたことに深く感謝しております。また、成果という面で **Journal** 執筆が不可欠ですが、誰が筆者かわからないくらい先生にはご助力しかいておらず、本当に深く感謝しております。また、修士時代に私情による長期離脱など、勝手気ままに研究生生活を行ってきましたが、これは谷本先生だけでなく、普段の指導のみならず、研究しやすい環境をご用意してくださった萩島理教授、池谷直樹教授のご助力があったことで可能だったと思っております。改めて谷本潤教授、萩島理教授、池谷直樹教授に感謝申し上げます。

また、秘書の神田さんや吉鶴さん、専攻事務室の原さんをはじめ、そのほか多くの関係者のみなさまには、普段の生活や休学に関する手続きなど、多くの雑務をお手伝いいただいたことで、研究生生活に集中することができました。ありがとうございました。

そして、同研究グループの長島さん、立川君、二俣君、末吉君、内海君、Ariful さん、Rajib さん、Muntasir さん、Ahsan さん、Anowar さんとは研究に関し、多くの議論を交わし、ともに多くの研究成果を出すことができました。特に長島さんや立川君に感謝しており、長島さんからはプログラミングで役立つアルゴリズムをご紹介いただいたり、一緒に理論を考えていただいたりと、多くのことをご指導いただき、とても頼れる先輩でした。立川君にはスーパーコンピュータの利用にあたっての環境構築や **makefile** の作成、後輩指導を行っていただきました。二俣君や末吉君、内海君は別学府への進学や新型コロナウイルスのこともあり、あまり多くの時間を過ごすことはできませんでしたが、多くのことを学び、多くのことを議論してくれました。そして同期の江頭君、香月君、真光君、永田君、松尾君、山中君の 6 名に支えられ、研究に関し多くの刺激をもらいつつも、非常に楽しい研究生生活を送ることができました。今でも社会人としてのご活躍を聞くたび多くの刺激ややる気をいただいております。そのほかにも多くの先輩や後輩に支えられ、ここまで研究生生活を続けることができました。研究室の先輩、同期、後輩のみなさまに心から感謝申し上げます。

そして、現在所属している会社のみなさんからも、ご理解をいただき、途中何度か研究に専念させていただいたことで、無事修了を迎えることができました。ありがとうございました。

最後に、学部入学から博士課程修了に至るまで休学期間を含め 10 年間、自分のやりたいことを一切の障害なく自由にやらせてくれた両親に心から感謝し、これまで学んできたこと、経験してきたことをこれからも役立てることをここに誓い、謝辞といたします。