

VAR モデルを用いた自己駆動粒子の相互作用に関する因果分析

大山勇人¹ 下川倫子² 高見利也¹

概要: 本研究は、車、人、生物など、自己駆動粒子の数理的なモデルの構築を行うため、粒子の時系列データを分析し、相互作用の要因を特定することが目的である。今回は分析対象として、自己駆動粒子の1つである樟脳船の1次元運動に着目する。実験映像から、樟脳船の挙動に関する時系列データを取得し、時系列分析によりデータ間の因果関係の推定を目指した。時系列分析にはベクトル自己回帰 (VAR) モデルを使用した。分析の結果、データ間の因果の方向について判別することができた。

Causal Analysis of Self-driven Particle Interactions Using the VAR Model

YUTO OYAMA^{†1} MICHICO SIMOKAWA^{†2}
TOSHIYA TAKAMI^{†1}

Abstract: The purpose of this study is to analyze the time series data of particles and identify the factors of interaction in order to construct mathematical models of self-driving particles such as cars, pedestrian, and living things. In this paper, we analyze the one-dimensional motion of camphor ships, which is a model of the self-driven particles. We acquired time-series data on the behavior of camphor ship from experimental videos, and aimed to estimate the causal relationship between the data by time-series analysis. Vector autoregressive (VAR) model was used for time series analysis. As a result of the analysis, we able to identify the direction of the causal relationship between data.

1. はじめに

物理学で粒子といえば、力学法則に従い受動的に運動する質点をイメージするが、車、人、生物などは能動的に動くため慣性の法則を満たさない。このような粒子を「自己駆動粒子」という。

自己駆動粒子のモデルの具体的な例として、Boids[1]や Social force model[2]といったものがある。Boids は、鳥の群れの振る舞いを表現したモデルで、分離(Separation)、整列(Alignment)、結合(Cohesion)の3つの動作規則により群れの自然な動きを再現することができる。Social force model は、密集時の歩行者の挙動を表現したモデルであり、目的に進もうとする力、他者から受ける反発力の2つの力を見かけ上の力として仮定し、運動方程式に当てはめることで歩行者の挙動を再現したものである。

このような自己駆動粒子のモデルは、映画、ゲームのCGアニメーションとしての利用や、災害時、混雑時などの避難シミュレーションなどに応用されている。物理学の分野では、自己駆動粒子が集団運動によりパターンを出現させるメカニズムを解明する研究が、アクティブマターと呼ばれ近年盛んに行われている。また、画像認識やGPS センサの精度向上などにより、車や人の挙動データが自動的に入

手可能となれば、自己駆動粒子モデルを利用したより現実に即したシミュレーションや、逐次的に変化する状況での挙動予測の実現が見込まれる。

しかし、自己駆動粒子は運動の3法則を満たさないため定式化が難しい。これは、自己駆動粒子の数理モデル化の際の大きな問題点である。特に、粒子間の相互作用については、心理的な要因や個体差、確率などに由来することが多く、厳密な定量化を行うことが困難である。

そこで、自己駆動粒子の観測、実験の映像から粒子ごとの時系列データを取得し、統計分析を行うことで粒子間の相互作用を引き起こす要因の特定や、相互作用の定量化を行う。これにより、上述した自己駆動粒子のモデル化の問題点を解決することができるのではないかと考えている。

本研究では、分析対象として、一次元水路上の樟脳船の運動に着目する。樟脳を使った自己駆動系は盛んに研究が行われており、本研究でも実験・観測が比較的容易であるため、樟脳船を分析対象とした。今回は、樟脳船の「速度」、「前方の個体との距離」、「後方の個体との距離」の3つの時系列データに対して時系列分析を行い、速度を予測させた際の精度の評価、及び「前方」と「後方」のどちらの距離に因果関係があるのかを明らかにすることを目指す。

第2節では、本研究で使用する樟脳船の実験について説

¹ 大分大学
Oita University
² 福岡工業大学
Fukuoka Institute of Technology

明し、第3節では実験映像から時系列データを抽出する過程について述べる。第4節では、予測や因果分析に使用するモデルや手法について紹介し、5節では分析の過程、結果について述べる。最後に、第6節で結論と今後の課題を述べる。

