

CPRC ディスカッション・ペーパー

競争政策研究センター

公正取引委員会

アルゴリズムと共謀

—経済分析のサーベイと競争政策への含意—

小田切 宏之

一橋大学名誉教授

CPDP-87-J March 2022

100-8987 東京都千代田区霞が関1-1-1

Phone:+81-3-3581-1848 Fax:+81-3-3581-1945

URL:<http://www.jftc.go.jp/cprc/index.html>

E-mail:cprcsec@jftc.go.jp

本ディスカッション・ペーパーの内容は公正取引委員会の見解を示すものではなく，文責は執筆者のみに帰する。

アルゴリズムと共謀

—経済分析のサーベイと競争政策への含意—

一橋大学名誉教授
小田切宏之

2022年3月

本研究は科学研究費補助金基盤研究（A）「データ駆動型社会の法に関する領域横断的研究—デジタルプラットフォームを焦点に」の支援を受けて実施された。研究代表者土田和博教授（早稲田大学）をはじめとするプロジェクトメンバーとの意見交換、および神戸大学イノベーション科学研究会参加者、公正取引委員会競争政策研究センターワークショップ参加者からのコメントから学ぶことが多かったことに感謝する。ただし論文中に示された見解はすべて筆者のみの責任によるものである。

要約

本論文ではアルゴリズムと共謀の関係を整理するため、寡占市場を対象に、Q 学習アルゴリズムを用いたコンピューター・シミュレーション分析、学生等を企業の戦略決定者に模しての実験分析、そして価格データを使った実証分析の 3 つの手法による経済分析をサーベイする。これらはいずれもナッシュ解すなわちクールノー・モデルやベルトラン・モデルの均衡解を上回る価格や利潤の存在を明らかにしている。ただし、行為としての共謀（すなわち企業間の意思の連絡）はなく、結果としての共謀あるいは協調にとどまる。OECD（2017）の区分でいえば自己学習型の共謀である。

さらに 2 つの示唆を得る。(1)アルゴリズム採用は、ナッシュ解が成立していた市場に協調をもたらしたというよりも、もともと協調的傾向にあった市場でそれをより容易にした可能性が高い。(2)協調解実現におけるアルゴリズムの役割を、狭義のアルゴリズム（人工知能や機械学習などを用いた最適化計算の高性能化）とデータ処理の高速化（他社価格などのデータ入手と処理の高速化・自動化）に分ければ、協調解実現により大きな役割を果たしているのは後者の可能性が高い。

最後に競争政策への含意、特にカルテル規制・企業結合規制への含意と経済分析への含意を述べる。

**Algorithm and Collusion:
A Survey of Economic Analyses and the Implications
for Competition Policy**

by **Hiroyuki Odagiri**
Emeritus Professor, Hitotsubashi University

Abstract

To inquire into the relationship between algorithms and collusion, this paper surveys recent studies employing three distinctive methodologies – computer simulations using Q-learning ML (machine learning) methods, experiments employing students as surrogates for corporate decisionmakers, and empirical analyses using price data. All these studies suggest the presence of supra-normal profits, that is, the level of profits higher than what the Nash equilibria (i.e., equilibria in the Cournot model and the Bertrand model) predict. Yet, none of them presume (or found) the presence of agreement among the competitors; that is, there is no “collusion as a conduct.” Only present is the “collusion as an outcome.” Thus, the role of algorithms in implementing collusion, if any, is “self-learning” according to the OECD (2017) classification.

Two further conjectures are made. First, probably the adoption of algorithms only facilitates and fosters the tendency for collusion that has been already there. In other words, the studies do not imply that such adoption makes a heretofore competitive market collusive. Second, generally the role of algorithms is twofold: algorithms in a narrow sense, that is, accuracy and speed in calculation and optimization; and fast data handling, that is, automatic and instantaneous acquisition and processing of data on demand conditions, rivals’ decisions, and such. Many studies suggest that the presence of collusive outcome owes more to the latter.

Finally, the paper concludes with discussions of the implications for competition policy, mainly cartel regulations and merger regulations, and to the oligopoly theory.

1. はじめに

企業の価格決定における人工知能（AI）の採用により、競争者間の価格決定における共謀あるいは協調が進むのではないかとの懸念がアルゴリズム・カルテルという言葉とともに広がり、競争政策の観点から大きな関心が寄せられている。

例えば OECD (2017)は、共謀の実行におけるアルゴリズムの役割として次の4つをあげている。

1. モニタリング

合意された共謀の実行にあたり、他社行動を監視し逸脱への報復を容易にすることで共謀を維持しやすくする。

2. 平行行動

同一アルゴリズムを競争企業間で利用したり、市場リーダーへの価格追随をアルゴリズムに組み込んだりすることで共謀を実現する。

3. シグナリング

共謀する意思を伝え、あるいは共通目的の追求を可能にするために情報を公開・伝達する

4. 自己学習

他社との相互依存関係を学習し、自社の行動を調整しつつ利潤最大化することで共謀と同じ状況を作る。

公正取引委員会の報告書（2021、以下「公取委報告書」）もこの区分を利用している。また Ezrachi and Stucke (2016)の著書『バーチャルな競争』ではメッセンジャー型、ハブ・アンド・スポーク型、予測可能な代理人型、デジタル・アイ型の4区分を用いているが、OECDの4区分にほぼ対応する。

経済学でも、人工知能（AI）の応用であるQ学習の手法を用いた最適化と市場均衡のシミュレーションにより、寡占市場においてナッシュ均衡を上回る価格が実現したとする結果が明らかにされ、競争者間での情報交換が全くないにもかかわらずカルテルと同様の結果が生じうることを示したため、アルゴリズム・カルテルの現実的な脅威が主張された。

この研究が示しているのは上記区分でいえば第4の自己学習による共謀へのおそれである。すなわち、「意思の連絡」（1995年東芝ケミカル事件東京高裁判決）があるわけでも、共通の意思決定がなされているわけでもないが、共謀と同様の結果がもたらされることへのおそれである。いわば「行為とし

での共謀」ではないが「結果としての共謀」が起きる可能性である（この区分については第2節で詳しく述べる）。

このため、競争政策として問題にすることは難しい。すなわち、OECDのあげた最初の3つのタイプの共謀は競争法上問題にしやすいのに対し、自己学習を禁止することは事業者の自主的で独立な学習や意思決定を禁止し、自由主義経済の理念に反しかねない。本稿ではこうした深い問題意識を持って、共謀が本当に起きうるのか、アルゴリズムのためなのかを考察したい。

本稿の構成は以下の通りである。次の第2節で寡占の価格理論およびカルテル理論を復習・整理することから始め、第3節で強化学習の1手法であるQ学習について概説した上で、第4節でQ学習を使ったシミュレーション分析を紹介し、共謀に類似する結果がもたらされたことを示す。しかし同様の結果は、実は被験者を用いた実験経済分析でも得られてきた。このことを第5節で実験分析のサーベイにより示す。第6節と第7節では、価格決定アルゴリズムを使ったソフトウェアやサービスの利用が価格に与える影響についての実証分析をサーベイする。最後に第8節では、これらの結果の持つ意味について、まず競争政策（カルテル規制、企業結合規制）の観点から、そして寡占理論のあり方という観点から議論する。

なお、アルゴリズムが価格決定に与える影響としては、アルゴリズムによりデータ収集され推定される消費者特性に合わせて価格差別をおこなう個別価格付け（personalized pricing）や需要条件等の変化に対応して価格を即時的に変化させる動的価格付け（dynamic pricing）の問題もあるが、本稿では扱わず、一物一価の法則が成立しているものとする。

また「アルゴリズム」という言葉そのものについては、とりあえず公取委報告書に倣い、「入力を出力に変換する一連の計算手順」と解釈しておく。後に第7節で、これはデータ入力・処理と計算・決定（狭義のアルゴリズム）に分けて考えられるべきであることを論じる。

2. 序論¹

2.1. 寡占理論の基本 — 競争解, ナッシュ解, 独占解, そして共謀解

本稿における用語を明確にするため、最初に経済学における寡占理論とカ

¹ 本節での寡占理論について詳しくは小田切（2019）の主として第3章を、カルテル理論については同書第11章を、企業の行動目的については小田切（2010）第3章を参照。

ルテル理論を復習しておこう。

寡占市場の主要モデルは、製品差別化があるか否か、すなわち財が同質的か差別化されているか、また、戦略変数が数量（通常は生産量）か価格かに応じて、表 1 の 4 モデルに分類される。

表 1. 寡占の主要モデル

財	数量決定型	価格決定型
同質財	クールノー・モデル	同質財ベルトラン・モデル
差別化	差別化クールノー・モデル	差別化ベルトラン・モデル

これらの均衡解はそれぞれクールノー解あるいはベルトラン解と呼ばれるが、いずれもナッシュ均衡の解である。ナッシュ均衡とは次のように定義される。

「ナッシュ均衡とは、相手の戦略を与えられたとき、他の戦略をとることにより有利になることがどのプレイヤーにとっても不可能であるような戦略選択をいう」(Fudenberg and Tirole, 1989, p. 266) ²。

数学的には、プレイヤー（企業など） i にとっての目的関数（利潤など）を π_i とし、戦略変数（生産量、価格など）を a_i とし、以下の関係がすべての i ($=1, 2, \dots, n$) について成立するときナッシュ均衡となり、 a_1^*, \dots, a_n^* はナッシュ解である。

$$\pi_i(a_1^*, \dots, a_{i-1}^*, a_i^*, a_{i+1}^*, \dots, a_n^*) \geq \pi_i(a_1^*, \dots, a_{i-1}^*, a_i, a_{i+1}^*, \dots, a_n^*)$$

for all a_i (1)

クールノー解もベルトラン解もこの条件を満たすから、以下、総称して「ナッシュ解」と呼ぶ。

これに対し完全競争市場における解を「競争解」と呼ぶ。競争解では価格は限界費用に等しい³。ナッシュ解が競争解に一致するのは、表 1 の同質財ベルトラン・モデルで企業間の限界費用が等しい場合、および参入障壁が全くな