2. 樟脳船の実験

2.1 樟脳船とは

樟脳船とは、樟脳という物質を小舟の後端に取り付けたものである。クスノキの昇華性結晶である樟脳を水面に浮かべると、昇華した樟脳分子が水中に溶解することで界面張力を変化させ、樟脳自身を運動させる。この樟脳粒をプラスチック円盤の後端に取り付けることにより、プラスチック円盤（樟脳船）は自己駆動粒子として振る舞う。また、樟脳船が自発的に駆動し、相互作用を持つという自己駆動粒子系としての特徴を持っていることから、物理的にも注目をあつめており、近年盛んに研究が行われている。

樟脳の成分は水に溶解して拡散する際、周囲の表面張力を下げる性質を持つ。図1に示すように、樟脳は船体の後端に取り付けられているため、船体後部の表面張力は、船体前部の表面張力よりも小さくなる。この表面張力差によって、樟脳船は船体前方の表面張力に引っ張られ水面上を自発的に駆動する。

2.2 実験概要

今回使用する樟脳船の実験映像は、平成29年度に福岡工業大学の卒業研究[3]で行われた実験の映像を使用する。以下に、福岡工業大学で行われた実験の概要を示す。

2.2.1 樟脳船

本研究で使用する樟脳船は、OHPフィルムを直径6mmの円盤状に切り抜いたものを船体とし、この一端に直径3mmの円盤状の樟脳粒を接着したものを使用する。図2に、実験で使用した樟脳船とその上面図を示す。

2.2.2 実験装置

樟脳船を走行させる円形水路は、大小二種類のガラスシャーレを重ねて幅12.8[mm]の水路を構成したものである。水路は、水平台上に設置して水平を確保している。また、実験の様子は実験装置の真上に設置したデジタルビデオカメラによって記録し、水平台下にはLEDライトを設置し、映像の二値化を容易に行えるようにしている。水路中の水溶液の粘度調整には、グリセリンを用いた。図3に実験で用いた円形水路、図4に実験装置全体図を示す。

2.2.3 実験手順

実験手順を以下に示す。

1. 実験にあたり、前回の実験で用いた溶液やゴミ・ホコ




図1 樟脳船の動作原理

Figure 1 Operation principle of camphor ship




図2 樟脳船とその上面図

Figure 2 Camphor ship and its top view




図3 円形水路




図4 実験装置

Figure 3 Circular waterway Figure 4 Experimental device

リなどによる僅かな表面張力の乱れが実験に影響を及ぼす可能性があるため、純水とエタノールで実験装置を洗浄する。

2. 円形水路に、表1に示す粘度の異なるグリセリン水溶液のいずれかを満たした状態にする。
3. 円形水路に樟脳船を一方方向に浮かべる。粘度毎に樟脳船の台数を5台から50台まで5台ずつ、計10パターンの実験を行う。
4. 浮かべた樟脳船全てが円形水路上を3周したことを確認した時点で、実験映像の記録を開始し、3分間記録する。
5. 撮影後、映像記録を停止する。実験装置を十分に洗浄する。

表 1 水溶液一覧

Table 1 List of aqueous solutions

水溶液	粘度 η [mPa·s]
グリセリン 20%水溶液	1.71
グリセリン 40%水溶液	3.92

表 2 実験映像の概要

Table 2 Summary of experimental video

動画時間	3 分
解像度	258 × 258
フレームレート	30 フレーム/秒
総フレーム数	5400

3. データの抽出

第 2 節で紹介した実験の映像に対して、映像解析を行い樟脳船の挙動に関する時系列データを抽出する。実験映像の概要を表 2 に示した通りである。映像解析のプログラムはすべて Python で実装した。映像解析の手順を以下に示す。また、元の実験映像を図 5 に、映像解析を行っている様子を図 6 に示す。

- (1) 実験映像を一定の閾値で二値化する。
- (2) 円形水路のみを抽出したマスク画像を用いて、不要な部分を取り除く。
- (3) ラベリング処理を行い、各樟脳にラベル番号を割り当てる。

本研究では、映像解析により以下の 3 つの時系列データの抽出を行った。

- 樟脳船の速度
- 前方の個体との距離
- 後方の個体との距離

尚、速度の算出の際、ノイズの軽減のため 10 フレーム間隔で位置座標の差分をとっている。それに伴い、前方の個体との距離と後方の個体との距離も 10 フレーム間隔で抽出を行った。そのため、実験映像の総フレーム数は 5400 であるが、分析に使用するデータ長は 540 となっている。

4. 分析方法

4.1 数理モデルと統計モデルについて

統計モデルは、対象データの生成過程を、近似した数式で表現するモデルであり、数理モデルはある現象のメカニズムを説明するために使われるモデルである。数理モデルは、現象のメカニズムについて十分調査した上で、モデルを仮定するという流れでモデル化されるが、統計モデルは具体的なメカニズムなどを前提とせず、データからモデル化される。本研究では、前提となる因果関係や具体的なモ




図 5 実験映像

図 6 映像解析の様子

Figure 5 Experimental video Figure 6 Image processing

デルをあらかじめ仮定せず、データのみからそれらを推定する必要があるため、統計モデルを用いた分析を行う。また、その結果を既存の樟脳船の数理モデルによる予測と比較を行う。

4.2 統計モデル

4.2.1 ベクトル自己回帰 (VAR) モデル

ベクトル自己回帰 (VAR) モデル[4]とは、時系列分析に用いられる代表的な統計モデルであり、ある変数を過去の自身の値の加重平均で表現する自己回帰 (AR) モデルを多変量に拡張したものである。

一次の AR モデルは AR (1) と表記され、以下の式で表される。

$$y_t = c + \phi_1 y_{t-1} + \varepsilon_t \quad (1)$$

y_t は時刻 t の時系列データ、 c は定数項、 ϕ_1 はモデルのパラメータ、 ε_t は予測残差である。また、自身の p 時点前までのデータを用いる場合、AR(p) と表記され以下の式で表される。

$$y_t = c + \sum_{i=1}^p \phi_i y_{t-i} + \varepsilon_t \quad (2)$$

この AR モデルを多変数に拡張したものが VAR モデルであり、2 つの時系列データ x , y に対する一次の VAR モデルは VAR (1) と表記され、次の式で表される。

$$y_t = c_1 + \phi_{11} y_{t-1} + \phi_{12} x_{t-1} + \varepsilon_{1t} \quad (3)$$

$$x_t = c_2 + \phi_{21} y_{t-1} + \phi_{22} x_{t-1} + \varepsilon_{2t} \quad (4)$$

AR モデルと同様に、VAR モデルも次数 p に拡張可能である。予測を行うには、ラグ次数 p と各種パラメータの推定が必要である。

VAR モデルは、通常の回帰分析と異なり、説明変数と被説明変数を区別せずに分析を行うことができるため、事前に具体的な因果関係を仮定しなくてよいのが大きな特徴である。本研究においても、特定の数理モデルを前提とせず、純粋な時系列データのみから変数間の関係を分析することができる点や、Granger 因果検定を行うことができる点に

において、時系列分析の手法として VAR モデルを利用するのが良いと判断した。

4.2.2 Granger 因果性検定

Granger 因果性検定[5]とは、ある時系列データが他の時系列データを予測するのに役立つかどうかを判断するための統計的仮説検定である。Granger 因果性検定は、通常 VAR モデルに時系列データを当てはめることで行われる。

時系列データ x , y に対し、 x から y への因果関係があるかどうか調べる時、 y のみを用いたモデルと x と y 両方のデータを含んだモデルを比較する。VAR(1)モデルの場合、次の2つの式を比較する。

$$y_t = c_1 + \phi_{11}y_{t-1} + \phi_{12}x_{t-1} + \varepsilon_1 \quad (5)$$

$$y_t = c_1 + \phi_{11}y_{t-1} + \varepsilon_2 \quad (6)$$

ここで、 ε_1 は相手のデータを利用したときの予測残差、 ε_2 は相手のデータを利用しなかったときの予測残差である。この2つの予測残差の残差平方和の大きさを比較し、相手のデータを用いることで予測残差が有意に減少したかを検定することで Granger の因果があるかどうかを調べることができる。ただし、Granger の意味での因果は、予測精度が向上するかどうかのみに着目しており、実際の因果の意味とはやや異なる。