² 本稿で引用する英語文献や英文ウェブサイトの日本語訳はすべて筆者（小田切）による。

³ 自然独占の場合には、市場が完全にコンテストブルであれば、均衡価格は平均費用に等しいが限界費用を上回る (Baumol et al, 1982)。これも競争解と呼ぶべきであるが、本稿では自然独占の場合を考えない。

いため企業数も内生的に決まる完全コンテストブル市場に限られ、それ以外の寡占モデルではナッシュ解における価格は競争解における価格を上回る。以下ではこの状況を考え、企業数 (n) は固定されているものとする⁴。

また、寡占市場において企業が共謀し結合利潤（全企業利潤合計）を最大化するときの解を「独占解」と呼ぼう。独占市場における利潤最大解と一致し、限界収入が限界費用に等しいように決められるから、価格は限界費用を上回る。利潤合計（産業利潤）は定義により独占解で最大となることから、次の関係が成立する⁵。

独占解 > ナッシュ解 > 競争解

同質財であれば価格についても同様の関係が成立し、産業生産量については逆の関係が成立する⁶。

このとき、市場において実現した解がナッシュ解を上回るなら、そうした解は「共謀解」と呼ぶことにしよう。すなわち利潤合計について

独占解 \geq 共謀解 > ナッシュ解 > 競争解

である。なお、企業数が異なれば、独占解や競争解は不変だがナッシュ解は変わること注意到しよう。例外的な場合を除き、企業数が少なければナッシュ解での価格は高く、利潤合計は大きい。よって、以下で紹介する多くの分析が示すように、企業数が少ないほどナッシュ解をより大きく上回る解が生じるのであれば、ナッシュ解自体が高い効果とナッシュ解からの乖離が大きい効果の両方が起きていることになる。

2.2. 行為としての共謀と結果としての共謀

⁴ 寡占モデルにおけるナッシュ解を、共謀がない場合の解という意味で競争解と呼んでいる文献もあり、本稿での用法とは異なるので注意が必要である。

⁵ なお、全企業が共謀（例えば明示的なカルテル）に参加しても、結合利潤最大化で合意できるとは限らない。企業間に非対称性がある場合、例えば A 社と B 社の間で限界費用が異なったり、差別化により製品の人気度が異なったりする場合には、結合利潤最大化での合意は困難で、優位に立つ企業（限界費用の低い企業や人気商品を持つ企業）が、共謀を成立させるために譲歩して生産量の均等化や利潤の均等化で合意することが多いという実験結果もある（Fischer and Normann, 2019）。こうした場合には結合利潤が最大化されないため、結合利潤（産業利潤）は独占解を下回る。

⁶ 製品差別化のある場合には企業ごとに価格が異なりうる。また「産業生産量」の概念が成立しない。

上記の意味での共謀解の存在は、結果としての共謀（collusion as an outcome）、すなわち、共謀が成立しているときに実現するであろうと予測される解が生じていることを意味する。これは行為としての共謀（collusion as a conduct）が成立していることを必ずしも意味しない。後者は、参加企業間でカルテル行為をおこなうことを、また、いかに実行するかを合意することである⁷。「二人以上の者が共同でたくらむこと」（『広辞苑』第5版）とされる「共謀」という日本語の本来の意味はこれであろう。

これら2つの関係を示したのが表2である。

表2. 行為としての共謀と結果としての共謀

		行為としての共謀	
		あり	なし
結果としての共謀	あり	(明示的な)カルテル 〈違法〉	暗黙の協調 〈違法性の立証困難〉
	なし	カルテル失敗？ 〈違法。ただし立証する メリットは限定的〉	ナッシュ均衡 〈違法性なし〉

(注) 〈〉内は競争法上の違法性の有無を示す。

行為としても結果としても共謀が成立している場合には明示的なカルテルであり、まさに独占禁止法上の不当な取引制限にあたるから、表の〈〉内に示したように違法性は明確である。

難しいのは行為としての共謀はないが結果として共謀が生じている場合である。暗黙の協調（tacit cooperation, tacit coordination）とか暗黙の共謀（tacit collusion）と呼ばれることが多い⁸。意思の連絡という行為がないため「他の事業者と共同して対価を決定し」等々と規定する不当な取引制限に該当しない。実務的にも会合等の証拠が存在しない。より本質的な問題として、排除措置命令で指示すべき問題解消措置が存在しない。市場で実現している価格

⁷カルテルの設立（initiation）と実行（implementation）の2段階における合意の違いを重視しているのは Green et al. (2014)であるが、ここではこの区別をしない。

⁸この場合を単に協調と呼んで共謀（行為としての共謀）と区別する文献もあるが、公正取引委員会の企業結合ガイドラインで協調的行動（coordinated conduct）という言葉が使われており、また、文献によっては共謀的結果（collusive outcome）という言葉も使われているので、区分をより明確にするため本文および表2に示す用語法を用いる。

がナッシュ解を上回っているからといって、ナッシュ解あるいは競争解の価格に下げよう命じるのであれば、それは競争政策ではなく価格統制であり、自由主義経済の根幹を覆しかねない。

ところがより頻繁に現実には起きているのは、こうした暗黙の協調である可能性がある。次節以降でこのことを、アルゴリズムによるコンピュータ・シミュレーションを使った分析や被験者を使った実験分析で見ていく。言い換えれば、アルゴリズムによる共謀が懸念されるのは、競争法上問題としやすい行為としての共謀よりも結果としての共謀である。OECDのいう自己学習による共謀である。それだけに、競争政策としての悩みは大きい。

2.3. 企業の目的関数

企業の目的は利潤流列の現在価値として定義される長期的利潤を最大化することである。この現在価値は企業価値（＝株価総額＋負債総額）に等しくなるため、その最大化は所有者である株主の利益を最大化するからである⁹。

まず、 τ 期の利潤を、その期の「状態」(state。需要条件、費用条件、過去の自社および他社の行動など)を表す s_τ と、「行動」(action。クールノー・モデルでは生産量、ベルトラン・モデルでは価格、など)を表す a_τ の関数として、 $\pi(s_\tau, a_\tau)$ と書こう。すると、 t 期についての企業価値 V_t は、

$$\begin{aligned} V_t &= \pi(s_t, a_t) + \delta\pi(s_{t+1}, a_{t+1}) + \delta^2\pi(s_{t+2}, a_{t+2}) + \dots \\ &= \sum_{\tau=t}^{\infty} \delta^{\tau-t} \pi(s_\tau, a_\tau) \end{aligned} \quad (2)$$

である。 δ は割引因子(discount factor)であり、0(将来を一切考慮しない)から1(将来への割引が一切ない)の間の値をとる。

毎期の決定が独立であれば、各期の利潤である $\pi(s_\tau, a_\tau)$ を最大化すれば V_t を最大化するから、2.1節での寡占理論で仮定されていたように毎期の利潤を最大化すればよい。ところが有形・無形資産への投資決定やカルテル行動の決定では、今期の決定が将来の利潤を変えるという異時点間の依存関係があるため、(2)式の最大化を分析する必要がある。

⁹ モジリアニ＝ミラーの定理による。株式市場では、一定の条件が満たされれば、株価総額(株式時価総額ともいう)と負債総額の合計として定義される企業価値が、利潤流列の現在価値に等しくなるように株価が決められる。株価総額＝株価×株式数であり、株式数と負債総額は過去の財務政策により既決されているため、企業価値最大化は株価最大化につながり、株主が保有する資産価値を最大化する。このため、企業が株主利益を最大化するかぎり(2)式の V を最大化する必要がある。詳しくは小田切宏之(2010)第3章参照。

(2) 式を展開すれば,

$$\begin{aligned} V_t &= \sum_{\tau=t}^{\infty} \delta^{\tau-t} \pi(s_{\tau}, a_{\tau}) \\ &= \pi(s_t, a_t) + \sum_{\tau=t+1}^{\infty} \delta^{\tau-t} \pi(s_{\tau}, a_{\tau}) \\ &= \pi(s_t, a_t) + \delta V_{t+1} \end{aligned} \quad (3)$$

となるが, 今期 a_t の行動をとり, 来期以降は最適行動をとることを前提とすれば, 企業価値を s_t, a_t の関数として, 以下のように書くことができる (s', a' はベクトル)。

$$V(s_t, a_t) = \pi(s_t, a_t) + \delta \max_{a'} V(s', a') \quad (4)$$

これはベルマン方程式 (Bellman equation) あるいはベルマンの公式 (Bellman formula) と呼ばれるもので, 第 3 節で見るとおり, Q 学習において重要な役割を果たす。

2.4. カルテル理論

カルテル理論では, カルテルから逸脱すると将来的に他社から報復を受ける恐れがあり, このため各社は逸脱するインセンティブを持たず, カルテルが持続すると考える。このインセンティブを分析するためには毎期の利潤最大化ではなく企業価値最大化を目的とする必要がある。

トリガー戦略 (a trigger strategy) モデルでは, 各期の利潤は (i) カルテルを遵守すれば $\hat{\pi}$ (単純化のため每期同一とする), (ii) 逸脱すれば $\bar{\pi}$ (逸脱によりライバルから全市場を奪うことができれば産業利潤に等しい), (iii) T 期後に他社に報復のトリガー (引き金) を引かれれば $\underline{\pi}$ (ナッシュ均衡になるのであればナッシュ解での利潤, より報復が厳しければ競争解であるゼロ利潤など) となる。 $\bar{\pi} > \hat{\pi} > \underline{\pi}$ である。すると, カルテルを遵守し続けた時の企業価値, $\sum_{\tau=t}^{\infty} \delta^{\tau} \hat{\pi}$, が, 今期逸脱し T 期後に報復を受けた時の企業価値, $\sum_{\tau=t}^{t+T-1} \delta^{\tau} \bar{\pi} + \sum_{\tau=t+T}^{\infty} \delta^{\tau} \underline{\pi}$, を上回れば, カルテル遵守が有利である。この比較から, ① $\bar{\pi} - \hat{\pi}$ (逸脱による利潤増) が小さいほど, ② $\hat{\pi} - \underline{\pi}$ (報復による利潤減) が大きいほど, ③ T が小さい (報復が素早い) ほど, ④ δ が小さい (将来利潤がより重要である) ほど, 逸脱は不利であり, このためカルテルは維持されやすいことがわかる¹⁰。

しっぺ返し戦略 (a tit-for-tat strategy) も提案されている。これは, 逸脱者の行動を他企業も追随するもので, ある企業が例えば 10% 値下げすれば, 次

¹⁰ 小田切 (2019), 第 11 章参照。

期には他社も一斉に10%値下げし、逸脱企業がカルテル価格に戻せば他社も戻すものである。分析には繰り返しゲーム理論を利用する。このとき、報復の効果はトリガー戦略よりも限定的な可能性があり、また、逸脱前後における市場価格の動きはトリガー戦略の場合よりも緩やかなものになりやすい。以下で見るように、シミュレーション分析その他において観察される価格の動きはこれに近いという結果が多い。

また、トリガー戦略では事前に報復トリガーの引き方について合意が必要であるのに対し、しつぺ返し戦略では、事前に明確に合意しなくても、各社が自然にしつぺ返しすることを予測し合えば共謀が持続する可能性がある。すなわち、行為としての共謀がなくても結果としての共謀が実現しやすい。このこともまた、シミュレーション分析等で見ていこう。

3. 強化学習の手法としてのQ学習

人工知能（AI）を用いた強化学習（Reinforcement learning）の手法の1つとしてQ学習（Q-learning）があり、この手法を用いた寡占市場のシミュレーション分析を紹介するので、その前にQ学習を説明しておく¹¹。

Q学習という言葉は目的関数として Q を用いることによる。これは次式で定義される。

$$Q_{t+1}(s, a) = (1 - \alpha)Q_t(s, a) + \alpha \left[\pi(s_t, a_t) + \delta \max_{a'} Q_{t+1}(s', a') \right]$$

if $s = s_t$ and $a = a_t$ (5)

関数の記号として V でなく Q を用いているが、(4)式により、右辺カギ括弧内は今期 a_t の行動をとり次期以降も最適化した時の企業価値と解釈される¹²。よって、これを最大化する a_t を選択すれば企業価値が最大化される。そして上式は、次期の Q が今期首の Q と行動 a_t を選択したときの Q の加重平均であり、後者へのウェイトが α であることを示す。 α は最適化行動への学習の

¹¹ Q学習については、強化学習についての多くの解説書やネット上のサイトに解説がある。以下では主として曾我部（2019）や次章で引用する Calvano et al.（2020a, 2021）や Waltman et al.（2008）における記述を参考にした。

¹² 余談ながら、企業価値をその企業の資産時価（ K ）で除した比率は、Tobin（1969）に従い、トービンの q と呼ばれることが多い。半世紀前のトービンがQ学習を知っていたとは考えられないが、 $Q/K=q$ と考えれば記号法には一貫性がある。トービンの q の投資決定や競争への意味については小田切（2010）、第3章参照。

速さを示す指標であるため、学習率と呼ばれる。

すなわち、 Q を最大化するように行動を選択していくというプロセスは、学習を繰り返しながら企業価値を最大化していくというプロセスである。それだからこそ、企業価値最大化を目的とする企業行動のシミュレーションに Q 学習のアルゴリズムが適しているのである。

強化学習の文献では、添字 t として期を示すものの、通常の経済学や会計学で考えられるカレンダー的な期（1日、4半期、会計年度など）ではなく、計算の繰り返しの1段階を意味するので、混乱を避けるため、以下では「試行」と呼ぼう。このため、これら文献では添字 t を略し、矢印「 \leftarrow 」を用いて右辺の値が左辺の値に更新されていくことを示すのが一般的である。それに従い、以下のように書こう。

$$Q(s, a) \leftarrow (1 - \alpha)Q(s, a) + \alpha \left[\pi(s_t, a_t) + \delta \max_{a'} Q(s', a') \right]$$

if $s = s_t$ and $a = a_t$ (6)

この最後の if 条件は、採択された状態と行動に該当する場合にのみ (6) 式の形での値の更新がおこなわれることを示している。それ以外の場合には Q の値は更新されない。すなわち

$$Q(s, a) \leftarrow Q(s, a) \quad \text{if } s \neq s_t \text{ or } a \neq a_t \quad (7)$$

である。

以上を例えば差別化された複占でのベルトラン・モデルにあてはめて例示しよう。企業1の行動である価格決定として、高価格 (a_1)、中価格 (a_2)、低価格 (a_3) の3つの選択肢があるとしよう。この企業の状態変数として最も重要なのはライバル企業（企業2）の決定する価格である。よって状態は企業2の高価格 (s_1)、中価格 (s_2)、低価格 (s_3) の3つとなる。すると、企業1の Q の値は次のマトリックス形式の表（ Q 表という）で示される。

表 3(a). 企業1の Q 表：一般表記

状態 (企業2の価格)	行動		
	a_1 (高価格)	a_2 (中価格)	a_3 (低価格)
s_1 (高価格)	$Q(s_1, a_1)$	$Q(s_1, a_2)$	$Q(s_1, a_3)$
s_2 (中価格)	$Q(s_2, a_1)$	$Q(s_2, a_2)$	$Q(s_2, a_3)$
s_3 (低価格)	$Q(s_3, a_1)$	$Q(s_3, a_2)$	$Q(s_3, a_3)$

簡単な例として、初期値はすべて0であるとしよう。よって、計算の初期段階ではQ表は以下のとおりである。

表 3(b). 企業 1 の Q 表 : 初期値

状態 \ 行動	a_1 (高価格)	a_2 (中価格)	a_3 (低価格)
s_1 (高価格)	0	0	0
s_2 (中価格)	0	0	0
s_3 (低価格)	0	0	0

最初の試行（試行 1）として行動 a_2 （中価格）がとられ、ライバル企業は高価格をつけたことによって状態は s_1 になったとしよう。すると、試行 2 の前には企業 1 の Q 表は次のように更新される。

表 3(c). 企業 1 の Q 表 : 1 回目試行後

状態 \ 行動	a_1 (高価格)	a_2 (中価格)	a_3 (低価格)
s_1 (高価格)	0	$Q(s_1, a_2)$	0
s_2 (中価格)	0	0	0
s_3 (低価格)	0	0	0

ただし、 $Q(s_1, a_2)$ は次の式で求められる。

$$Q(s_1, a_2) \leftarrow (1 - \alpha) \times 0 + \alpha \left[\pi(s_1, a_2) + \delta \max_{a'} Q(s', a') \right] \quad (8)$$

$\pi(s_1, a_2)$ はもちろん企業 1 が中価格、企業 2 が高価格をつけた時の企業 1 の利潤で、推定あるいは仮定された市場条件（需要関数、費用関数等）に従って計算される。以下、試行が進むにつれ行動が選択され、それに基づいて Q 表は更新されていく。試行が例えば数十万回という頻度で高速で繰り返されると Q 表の値が収束し、よって最適行動も確定してくるので、それを均衡と考える。

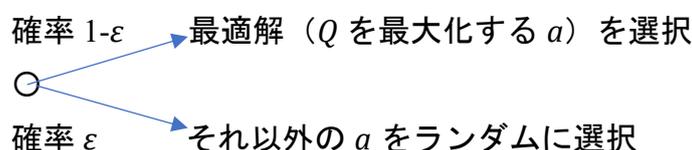
それでは、各試行において行動はどのように選択されるべきだろうか。理論的には当然 Q を最大化する行動をとるべきだと考えられよう。すなわち最適解の「利用」(exploitation) である。ところが理論とは異なり強化学習のプロセスでは、利用のみの選択には大きな落とし穴がある。潜在的にはより有利かもしれない代替的な戦略を模索せずに終わってしまうリスクである。表 3(c) の例でいえば、 $Q(s_1, a_2)$ のみがプラスの値をとり他の桁では 0 である

から、行動 a_2 が最適とみなされ、永遠に a_2 のみが選択され続け、代替的な行動が無視され続けるリスクである。

このため、短期的には不利のように見えても、他の行動を「探索」(exploration) あるいは「実験」(experiment) した方がよい可能性が高い¹³。この考え方に基づき、行動の選択に2つのモデルが提案されてきた。

第1は ϵ -greedy モデルである¹⁴。これは $1-\epsilon$ の確率で「利用」し、 ϵ の確率で「探索」するものである。探索については最適行動以外の行動をランダムに選択する形をとるものが多い。これを図示すれば図1のとおりである。

図1. ϵ -greedy モデル



ϵ の値については、0 (すべて利用) と 1 (すべて探索) の間で計算者・実験者が何らかの情報に基づいて先見的に決定したり、いくつかの代替的な値を実験したりして決められる。多くの実験によれば、0 でも 1 でもよい結果は得られず、しかも少なくとも当初は、探索に重点を置いて 0.5 を超える値にした方がより高い Q が最終的に実現される。ただし試行が繰り返されることで学習が起きると想定して、試行の繰り返しに従い ϵ が低下するようにモデル設定するのが普通である。

第2のモデルはボルツマン実験モデル (Boltzman experimentation model) である。これは次の確率により a を選択するものである。

$$\Pr(a) = \frac{\exp\left(\frac{Q_t(s_t, a)}{\beta}\right)}{\sum_{a'} \exp\left(\frac{Q_t(s_t, a')}{\beta}\right)} \quad (9)$$

$\beta > 0$ で、これは探索傾向の強さを表すパラメーターである。すなわち β が小さいほど最適解 (Q の値が大きい a) を選択する確率が高まり、大きいほどラ

¹³ 消費者行動でいえば、購入経験のあるブランドの中からベストなものを選ぶ (「利用」) だけではなく、時には他の未知のブランドもランダムに試し (「探索」)、そちらの方が良ければそれに切り替える方が長期的に有利であろう。

¹⁴ ϵ (イプシロン) 貪欲モデルあるいは ϵ 貪欲法とも訳されているが、多くの日本語文献で英語のまま使われており、これに従う。

ンダムに実験する。このモデルでも ε -greedy モデルの場合と同様に、試行の繰り返しに従い β が低下する形に定式化することが多い。実際、次節で紹介するシミュレーションモデルのいずれでも、 ε や β が低下する、すなわち探索の確率が低下し最適解がより多く利用されるように定式化されている。