4.3 数理モデル

4.3.1 最適速度 (OV) モデル

最適速度モデル[6]とは、坂東らによって1995年に提案された交通流を表すモデルであり、自動車の速度を車間距離によって定義したものである。複数の樟脳船を一次元の円形水路に一方方向に浮かべた際も、渋滞が発生し最適速度モデルと類似の運動をすることが先行研究[7]によって示されている。そのため、本研究では VAR モデルの予測精度の評価のため、比較対象として最適速度モデルを用いる。

最適速度モデルは、以下の基礎方程式によって表される。

$$\frac{d^2x_n(t)}{dt^2} = a \left\{ V(\Delta x_n(t)) - \frac{dx_n(t)}{dt} \right\} \quad (7)$$

a は感応度と呼ばれ、運転者の反応速度に対応するパラメータである。 V は最適速度関数と呼ばれる関数であり、車間距離に応じた速度を決定する関数である。最適速度関数は現在までに多くの関数が提案されている。本研究では、坂東らが提案した双曲線関数による最適速度関数を採用した。具体的な式は以下になる。

表 3 使用したパッケージ
Table 3 Packages used

パッケージ名	用途
vars	VAR モデル, Granger 因果検定を利用するのに使用
forecast	単位根検定を行うために使用

$$V(h) = A \left\{ \tanh\left(\frac{h-C}{B}\right) + \tanh\left(\frac{C}{B}\right) \right\} \quad (8)$$

h は前方の車両との車間距離を表している。 A , B , C は正の定数であり、推定すべきパラメータである。

5. データ分析

5.1 VAR モデルによる予測

VAR モデルのパラメータ推定を行い、得られたパラメータを用いて樟脳船の速度の予測を行った。以下に、予測の手順、結果について記述する。また、使用した R 言語のパッケージを表 3 に示す。

5.1.1 説明変数について

本来、樟脳船は、進行方向の個体と相互作用を行うとされている。しかし、本研究では前提となる数理モデルを考えず、時系列データのみから解析を行う必要があるため、説明変数として前方の個体との距離を与えた場合、後方の個体との距離を与えた場合の2つについてそれぞれ VAR モデルによる予測を行う。

5.1.2 パラメータ推定・予測方法

VAR モデルは時系列データにしか適用できないため、全ての樟脳船の時系列データに対して個別に VAR モデルのラグ次数の決定及びパラメータの推定を行った。また、時系列データを前半部分と後半部分に分割し、前半部分は VAR モデルの推定に、後半部分は予測精度のテストに利用した。尚、説明変数である前方との距離または後方との距離はすべて実際の観測値を使用するが、速度に関しては最初のラグ次数分のデータのみは実際の観測値を使用し、それ以降は過去の予測値を利用して予測を行う。

5.1.3 予測結果

構築された VAR モデルを用いて、樟脳船の速度の予測を行った。以下に、グリセリン 20%、樟脳船 35 隻の実験中の1つの樟脳船の速度を予測したものを図 7 に示す。

緑のグラフは観測値、青のグラフは前方との距離を利用し




図 7 VAR モデルによる予測
Figure 7 Prediction by VAR model

た VAR モデルによる予測値, 赤のグラフは後方との距離を利用した VAR モデルによる予測値である. 前半部分はパラメータ推定用に利用したため, 予測は後半部分から行っている. 予測精度の具体的な評価については 5.3 節で行う.

5.2 OV モデルによる予測

VAR モデルによる予測との比較を行うため, 最適速度モデルによる樟脳船の速度の予測を行った. 以下にその手順, 予測結果を示す.

5.2.1 最適速度関数への近似

映像解析によって得られた樟脳船の速度, 前方との距離の関係性について, 最小二乗法により最適速度関数への近似を行い, 3 つのパラメータを推定する. 尚, 今回は同一の粘度条件で, 実験毎に速度, 前方との距離の平均値を求め, 実験毎の平均値に対して近似を行う. 以下に, 近似の結果を示す.

図 8, 図 9 は, グリセリンの濃度がそれぞれ 20%, 40% の時のフィッティング結果を示したものである. また, 最適速度関数の 3 つのパラメータ A, B, C の値はそれぞれ表 4 のように推定された.




図 8 最適速度関数への近似 (グリセリン 20%)
Figure 8 Approximation to optimal velocity function (glycerin 20%)




図 9 最適速度関数への近似 (グリセリン 40%)
Figure 9 Approximation to optimal velocity function (glycerin 40%)

表 4 最適速度関数のパラメータ

Table 4 Optimal velocity function parameters

グリセリン濃度	パラメータ A	パラメータ B	パラメータ C
20%	0.07462	0.04637	0.00000
40%	0.03109	0.02407	0.02091

5.2.2 予測結果

近似によって得られた上記のパラメータを用いて, 各樟脳船の速度の予測を行った. 以下に, グリセリン 20%, 樟脳船 35 隻の実験中の 1 つの樟脳船の速度を予測したものを図 10 に例示する.

緑のグラフは観測値, 赤のグラフは最適速度モデルによる予測値である. 誤差の算出には, VAR モデルと条件をそろえる為後半部分の時系列データのみを利用した. VAR モデルによる予測と同様に, 予測精度の具体的な評価については 5.3 節で行う.

5.3 誤差の比較

VAR モデルによる予測誤差と, OV モデルによる予測誤差の比較結果を以下に示す. 尚, 樟脳船の速度の分布は実験毎に異なっており, 絶対誤差の大小だけでは誤差の度合いが比較できないため, 相対誤差を用いて比較を行った. 相対誤差は, 絶対誤差を実際の数値で割ったものであり, 誤差の割合を表す.

図 11, 図 12 は, グリセリン 20%, 40% 時それぞれの実験毎の相対誤差をプロットしたものである. 縦軸が相対誤差, 横軸が樟脳船の数を表している. 黒のグラフが最適速度モデル, 青のグラフが前方との距離による VAR モデル, 赤のグラフが後方との距離による VAR モデルの相対誤差

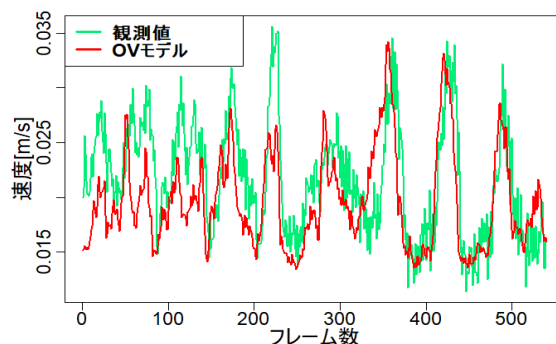


図 10 OV モデルによる予測
Figure 10 Prediction by OV model




図 12 相対誤差 (グリセリン 20%)

Figure 12 Relative error (glycerin 20%)




図 11 相対誤差 (グリセリン 40%)

Figure 11 Relative error (glycerin 40%)

をそれぞれ表している。前方との距離による VAR モデルと、後方との距離による VAR モデルの予測精度にはほとんど差が見られなかった。また、VAR モデルによる予測誤差は、一部を除き OV モデルによる予測誤差を下回っていることが確認できた。

VAR モデルは樟脳船 1 つずつ個別のモデルを用いて予測を行っているのに対して、最適速度モデルはすべての樟脳船に同一のモデルを用いて予測を行っているため、単純に比較を行うことはできない。しかし、樟脳船の運動を表すモデルの 1 つである最適速度モデルと比較して誤差が小さい場合が多く、十分に予測ができていたことが確認できた。しかし、前方との距離による VAR モデルと後方の距離による VAR モデルによる予測精度には大きな違いを確認するには至らなかった。

5.4 Granger 因果性検定

樟脳船の速度は、一般には最適速度モデルのように、前方の個体との距離に影響を受けるとされているが、VAR モデルを使った予測結果は、「前方との距離」と「後方との距離」のどちらを使って予測を行っても、結果に差が生じなかった。しかし、統計モデルを用いた予測精度の評価だけでは、実際に因果関係があるのか、単に相関があるだけなのかを判断するのは難しい。そこで、「前方との距離」、「後方との距離」と「速度」の因果関係について調べるため、Granger 因果検定を行った。以下に Granger 因果検定の手順及び結果を示す。

5.4.1 単位根検定

Granger 因果性検定は、定常過程に従う時系列データしか分析することができない、定常過程に従う系列データとは、時間によらず平均や分散などデータの水準が一定であることを意味する。したがって、分析対象のデータが非定常過程に従っている場合は、差分をとるなどの処理を行い定常過程に変換しなければならない。時系列データが定常かどうかは、単位根検定を用いて判別する。今回は、Granger 因果性検定を行う前に各時系列データに対して単位根検定