4. シミュレーション分析—Q 学習の寡占市場分析への応用

この Q 学習アルゴリズムを企業行動に応用し、寡占市場の均衡でナッシュ解が実現するのか、それとも共謀解が起きるのかをシミュレーション分析する研究がいくつか発表されてきた。これらの分析では企業間での意思の連絡は仮定されていないから、起きるとすれば結果としての共謀のみである。代表的な分析として Waltman and Kaymak (2008, 以下 WK と略す), Calvano, Calzolari, Denicolò, and Pastorello (2020a, 以下 CCDP20 ; および 2021, 以下 CCDP21) を紹介する¹⁵。

いずれも需要曲線（右下がり線形）や費用関数（限界費用一定）についての仮定を置き、同質財のクールノー・モデルあるいは差別化されたベルトラン・モデルを採用する。よって Q 学習における行動として前者では生産量、後者では価格の決定がなされる。ただし Q 学習の手法を適用するため、これら変数は連続変数ではなく有限の選択肢に分割される。例えば CCDP20 では企業が取りうる価格の上限と下限を計算し、これらの間を 100 分割して、そのいずれかを企業は選択する。よって、Q 表は 100×100 の枱を持つ。100 の選択肢の中からいずれかを選択するという行動を産業内全企業が決めれば、仮定された需要関数と費用関数から各社の利潤が決まり、次の試行に進む。

企業が行動を決定するにあたり状態として与えられる情報については、前期までの自社および他社の生産量あるいは価格が中心となるが、どれだけの変

¹⁵ Q 学習を用いたシミュレーション分析としては他にも Johnson et al. (2020, メーカー・消費者間に小売プラットフォームが入り、最安値のメーカーの商品のみ扱う), Klein (2021, 価格決定が企業間で逐次的になされる), Abada and Lambin (2021, 電力市場を例にとり発電能力の制約ありとする) があるが、それぞれかつこ内に記したように特定の状況を扱っており、ここでは標準的な寡占市場についての分析である WK と CCDP に限定する。また Asker et al. (2021) は、より一般的な強化学習の手法を用いてシミュレーション分析しており、Q 学習に当たるケースでは WK や CCDP と同様の結果を得ている。ただし、同質財市場のベルトラン・モデルで非弾力的な需要（すべての消費者の留保価格は等しく、それを超える価格では需要ゼロ、それ以下の価格では需要量一定）という限定的な仮定に基づいた分析である。

数についての情報があるか、個別のライバル企業の情報が与えられるか市場全体の情報のみか、また何期前までの情報を参照できるか（メモリ一期間という）などにつき、論文により違いがある。

1つのシミュレーション計算（「セッション」と呼ぶ）では試行をQ表の数値が安定するまで続けるのが基本である。例えばCCDP20では、10万回の連続する試行の間に数値が変わらないようになれば安定したとみなすため、全体として数十万回の試行を実行している。またWKでは100万回試行している。この安定した値（価格、生産量、利潤など）をそのセッションの結果として採用する。こうしたセッションを一定数（例えばCCDP20では1,000セッション）実施し、その平均値等を分析結果とする。また、企業数を変えたり、市場条件に関するパラメーターを変えたりして同様の分析をおこない、比較することで、企業数やパラメーターの影響を分析する。

以上の基本的枠組みは同じであるが、分析フレームワークや結果には違いもあるので、3論文を比較したのが表4である。いずれも利潤をナッシュ解や独占解と比較するため、次の指標を用いている。

$$\varphi_{profit} = \frac{\pi - \pi^N}{\pi^M - \pi^N} \quad (10)$$

ただし π は産業利潤（全企業利潤合計）で、上付き添字はNがナッシュ解、Mが独占解を示す。よって φ_{profit} は、シミュレーション結果の産業利潤がナッシュ解と一致した時に0、独占解と一致した時に1の値をとる。その中間的な値、すなわち1よりは小さいがプラスなら、共謀解が結果として実現していると解釈されることになる。

表 4. Q 学習を用いた 3 つのシミュレーション分析

		WK	CCDP20	CCDP21
市場	差別化	なし	あり	なし
	モデル	クールノー	ベルトラン	クールノー
	需要と費用	線形需要曲線, 限界費用一定	同左	同左。需要曲線はランダムにシフト
Q 学習モデル	行動	生産量	価格	生産量
	企業に与えられる情報(当該企業が認知する「状態」)(注 1)	前期の自社生産量および総生産量	前期の全社の価格	前期の自社生産量および価格
	行動選択方式	ボルツマン	ϵ -greedy	同左
結果	φ_{profit}	0 と 1 の間	同左	同左
	カルテル・モデルとの相違点・共通点(注 2)	逸脱・報復のメカニズムが働いているわけではない①	逸脱・報復のメカニズムが機能している可能性②	同左③
	企業数 (n) 増加の産業変数への影響 * $n=2 \rightarrow 3 \rightarrow 4$ による φ_{profit} の変化(注 3)	生産量 \uparrow , 利潤 \downarrow の傾向。 *0.83 \rightarrow 0.76 \rightarrow 0.60	利潤 \downarrow の傾向。 *0.85 \rightarrow 0.64 \rightarrow 0.56	利潤 \downarrow の傾向。 *0.75 \rightarrow 0.73 \rightarrow 0.67

(注 1) 1 期メモリーのケース。WK および CCDP20 では 0 期メモリー, すなわちメモリーなしの場合も分析している。

(注 2) ①②③については本文参照。

(注 3) 引用した数値は $\alpha=0.5, \delta=0.9$ (WK), $\alpha=0.15, \delta=0.95$ (CCDP20, CCDP21) の場合。ただし α は学習率。 δ は割引因子。

結果は3点にまとめられる。

第1に、 φ_{profit} はいずれの分析でも0（ナッシュ解）より大きく1（独占解）より小さい。よって結果としての共謀解が実現している。しかも複占（ $n=2$ ）では、いずれの分析でも0.8前後の値を取っているから、ナッシュ解より独占解に近い利潤を実現している。ただし、あくまでも企業ごとに決定がなされており、企業間での共同決定や連絡は皆無であるから、行為としての共謀はない。このことについては後述する。

第2に、2.4節で述べたような逸脱・報復のメカニズムが機能しており、このためにナッシュ解を上回る利潤が実現しているといえるだろうか。この問いへの答えについては、表4の下から2段目に①②③として示されているように3論文で分かれる。

- ① WKは否定する。これは彼らが近視眼的（myopic）と呼ぶ $\delta=0$ のケース、すなわち企業が短期的に行動し、将来利潤への影響を無視するケースでも φ_{profit} がプラスだからである。
- ② CCDP20は肯定的である。セッションでの価格の動きを見ると、ある企業が価格を下げると次の試行期で他社も下げ、その後徐々に安定解に近づくという、しっぺ返し戦略と類似する傾向が見られるからである。
- ③ CCDP21も肯定的である。ある試行期に*i*社生産量を外生的に増加させると次期に*j*（ $\neq i$ ）社は生産量を増加させる。*i*社は前期よりは減らすが長期安定解よりは多い。試行が繰り返されるにつれ、両社生産量とも安定解に近づく。これはしっぺ返し戦略に類似した動きだからである¹⁶。

繰り返すが、②や③でも、逸脱への報復を企業間で合意しているわけではない。あくまでも各社の自主的な行動である。

第3に、表4の最下段にあるように、いずれの分析でも企業数が2社から3社、4社へと多くなるにつれ、 φ_{profit} は低下する。すなわち、企業数の多さは実現する利潤を独占解からナッシュ解に近づける効果がある。しかも2.1節で述べたように、企業数が多ければナッシュ解での産業利潤（ π^N ）自

¹⁶ 筆者らは、各社が価格変化を観察した時にそれが需要変動のためか他社逸脱のためか不確定だという状況で報復していると考えられるため、Green and Porter (1984)のモデルと共通するとしている。

体が低いから、 π^N の低さとそれからの相対的乖離 (φ_{profit}) の小ささという二重の意味で産業利潤が低いことになる。

さらに5社、6社へと多くなったときの効果についてはWKのみが分析しており、それによれば、表4と同じ条件では φ_{profit} は5社・6社でむしろ増加、産業利潤は5社で減少・6社で増加、他の条件（メモリーなしなど）では増加も減少もあるなど、企業数の効果は一定しない。

これら分析、特にCCDPの結果は、ナッシュ解より高い価格と高い利潤を実現していること、また逸脱・報復のメカニズムと思われる現象が見られることから、Q学習というアルゴリズムが共謀を生んでいると解釈されがちである。筆者らも「分析結果は、比較的単純な価格決定アルゴリズムが共謀を系統だって学習することを示している」(CCDP20, p. 3268)と結論している。ただし、筆者らは続けて「アルゴリズムはこれら戦略を純粋に試行錯誤によって学ぶ。共謀するよう設計されているわけでも指定されているわけでもなく、お互いに意思疎通することもなく、また、実行している環境についての事前の知識を持っているわけでもない」とも記している。

つまり、これら分析は、各社の行動と市場均衡をアルゴリズムで模写すると共謀解が現出するものの、それはあくまでも結果としての共謀であり、行為としての共謀なく生まれていることを示している。この意味で、これら分析結果がアルゴリズム・カルテルの必然性を証明しているとして、競争法上問題にすべきだと直ちに論じるのは誤解を招きやすい。むしろ、各社が独立的に行動していても結果としての共謀、すなわち暗黙の協調を避けられないおそれを指摘していると解釈した方がよい。

それでは、こうした結果はAIとアルゴリズムがもたらしたものといってよいのだろうか。この疑問を次に考えよう。

5. 実験分析—実験経済学手法の寡占市場への応用

実はAIもアルゴリズムも用いず人間を被験者として寡占を分析した実験研究でも、前節と同じ結論、すなわち結果としての共謀の出現が報告されている。

本節で取り上げるのはHuck, Normann, and Oechssler (2004, 以下HNO) およびHorstmann, Krämer and Schnurr (2018, HKS)の2つの論文、3つの分析(HKSは2つのモデルを含むため)である。HKSには先行研究12編のサーベイおよびメタ分析も含まれており、これら先行研究もHNOやHKSと共通

した分析結果を多く得ていることを明らかにしているため、ここでは2論文に限定して紹介する。

HNO, HKS およびほぼすべての先行研究に共通する分析手法を先にまとめておこう。

- 学生アルバイトを被験者として募集。 n 社寡占の分析では n 人を対象とし、これを設定された状況（企業数 n は何社か、生産量決定型か価格決定型か、企業間で対称か非対称か、など）ごとに数十組実施。
- それぞれの実験で、1人ごとブースに入りコンピューターを操作。被験者間のコミュニケーション禁止¹⁷。
- 完全情報の実験では、最初に費用条件（例えば一定の限界費用）、市場需要（例えば線形の需要曲線）、ライバル数の情報を与えられる。これらを与えない不完全情報のケースを実験している論文もある。
- 被験者は每期（前節でいう「試行」ごと）に自社の行動（生産量または価格）を決定し入力。コンピューターからその期の市場価格（差別化モデルでは各社価格）、あるいは各社生産量または総生産量、および自社利潤がフィードバックされる。次期へ移行。これを数十期から数百期にわたり実験¹⁸。
- 最終期（あるいはそれまでの数期の平均）の利潤に比例する形でアルバイト料が支払われる。HKSでは約1時間の仕事で20ユーロ程度。

この下での分析結果をまとめたのが表5である。

¹⁷ Fischer and Normann (2019)のように、コミュニケーションを許す実験も実施してコミュニケーション禁止の場合と比較したり、参加者間でどのように合意が形成されるかを分析したりする研究もある。

¹⁸ 1200期まで実験した分析（Friedman et al, 2015）もあるが、前節で紹介したQ学習アルゴリズムを用いたシミュレーション分析では数十万期や100万期にわたる試行をしていたことを考えれば、人間を対象とした実験と比較してのコンピューター・シミュレーションの有利性が示唆される。ただしこの違いは、結果が収束するのが実験の方が早いためでもあるので、いずれがより正確な分析というわけではない。実験では被験者は開始前に実験のセットアップについての説明を受けること、またおそらくは実生活でも類似した行為をする体験をしていることなどから、収束が早いものと想像される。

表 5. 寡占市場の 3 つの実験分析

	HNO (クールノー)	HKS (クールノー)	HKS (ベルトラン)
市場モデル	同質財, 生産量決定	差別化, 生産量決定	差別化, 価格決定
2社複占均衡の特徴 (注)	ナッシュ解より生産量が小さい $r=0.91$	ナッシュ解より生産量小さく価格高い $\varphi_{price}=0.627$	同左 $\varphi_{price}=0.832$
3社→4社に増えると	$r: 0.98 \rightarrow 1.02$ ナッシュ解 ($r=1$) と有意な差なし, かつ 4社以上ではナッシュ解より大	$\varphi_{price}: 0.397 \rightarrow 0.166$ ナッシュ解より価格高く, 3社→4社で価格下がる	$\varphi_{price}: 0.605 \rightarrow 0.436$ 同左
企業間の非対称性あり (1社のみ需要曲線が上方に位置)			3社→4社で $\varphi_{price}: 0.332 \rightarrow 0.201$

(注) $r = \frac{Q}{Q^N}$, $\varphi_{price} = \frac{p-p^N}{p^M-p^N}$, ただし Q は産業生産量, p は価格, 添字 N はナッシュ解, M は独占解。

表 5 に明らかなように, 2 社複占の場合, いずれのモデルでも, 実験結果をナッシュ解と比較すると生産量は少なく価格は高い。クールノー型のセッティングで実験した HNO によれば, 生産量はナッシュ解より 9% 低く, HKS によれば, 価格についての比率である φ_{price} について, 差別化された市場での生産量決定型で 0.627, 価格決定型で 0.832 という結果を得た。すなわち価格は独占解よりは低いですがナッシュ解を上回る。前節の WK や CCDP では利潤についての比率 (φ_{profit}) を使っており, そのまま比較することができないが, いずれにおいても結果は 0.8 前後といったナッシュ解より独占解に近いものとなっており, Q 学習アルゴリズムを使ったシミュレーション結果と実験分析による結果とは類似していると考えられる¹⁹。

¹⁹ Werner (2021) は同一モデルで Q 学習によるシミュレーションと被験者による実験の双方の分析を実施して結果を比較している。それによれば, いずれでも共謀解が生じ, 企業数 2 社ではシミュレーションの方が高価格になる, しかし 3 社では実験の方が高価格の場合もあるという結果を得ている。また同じ市場に Q 学習により意思決定する企業と被験者が意思決定する企業が混在する場合も分析している。ただし, 注 15 に引用した Asker et al. (2021) と同様に, 非弾力的需要の同質財ベルトラン・モデルという限定的な状況を扱っており, 本文で紹介した分析とそのまま比較することはできない。さらに, Q 学習での割引因子 δ と, 実験分析で次期に実験が継続する確率 ($1-\delta$ の確率で実験はその期で終了) を同等視するな

言いかえれば、Q学習アルゴリズムの導入が結果としての共謀を生んだわけではない。実験でもシミュレーションでも、すなわちコンピューターによるアルゴリズム利用の有無にかかわらず、結果としての共謀が多く現出したという事実が重要である。このことはナッシュ均衡を前提としてきた寡占理論が現実市場を正しく捉えてきたかについて疑義を投げかける。最終節でこの疑問に立ち戻ることにしよう。

表5はまた、企業数が3社、4社と多くなった時の変化についてまとめているが、この点については2つの研究が異なった結論を得ている。HNOは、2社では生産量が有意にナッシュ解を下回るのに対し、3社では増加しナッシュ解と有意に異ならず、4社では非有意ながらナッシュ解を上回るとする。このため、同論文は「2社は少ないが4社は多い」のタイトルを持つ。これに対しHKSは、2社から3社、4社と多くなるにつれ価格は低下を続けるものの、それでもナッシュ解を上回るとの結果を得ている²⁰。

また表5の最下段に示すように、HKSは差別化された寡占で製品間の人気度に非対称性がある場合も分析しており、 φ_{price} は対称な場合に比較して低く、ナッシュ解に近づくこと、また対称な場合と同様に、3社から4社に増えると φ_{price} が低下することを明らかにしている。この結果は、企業間の対称性が協調を生みやすいことを示唆している。分析は需要条件の対称性についてなされており、費用条件や企業規模などの対称性の効果について立証しているわけではなく、一般化はできないが、企業間の対称性が協調を生む可能性を示唆する。

6. 実証分析—価格決定アルゴリズム導入の価格への影響

それでは、現実において、価格決定アルゴリズムの導入は価格を上昇させたのだろうか。Assad, Clark, Ershov, and Xu (2021, 以下 ACEX)は筆者の知る限り唯一の実証分析である。分析対象はドイツのガソリン小売事業者（service station を略して以下 SS）で、同業界では2010年ごろからソフトウェア提供やそれを用いたサービス提供の専門事業者（以下「アルゴリズム提

ど、シミュレーション分析と実験分析が完全に比較可能かについて疑問が残る。

²⁰ HKSは、先行研究の多くがHNO同様の結果を得ているとして、自身の結果の新規性を主張している。

供者」と呼ぶ) が提供する価格決定アルゴリズムを使う SS が増えてきたという。

この実証分析に入る前に、その背景として 2 点を重視したい。

第 1 は、価格情報の入手可能性、またその迅速性が高まったことである。ACEX が対象としたドイツでは、価格の透明性を高める必要があるとして、2013 年にカルテル庁の中に燃料市場透明性ユニット (German Market Transparency Unit for Fuels) が設けられ、SS は価格を変えるごとに即時的に新しい価格を届けることを義務付けられた。このデータは同ユニットから多数の消費者情報提供民間事業者提供され、一般消費者はこれら事業者のサービスを通じて見ることができる。ACEX はこの価格データを用いて実証分析しているが、同様にアルゴリズム提供者も、同データを用いることでアルゴリズムを十分に生かすことができるようになった。

こうした価格データの透明性・迅速性は協調的な価格決定を促進する可能性がある。2.4 節で見たように、共謀が明示的なものであれ暗黙のものであれ、逸脱への報復が迅速になされる可能性は逸脱を抑制する効果があるからである。同ユニットのホームページは、「モータリストたちが価格情報を入手できるようになることで、最も安い SS を探し出すことを容易にし、(中略)、競争を促進する」²¹ことを強調しているが、逆に共謀を容易にする可能性にも留意する必要がある。

第 2 は、アルゴリズム提供者が複数存在していることである²²。どのサービスをどの SS 事業者が利用しているか、またいつから利用しているかは公表されていない。このため、(1) 競合関係にある複数事業者が同じアルゴリズム提供者のソフトウェアあるいはサービスを利用している可能性、(2) アルゴリズム提供者間で顧客 (SS 事業者) 獲得競争が起きている可能性が、共に存在する。すると、アルゴリズム提供者間で、自社アルゴリズムを顧客にとって魅力的なものにするため、自社顧客 SS 間で価格を調整して SS の利潤を高めるようにするという形の競争が発生することが理論的には予想される。これは、アルゴリズム提供者をハブとするハブ・アンド・スポーク型の共謀を

²¹ https://www.bundeskartellamt.de/EN/Economicsectors/MineralOil/MTU-Fuels/mtufuels_node.html (2022 年 1 月アクセス)。

²² ACEX はアルゴリズム提供者として 4 社を例示しており、これらについての情報は補論にまとめた。

生むであろう²³。ただしハブは1つではない。すなわち、アルゴリズム提供者は複数あるから、彼らの間での協力行為がない限り、自社サービス利用者間のみで価格調整することが有利かどうかについては疑問が残る。

こうした考慮を踏まえた上で、ACEXの分析の内容に入ろう。

分析は2段階よりなる。第1段階では各SSのアルゴリズム採用時期を推定し、第2段階で、この採用以降に価格が変化したかどうかを分析する。彼らが中心的に用いるデータは、上記したドイツ・カルテル庁燃料市場透明性ユニットが公表しているSSごとの日次の価格データである。分析サンプルとなるSSの数は16,027に及ぶ。また、この価格から地域ごとの卸売価格（石油会社出荷価格）を引いた価格マージンのデータも用いる。