を行い、定常過程になるまで差分をとる処理を行っている。

5.4.2 Granger 因果性検定による分析方法

Granger 因果性検定は、他の時系列データを用いて予測を行った場合、予測残差が有意に減少したかを検定するものであり、帰無仮説、対立仮説は以下のようになる。

帰無仮説 : 予測残差は減少しない

対立仮説 : 予測残差が減少する

ここで、帰無仮説が棄却された場合、予測残差が有意に減少しており、Granger の因果があるとみなせる。今回は p 値が 0.05 を下回った場合に帰無仮説を棄却する。

また、今回は以下の 4 通りの因果関係に対し、Granger の因果があるかどうかを調査する。

- ① 「前方との距離」から「速度」への因果関係
- ② 「速度」から「前方との距離」への因果関係
- ③ 「後方との距離」から「速度」への因果関係
- ④ 「速度」から「後方との距離」への因果関係

①、②は「前方との距離」と「速度」に関する因果関係で、①と②の Granger 因果性検定の結果を比較することで、どちらか一方方向に因果関係があるのか、相互に因果関係があるのかを判別する。③、④についても同様である。

5.4.3 結果

以下に、Granger 因果性検定の結果を示す。尚、Granger 因果性検定は各樟脳船に対して個別に行い、実験毎に Granger の因果があるとみなされた個体の割合を集計した。

1. 「前方との距離」と「速度」の Granger 因果

図 13、図 14 は、「前方との距離」と「速度」速度の Granger 因果があるとみなされた樟脳船の割合を示したものである。縦軸は Granger 因果の確認された樟脳船の割合、横軸は実験に使われた樟脳船の数であり、青のグラフは「前方との




図 13 前方距離と速度の Granger 因果(グリセリン 20%)
Figure 13 Granger causality of forward distance and velocity (glycerin 20%)




図 15 後方距離と速度の Granger 因果(グリセリン 20%)
Figure 15 Granger causality of rear distance and velocity (glycerin 20%)




図 14 前方距離と速度の Granger 因果(グリセリン 40%)
Figure 14 Granger causality of forward distance and velocity (glycerin 40%)




図 16 後方距離と速度の Granger 因果(グリセリン 40%)
Figure 16 Granger causality of rear distance and velocity (glycerin 40%)

距離」から「速度」への Granger 因果，赤のグラフは「速度」から「前方との距離」への Granger 因果を表している。

「前方との距離」から「速度」への Granger 因果（青のグラフ）は，一部例外はあるものの基本的には，樟脳船の数が増えるほど増加していき，グリセリン 20%の場合では 20 個，グリセリン 40%の場合では 30 個でほぼ 100%の割合で Granger 因果が確認されている。一方で，「速度」から「前方との距離」への因果（赤のグラフ）は，樟脳船の数が増えるほど緩やかに増加するが，最大でも 50%までしか増加せず，「前方との距離」から「速度」への Granger 因果とは大きく乖離していることが確認された。

2. 「後方との距離」と「速度」の Granger 因果

図 15, 図 16 は，「後方との距離」と「速度」速度の Granger 因果があるとみなされた樟脳船の割合を示したものである。縦軸は Granger 因果の確認された樟脳船の割合，横軸は実験に使われた樟脳船の数であり，青のグラフは「後方との距離」から「速度」への Granger 因果，赤のグラフは「速度」から「後方との距離」への Granger 因果を表している。

「後方との距離」から「速度」への Granger 因果（青のグラフ）は，グリセリン 20%, 40%ともに，すべての実験で 100%に近い値となっている。一方で，「速度」から「後方と

の距離」への Granger 因果（赤のグラフ）は，樟脳船の数が 20~40 隻のとき 100%に近づいており，2つの値はそれほど乖離していないことが確認できる。また，樟脳船の数が 40 隻から増加すると，再び減少し始めることが確認された。