分析では地域特性も考慮するため、5ケタ郵便番号レベルで5,781の地理的市場に分けるが、2,094(36%)の市場で独占（すなわち1SSのみ）、1,307(23%)で複占（2SS）と6割近くの市場でSSは1ヶ所あるいは2ヶ所に止まる。

分析対象とした時期は2016年1月から2018年12月である。この期間に価格決定アルゴリズムが多くのSSで採用されるようになったことは知られているが、SSごとの採用時期は不明なため、これを分析の第1段階として推定する必要がある。このためにACEXは3つの指標に注目する。①価格変化の回数、②価格変化の幅、③ライバルへの価格反応時間、すなわちライバルSSが価格変化させてから自SSが変更するまでの時間、の3つである。それぞれについてSSごとに有意な変化が起きた時期をF検定により決定し、少なくとも2つの指標について4週以内に有意な変化が起きていれば、その月を価格決定ソフトウェア採用月と認定する。この結果、3,323(21%)のSSが分析期間内に採用したと認定された。

その上で、分析の第2段階として、採用後に価格あるいはマージンが上昇したかを検定するため、これら変数を採用ダミー（採用後のSSにつき1の値をとるダミー変数）に回帰する²⁴。いわゆる差の差分析(difference in difference)

²³ Ezrachi and Stucke (2018)。またOECD (2017) のいう平行行動による共謀もこれにあたる。こうした共謀の理論的分析として、アルゴリズム提供者が1社のみケースについてはHarrington (2021)がある。競争政策上は、こうした行為を競争法上違反とできるのか、独占禁止法でいえばどの条文を適用可能か、違反行為の実施者とされるのはアルゴリズム提供者かSS事業者か、について法的および実務上の問題がある。

²⁴ なお採用決定が内生変数である可能性を考慮し、SSごとの採用週をブランド・レベルでの採用比率（ブランド傘下での採用済みのSSのシェア）にまず回帰させる2段階最小二乗

である。この結果、採用は価格にもマージンにも有意なプラス効果があることがわかった。例えばマージンは採用後に 0.8 セント（9%）増加すると推定された。

また地理的市場の競争状況に応じて効果には差があることも示された。独占市場に限定して推定すると効果は非有意であった。競争が存在した市場でのみ、採用による価格上昇効果が起きていることになる。また複占市場に限定して分析すると、2社とも採用した時にのみ有意なプラス効果があることも示された。また採用後 6 ヶ月以内、7~12 ヶ月、12 ヶ月以上と 3 つの期間を分けると、採用による価格上昇効果は期間が経つにつれ徐々に大きくなることがわかった。これはアルゴリズム自体にも学習が必要であるためと筆者らは解釈する。

このように、複占市場で両社ともアルゴリズムによる価格付けを採用すると価格が高止まりする傾向が生まれることがわかったが、こうした傾向をもたらすメカニズムは何か。これを探るために、ACEX はライバル企業の価格変化への反応（5分以内の追随）の確率を価格上げと価格下げに分けて推定した。その結果、ライバル企業の価格下げへの反応の確率は有意にプラスであったが、価格上げへの反応確率は有意でなかった。この結果から筆者らは次のように結論する。「アルゴリズムは価格下げに対し自らの価格下げで対抗する。これによって、価格下げは常にライバル企業の価格下げで追随されるので利益にならないことをお互いに教えるのである。」（ACEX, p. 38）

7. 実証分析—追加的検討

ACEX のこの引用文は OECD のいう自己学習型の共謀を示唆する。ただし、ACEX の分析結果をもとに価格決定アルゴリズムの採用が共謀を生んだと結論するには、さらに 2 つの観点からの検討が必要である。第 1 は、採用以前には行為あるいは結果としての共謀はなかったといえるのかどうかである。第 2 は、価格決定アルゴリズムの採用がもたらした効果はアルゴリズムそのものにより生まれたのか、あるいは、同時に価格情報が利用容易になったことにより生まれたのかである。

最初の疑問に対しては、実はもはや古典ともいえる実証分析がある。Slade (1987) である。これはカナダではあるが同じくガソリン小売業 (SS) について

法を用いて推定している。

の研究である。分析対象はバンクーバー市内キングスウェイ地区の 13SS（10社）で、地理的に同地区は 1 つの市場とされる。彼女は 3 ヶ月間のガソリン価格と販売量のデータを SS オーナーの協力を得て収集しているが、1983 年なのでもちろん手作業で収集したアナログなデータである。

SS は立地等で差別化されており、価格決定型モデルを用いる。価格と販売量のデータより各 SS の需要関数を SS 間の相互依存関係を認識しつつ推定し、これと限界費用（ガソリン仕入価格）をもとに計算すれば、他 SS 価格の関数として自 SS の利潤を最大化する価格が決まる。これは価格についての各社の反応関数にあたる。ベルトラン均衡を想定し、13SS の反応関数を連立して解くことで（図形的には反応曲線の交点として）、ベルトラン解すなわちナッシュ解を求めることができる。

Slade は実際の価格や利潤がこのナッシュ解を上回ることを発見した。ただし独占解よりは小さい。さらに、価格データより反応関数を直接推定すると、他 SS 価格への反応はベルトラン・モデルから計算される反応より大きく、逸脱・報復のメカニズムが働いているためと解釈されるが、その報復はトリガー戦略が示唆するようなナッシュ解（あるいは競争解）へのジャンプではなく、より小幅な連続的な動きであることもわかった。

この結果をどれだけ他国・他年代に一般化できるかはもちろん不明であるが、アルゴリズムやデータが機械的に利用可能になる以前から、ガソリン小売市場において、結果として共謀とも解釈できる価格決定がなされていた可能性を示唆する。この意味では、Q 学習によるシミュレーション分析や実験分析における結果と共通している。

第 2 の疑問、すなわち変化の要因はアルゴリズムかデータかについても参考になる実証分析がある。Byrne and De Roos (2019) である。これはオーストラリア・パース市でのガソリン市場の分析であり、同市では毎日、すべての SS のガソリン価格の届出が義務付けられており、即日公表される。この日次・SS ごとの価格データを用い分析することで、毎週木曜に価格がジャンプ（価格上昇）し、続く 1 週間のサイクルで徐々に価格低下、また次の木曜にジャンプというパターンが安定的なこと、このパターンができる前には最大手の BP が最初は水曜にジャンプ、翌日より他社追随というパターンを実験しながら作り、後に BP も木曜にジャンプするようになり、他社は同時にジャンプするが、ジャンプ幅が異なれば翌日、翌々日などで修正して BP に合わせていく、という行動様式ができあがったと論じている。よって、カルテルというより

BP をリーダーとするプライス・リーダーシップで、その確立に価格公表が貢献した可能性を示唆している²⁵。

これらを総合して考えると、上記した2つの疑問への答えとして次の示唆を得る。第1は、アルゴリズム採用は、ナッシュ解が成立していた市場を協調的にしたというよりも、もともと協調的傾向があった市場でそれをより容易にした可能性が高いことである。第2に、アルゴリズム採用により、AIやMLを用いた最適化計算の高性能化という機能と同時に、オンラインを通じた他社価格や原材料価格等についてのデータ入手と処理の高速化・自動化という機能の双方が実現することが期待される。前者を狭義のアルゴリズム（計算式・計算手順といった意味の本来の「アルゴリズム」に該当²⁶）、後者をデータ処理の高速化と呼ぼう²⁷。すると、双方ともに協調的傾向の容易化に貢献したことは否定できないものの、価格公表のみでもこの傾向を促進したとする分析結果があることを考えると、データ処理の高速化がより根本的な要因ではないかと推測される。

これは、寡占市場分析のあり方について、また競争政策のあり方について、新しい見方が必要であることを示している。次の最終節ではこのことを論じよう。

8. 寡占理論と競争政策への含意

本論文はアルゴリズムと共謀の関係を整理するため、Q学習アルゴリズムを用いたコンピューター・シミュレーション分析、学生等を企業の戦略決定者に模しての実験分析、そして価格データを使った実証分析の3つの手法による経済分析をサーベイした。分析結果を解釈するにあたっては、行為として

²⁵ ガソリン市場以外では、デンマークの生コン市場で、競争当局が事業所ごとの価格データを報告させ公表するようになってから実勢価格が19%上昇したことを実証した分析（Albæk et al, 1997）、米国のオンライン一般医薬品市場（よって価格データは即時的に入手可能）で、5社のうち価格改定頻度が少ない販売サイトが価格決定における事実上のシュタツケルベルグ・リーダーとなり、ベルトラン解を上回る価格が実現していることを実証した分析（Brown and MacKay, 2021）がある。

²⁶ Algorithm の語源については例えば仏独当局の報告書（Autorité de la Concurrence and Bundeskartellamt, 2019）、p. 3, note 8 参照。

²⁷ 公正取引委員会報告書（2021、図表5）は価格調査アルゴリズムと価格設定アルゴリズムを区別している。前者はデータ処理の高速化に、後者は狭義のアルゴリズムに該当するとみられる。

の共謀と結果としての共謀を区別すべきことを強調した。その上で、そうした共謀が存在するなら、それはアルゴリズムのために実現したものかどうかを問うた。

最後に、まとめとして、これら分析からの含意をカルテル規制、企業結合規制、問題解消措置、そして寡占理論に分けて整理しよう。

8.1. カルテル規制への含意

実験やシミュレーションでナッシュ解より高い価格や利潤が実現しやすいこと、また実証分析のいくつかで現実の価格や利潤がナッシュ解を上回ると推定されたことは、結果としての共謀が実現していることを示唆する。ただし、実験でもシミュレーションでもプレイヤー間の連絡は禁止されており、行為としての共謀ではない。シミュレーションで用いられた Q 学習アルゴリズムでは、各社は過去のライバル企業の決定についての情報を状態として与えられるが、あくまでも自社企業価値にあたる Q 関数を最大化すべく学習し決定する。よって、それぞれ独立の意思決定者の決定プロセスを模し、あるいは手助けをするものであり、コンピューターは各社のそうした行動をもとに市場均衡を計算し、各社の Q 表にフィードバックする。実験分析でも、学習し決定するのが人間になるだけで基本は変わらない。ACEX のドイツ SS 市場の実証分析でも、SS 間でカルテルが起きたとはされていない。競合する SS が同一アルゴリズム提供者のサービスを受け、それがハブとなってハブ・アンド・スポーク型のカルテルが起きている可能性を否定はできないものの、すべての SS がアルゴリズムを採用したわけでも、すべての採用者が同じアルゴリズムを採用したわけでもない。

この意味で、共謀解の発生は、OECD の表現を使えばあくまでも自己学習によるものである。あるいは仏独報告書の表現を使えば「協調というよりも市場への知的な適応」によるものである²⁸。もちろん、データ処理の高速化が自己学習や市場への知的な適応を迅速におこなうことを容易にした可能性や、互いの行動の予測を容易にすることによって協調への学習を迅速化した可能性は残る。価格決定アルゴリズムの採用は、同時にオンライン接続によるデータ取得の高速化と計算力の飛躍に繋がったからである。Q 学習のシミュレーションで、ライバル企業の行動や市場状況がフィードバックされ、それが

²⁸ OECD (2017), pp. 30-32; Autorité de la Concurrence and Bundeskartellamt (2019), p. 60.

数十万回にわたり高速で繰り返されたことを見ても、それに伴い協調への学習（「市場への知的な適応」）も急速になされたであろうと推測される。

このため、今後、経済のデータ化、オンライン化と機械学習の高速化に伴い協調的な傾向が強まる可能性は十分に存在する。いうまでもなく、消費者の立場に立てば、あるいは社会的余剰の最大化という観点に立てば、これは憂えるシナリオである。ただし競争政策にとっては大きなジレンマである。現行の競争法の考え方のもとでは、これはカルテル（独占禁止法でいう「不当な取引制限」）でなく違法ではない。

それでは、共謀解の出現を防止するために価格決定アルゴリズムの利用を禁止し、あるいはデータ処理の高速化を禁止すべきだろうか。それは明らかに誤りであろう。オンラインでのデータ取得を禁止しマニュアルで価格を調べたり、需要条件や費用条件の変化に伴い迅速におこなう必要のある価格変化をマニュアルで実施したりしなければならなくなれば、生産性を下げ、結局は費用増を通じて消費者の負担を増やすであろう²⁹。

Harrington (2019)や Calvano et al. (2020b) は、事業者に利用している価格決定アルゴリズムを提出させ、そのコードを調べることにより、あるいはテストデータを入力してアウトプットとして決定される価格の動向を調べることにより、共謀解をもたらすアルゴリズムが見つければそれを禁止すること、また、それでも当該アルゴリズムを使用する事業者がいれば共謀の意思があったとみなして競争法違反と判断することを提案している。しかし、これら論者も認めるように、アルゴリズムが共謀解を生むかどうかの認定は容易でない。実際、第4節で紹介したQ学習アルゴリズムによる価格決定はナッシュ解を上回る価格をもたらしたという意味で共謀解を生んでいるが、アルゴリズムそのものは企業価値最大化という当然の（そして反競争的とはいえない）企業目的を実現すべく設定されており、使用を禁止することは望ましくなく、現実的でもない。過剰に禁止すれば社会的効率性をもたらすはずのアルゴリズム利用を妨げることになろう。

データ処理の高速化は改善として受け入れつつ、また、価格規制を避けて事業者の自主的な経営を維持しつつ、協調的な解が広がるのを防ぐにはどのよ

²⁹ また、価格決定アルゴリズムの開発・維持にかかる費用は大きいですが、もう1社追加的な事業者が利用するときの費用という意味での限界費用は小さいことを考えれば、同一アルゴリズム提供者からのサービスの複数企業による利用を禁止することも望ましくない。開発されたアルゴリズムの社会的過少利用になるからである。

うな法と政策，社会設計が可能か，ハードルは大きい。

8.2. 企業結合規制への含意

カルテル規制という観点から競争法ができることは限定的としても，企業結合規制の観点からは，より明確な提言ができる。協調的行動の予防の重要性について，および問題解消措置の設計についてである。

最初に，「協調的行動による競争の実質的制限」について考えよう。公正取引委員会の企業結合ガイドラインが「当事会社グループとその競争者が協調的行動をとることにより当該商品の価格等がある程度自由に左右することができる状態が容易に現出し得るので，水平型企业結合が一定の取引分野における競争を実質的に制限することとなる。」という時の「協調的行動」は本稿で述べてきた意味での協調と合致している³⁰。前節までに紹介したシミュレーション分析や実験分析でも，この協調は企業数が少ないほどより顕著に現れることが示唆されている。したがって，企業結合がより協調的な行動を生む可能性は十分に存在し，慎重な審査が必要である³¹。

³⁰ 企業結合ガイドラインにおける以下の記述を見よ。「水平型企业結合によって競争単位の数が減少することに加え，当該一定の取引分野の集中度等の市場構造，商品の特性，取引慣行等から，各事業者が互いの行動を高い確度で予測することができるようになり，協調的な行動をとることが利益となる場合がある。このような場合，事業者甲の価格引上げに追随して他の事業者が商品の価格を引き上げたときに，例えば，事業者乙が当該商品の価格を引き上げないで売上げを拡大しようとしても，他の事業者が容易にそれを知り，それに対抗して当該商品の価格を元の価格まで引き下げ，あるいはそれ以上に引き下げて，奪われた売上げを取り戻そうとする可能性が高い。したがって，事業者乙が当該商品の価格を引き上げないことにより獲得できると見込まれる一時的な利益は，事業者甲に追随して価格を引き上げたときに見込まれるものより小さなものとなりやすい。このような状況が生み出される場合には，各事業者にとって，価格を引き上げないで売上げを拡大するのではなく互いに当該商品の価格を引き上げることが利益となり，当事会社グループとその競争者が協調的行動をとることにより当該商品の価格等がある程度自由に左右することができる状態が容易に現出し得るので，水平型企业結合が一定の取引分野における競争を実質的に制限することとなる。」

(公正取引委員会「企業結合審査に関する独占禁止法の運用指針」2019年改定，第4，1，(2))。

³¹ なお，参照したシミュレーション分析や実験分析のいずれでも，参入は考慮されておらず，企業数が固定されている。また実証分析の対象になったガソリン小売業も，需要が減少傾向にあり，新規参入は期待できない市場である。これに対し，超過利潤の存在が新規参入を促進すると期待されるような市場，すなわちコンテストブル市場であれば，共謀解は生まれにくいと予想される。よって企業結合審査においては，まず参入の可能性を評価し，十分

合併シミュレーション分析でも、協調的行動を前提にした方が企業結合の影響をより正確に予測できることを明らかにした研究が最近発表されている。例えば Björnerstedt and Verboven (2016)のスウェーデンの鎮痛剤市場における GSK（グラクソスミスクライン）と AZT（アストラゼネカ・ティカ）の合併の分析や、Miller and Weinberg (2017)の米国ビール市場におけるミラー（Miller）とクアーズ（Coors）のジョイントベンチャー（JV）による統合の分析である。前者では GSK と AZT および彼らの競争企業が合併前後を通じて協調行動をとり、後者では、統合後に誕生した JV の MillerCoors（業界 2 位）と統合前後を通じて業界首位の ABI が JV 発足後に協調行動をとるようになったとする仮定の下での分析が、企業結合前後ともナッシュ解が成立したとするときの分析よりも、現実にかきた事後的な価格変化をより正確に描写することが示されている³²。

これらの分析結果は、Q 学習シミュレーション分析や実験分析における、企業数が少ないほどナッシュ解からの乖離、独占解への接近という形での協調度の増加をもたらすという結果と整合的である。それだけに、企業結合審査において協調的行動への考慮をこれまで以上に重視する必要がある。結合前の市場において協調（結果としての共謀、あるいはナッシュ解からの乖離）が起きてはいなかったか、結合後に協調の度合いが強まるおそれはないか、十分な審査が必要である。

特に、Q 学習シミュレーション分析でも実験分析でも、複占では協調が高い確度で起きることが示されている。また、上記のスウェーデンや米国における実証に基づくシミュレーション分析でも、企業結合により上位 2 社の市場シェアが高まった事例を取り上げている。よって、企業結合により複占市場となる場合や上位 2 社のシェアが高まりリーダー的存在になることが予想される場合には、特に慎重な審査が必要であり、結合による協調度の増加を上回るような効率性の向上が確実に期待できるような状況でない限り、禁止されるべきであろう。

にコンテストナブルな市場ではないと判断された時に、単独行動および協調的行動による競争制限効果を評価することが必要になる。

³² これらの分析における協調のモデル化の詳細は 8.4 節で述べる。なお Miller らは別の論文（Miller et al, 2021）では、ABI をリーダーとするプライスリーダーシップ・モデルを用いて実証分析している。

8.3. 問題解消措置への含意

第2に、問題解消措置の設計にも重要な示唆がある。第5節の表5に示したように、HKSはベルトラン型の実験分析で、企業間が対称的なほどより独占解に近い共謀解が生まれることを示している。この他にも、

- Compte, Jenny and Rey (2002)は、企業間で対称的（生産能力が同規模）なほど、共謀が維持されやすいことを理論的に示した上で、1992年のボトルウォーター市場における企業結合を例にとり、EU当局が問題解消措置として認めた事業譲渡が上位2社の対称性を高めるものであったことを批判した³³。
- Igami and Sugaya (2022)は、1990年代の米国のビタミン・カルテルをモデル化し推定した上で、2001年に起きたBASFによる武田薬品のビタミン事業買収をその他の仮想的な事業者間の結合のシミュレーション分析と比較することで、企業間の対称性が高まる組み合わせほどカルテルの安定性（各社とも逸脱せずカルテル維持）が高まることを示した。

これらの結果は、企業間の対称性が高くなるような企業結合については特に協調的状況が生まれる可能性を懸念すべきこと、また問題解消措置の設計にあたっては、事業譲渡などによって上位企業間の対称性が強まることがないよう注意すべきことを示している。