「前方との距離」と「速度」に関する Granger 因果と，「後方との距離」と「速度」に関する Granger 因果を比較すると，樟脳船が 20~40 隻場合で，「前方との距離」と「速度」は 2つのグラフは大きく乖離しているため，因果関係が「前方との距離」から「速度」への一方方向であると推測できる。一方で，「前方との距離」と「速度」は 20~40 隻の場合で 2つのグラフが 100%付近で近づいており，乖離は少ないため双方向に因果関係がある，もしくは単に相関関係があるだけである可能性がある。樟脳船 5~15 隻および 45~50 隻の場合においては，特に違いや規則性を確認することはできなかった。

6. まとめ

6.1 結論

本研究では，樟脳船の実験映像から時系列データを取得し，樟脳船の速度の予測及び，因果分析による相互作用の

要因の特定を目指した。

VAR を用いた樟脳船の速度の予測では、既存の数理モデルの1つである最適速度モデルと比較を行った。結果として、多くの場合で最適速度モデルより高い予測精度が出ていることが確認できた。また、樟脳船の速度を「前方との距離」を用いてモデル化した場合と、「後方との距離」を用いてモデル化を行った場合の2つの予測精度を比較したところ、2つのモデルの予測精度にはほとんど差がないことが確認された。

Granger 因果性検定を用いた分析では、「前方との距離」または「後方との距離」から「速度」方向への Granger 因果と、その逆向きの Granger 因果について、それぞれ樟脳船ごとに検定し、実験毎に因果があるとみなせる船の割合を算出し、比較した。結果として、「前方との距離」から「速度」方向への Granger 因果があるとみなせる割合は高いが、「速度」から「前方との距離」方向の場合は割合が低く、2つのグラフは大きく乖離していることが確認された。一方、「後方との距離」と「速度」間の Granger 因果があるとみなせる割合は、双方向で高い傾向にあり、2つのグラフの乖離は小さかった。このことから、「前方との距離」は「速度」に一方的に影響を与えている可能性が高く、「後方との距離」と「速度」は相互に影響を及ぼしている可能性が高いと推測できる。

6.2 今後の課題

今回は、実験映像から得られた時系列データに対し、VAR モデルを用いた分析や Granger 因果性検定を用いた因果分析を試みた。しかし、これらの結果を定量的に分析することはできなかった。今後の課題として、以下の2つをあげる。

1つ目は、推定された VAR モデルの解析である。本研究では、予測精度の評価と Granger 因果性検定に VAR モデルを用いたが、樟脳船ごとに異なるパラメータが推定されており、実験や個体ごとに違う特徴を持っていると考えられる。実際に、Granger 因果性検定では樟脳船の数によって結果が異なっていることが確認されている。そのため、推定された樟脳船ごとのモデルの分析、評価についても検討をしていく必要がある。また VAR モデルには、インパルス応答解析や、分散分解といった解析方法も存在するため、これらも検討する必要がある。

2つ目は、大量の時系列データを分析する手法の検討である。今回、樟脳船の時系列データを分析するにあたって、1組の時系列データに対して1つのモデルを推定するという方法をとったため、データ全体の特徴を分析することが困難であった。そのため、大量の時系列データの同時に分析を行うことができる解析方法が有用であり、主成分分析などの解析方法も検討を行う必要がある。

謝辞 本研究は JSPS 科研費 JP18K11338 の助成を受けたものです。

参考文献

- [1] Craig W. Reynolds: Flocks, herds and schools: A distributed behavioral model. SIGGRAPH Comput. Graph., Vol. 21, No. 4, pp. 25–34 (1987).
- [2] Dirk Helbing *et al.*: Social force model for pedestrian dynamics: Phys. Rev. E Vol. 51, pp. 4282 (1995).
- [3] 西尾祐司: 最適速度モデルでみる樟脳船渋滞現象: 福岡工業大学卒業研究 (2017).
- [4] 村尾博: R で学ぶ VAR 実証分析 時系列分析の基礎から予測まで: 株式会社 オーム社 (2019).
- [5] C. W. J. Granger: Investigating Causal Relations by Econometric Models and Cross-spectral Methods: Econometrica Vol.37, No.3, pp.424-438 (1969).
- [6] M Bando *et al.*: Dynamical model of traffic congestion and numerical simulation: Phys. Rev. E Vol. 51, pp. 1035 (1995).
- [7] 末松信彦: 樟脳粒の集団に現れる時空間パターン: 数理解析研究所講究録 第2063巻 pp.15-29 (2018).