8.4. 寡占理論への含意

最後に経済学への含意についても述べよう。多くの寡占市場で、現実には、価格や利潤がクールノー・モデルやベルトラン・モデルが予想するレベルを上回っている可能性が高いという事実は、これまでの寡占理論が現実を正しく記述してきたかどうかについて大きな疑問を投げかけるものである。筆者自身のものを含めほぼすべてのミクロ経済学や産業組織論の教科書は寡占理論としてクールノーやベルトランのモデルを教え、それが基準であり、カルテルや共謀はそれから逃れる不当な行為であると教えてきた。しかしながら、実際の寡占企業は意思の疎通なくしていわばお互いに忖度し合うことにより、共謀に近い解を実現しているのだとすれば、標準的寡占理論は現実を表して

³³ ネッスルのペリエ買収において、EU当局がボルビック（ペリエが保有していたブランド）の第2位企業BSNへの譲渡を問題解消措置とした上で承認したため、上位2社（ネッスル+ペリエボルビック、BSN+ボルビック）の規模がほぼ同一になったことが共謀の可能性を高めたと批判した。

いない可能性があることになる。このことを認識し、現実の市場に即したモデル構築に努力する必要がある。

悩ましいのは、現実が共謀解に近いとしても、それを特定することが困難なことである。ナッシュ解は最大化問題を解けば特定できる。しかし協調解を最大化問題の解として得ることには大きな障害がある。例えば、多くのシミュレーション分析、実験分析、実証分析からの最大公約数的な帰結として現実の価格はナッシュ解を $X\%$ 上回るといえたとしても、それはあくまでも平均で、市場条件その他によって変動するだろう。この点は行動経済学が抱える問題と共通する。例えば、ほとんどの個人は利子率（合理的個人が使うはずとされる割引率）を上回る率で将来利得を割り引くという事実が行動経済学における多くの実験や調査で明らかにされているが³⁴、どの率が実際に使われるかを特定することは困難である。

8.2 節で引用したスウェーデンと米国の 2 つの企業結合シミュレーション分析では、協調的行動を最大化問題として定式化するため、企業の目的関数として自社利潤に他社利潤に一定のウェイト ($\theta \leq 1$) を乗じたものを加えている。差別化寡占モデルで、合併前の i 社 ($i=1, 2, \dots$) はブランド i を販売し、合併後の合併会社は合併前からの両ブランドを販売するとしよう。 π_i をブランド i からの利潤とする。すると

☞ Björnerstedt and Verboven (2016) は、企業 1 (GSK) と企業 2 (AZT) が合併し、その他に企業 3 (複数社で可) があるとするれば、合併前の企業 1 は $\pi_1 + \theta(\pi_2 + \pi_3)$ を、企業 2 は $\pi_2 + \theta(\pi_1 + \pi_3)$ を最大化するのに対し、合併後企業は $\pi_1 + \pi_2 + \theta\pi_3$ を最大化すると仮定している。

☞ Miller and Weinberg (2017) は、企業 1 (Miller) と企業 2 (Coors) が統合し、その他に企業 3 (ABI) がトップ企業として存在するとして、合併前は各社とも自社利潤 π_i のみを最大化するが、統合後は統合会社 MillerCoors が $\pi_1 + \pi_2 + \theta\pi_3$ を、ABI (企業 3) が $\theta(\pi_1 + \pi_2) + \pi_3$ を最大化するものと仮定している。

θ は協調の強さを示しており、1 であれば結合利潤最大化として独占解をもたらし、0 であればナッシュ解をもたらす³⁵。現実にはその間の値をとると予

³⁴ 大竹 (2019) のいう現在バイアス。

³⁵ Miller and Weinberg (2017) では企業 1~3 以外にフリンジとして企業 4 等が存在する状況を考えており、これら企業は協調には加わっていないとして企業 1~3 の目的関数に π_4 を含まない。このため、 $\theta=1$ であっても完全な独占解にはならない。

想されるが、問題はそれをどう設定するかである。上記の分析は事後分析であり、推定モデルから θ を推定したり、いくつかの仮想的な θ の中から事後データに最も当てはまるシミュレーション結果を生み出すものを選択したりしている。しかし企業結合審査では、事前データのみからモデルを推定し、シミュレーションして合併後に価格がどう変わるかを予測しなければならない。この時にどのような θ の値を用いるべきか、難しい選択を迫られる。もちろん、事後研究が数多く蓄積されてくれば、それらの前例より類推することが可能になると期待されるが、それでも、経済状況により、業界を取り巻く諸環境により、あるいは経営者の特性により、 θ が変化することは十分に予想されるだけに、難しさは残る。

このように、競争政策の観点からも経済学研究の観点からも、より現実に沿った政策や理論の構築のためには理論・シミュレーション・実験・実証のいずれの方法によるにせよ、更なる研究が必要であり、直ちに結論が得られるわけではないであろうことを理解しつつも成果を積み重ね、一步でも現実的な解の特定に近づくための努力を続けるしかないことが理解されるであろう。

補論 価格決定アルゴリズムを提供する事業者たち

Assad, Clark, Ershov, and Xu (2021, ACEX)によれば、欧州のガソリン小売事業者（SS）の多くは2010年代になり、ソフトウェアとサービスの提供者による価格決定アルゴリズムを利用するようになった。こうしたアルゴリズム提供者としてACEXが例示する4事業者を、それぞれのホームページ（すべて2021年6月アクセス）で提供されている情報をもとに概観すれば以下の通りである（順不同）。

第1はa2i Systemsである³⁶。デンマーク最大のSS事業者であるOK Benzinより委託を受け、AIを利用した需要分析と価格決定のツールとして*PriceCast Fuel*を開発、2011年より利用開始。その後、OK Benzin以外にもサービス提供するようになった。

第2はKalibrateである³⁷。2011年にMarket Planning Solutions Inc. (MPSI, 1970年創業)とKSS Fuels（1993年創業）とが合併し2013年にKalibrateと社名変更した。もともと価格決定に関するサービスを提供していたのはKSS Fuelsである。

同社日本法人のホームページによれば、KSS Fuelsは「1990年代前半にガソリン価格の最適化の分野においてパイオニアとなっていました」。ただし現在では石油以外の小売り事業にもサービスを提供しているようで、本社ホームページがリストしている顧客の中には7-Elevenもあがっている。とはいえ中心はSSのようで、日本法人のサイトはSSでの価格設定を中心に説明して、「需要と供給の関係を最大限に活かして、貴社のポジションをより優位なものへ導きます。消費者のSS選考要因とその重み付けを理解し、貴社SSの価格変更によって影響を受ける競合SSを明確に把握し、最適な価格設定を行います。」と記している。

第3はKantifyである³⁸。同社ホームページはAI（人工知能）、ML（機械学習）を使った価格予測のサービスを提供しているとあり、価格設定アルゴリズムの提供とはしていないが、「価格は変動しやすく長期的にも予測困難です。KantifyはAIモデルを開発して、多くの機会に既存の予測を打ち負か

³⁶ 本社はデンマーク。 <https://www.a2isystems.com/pricecast/>

³⁷ 本社は英国。 <https://kalibrate.com/software/kalibrate-pricing/>。日本法人としてカリブレイトジャパン（株）がある。 <http://www.kalibrate.jp>

³⁸ 本社はベルギー。 <https://www.kantify.com>

してきました。私たちのモデルを貴社のデータ源に適用することで、Kantify はあなたの産業において貴社を、価格決定の主要要因を明らかにし、価格がどう変化していくかを予測し、それに基づいて価格決定をすることのできる唯一の存在とします」³⁹と記している。

第4はPDIである⁴⁰。1983年創業。最適な石油小売価格を提供するサービスとして *PDI Fuel Pricing Retail* を持ち、小売事業者に対し「利潤を最大化するために効果的な価格戦略を作る、市場の変化や現場のニーズに素早く適応する、データを収集・分析して貴社の市場におけるサイトをランク付けする、POSシステム・看板表示・給油ポンプ・モバイルをシームレスに統合する」ことの手助けをするとしている。また同社サービスは石油事業者以外にコンビニエンスストアなどでも利用されているようである。

このように、4社はいずれもアルゴリズム提供者、すなわち価格決定に関するソフトウェアあるいはサービスを提供している企業とみられる。いずれも何らかの形で AI や ML を用いていると推測されるが詳細は公表されていない。例えば Q 学習が使われているかどうかは不明である。

³⁹ <https://www.kantify.com/use-cases/price-prediction>。

⁴⁰ 本社は米国。 <https://www.pdisoftware.com/fuel-pricing-retail/>。

参考文献

- Abada, Ibrahim and Lambin, Xavier (2021) “Artificial Intelligence: Can Seemingly Collusive Outcomes Be Avoided?” *SSRN*, id 3559308.
- Albæk, Svend; Møllgaard, Peter; and Overgaard, Per B. (1997) “Government-Assisted Oligopoly Coordination?: A Concrete Case,” *Journal of Industrial Economics*, 45(4), 429-443.
- Asker, John; Fershtman, Chaim; and Pakes, Ariel (2021) “Artificial Intelligence and Pricing: The Impact of Algorithm Design,” *NBER Working Paper*, 28535.
- Assad, Stephanie; Clark, Robert; Ershov, Daniel; and Xu, Lei (2021) “Algorithmic Pricing and Competition: Empirical Evidence from the German Retail Gasoline Market,” https://economics.yale.edu/sites/default/files/clark_acex_jan_2021.pdf
- Autorité de la Concurrence and Bundeskartellamt (2019) “Algorithms and Competition,” 6 November.
- Baumol, William J.; Panzar, John C.; and Willig, Robert D. (1982) *Contestable Markets and the Theory of Industry Structure*. Harcourt Brace Jovanovich.
- Björnerstedt, Jonas and Verboven, Frank (2016), “Does Merger Simulation Work?: Evidence from the Swedish Analgesics Market,” *American Economic Journal: Applied Economics*, 8(3), 125-164.
- Brown, Zach Y. and MacKay, Alexander (2021) “Competition in Pricing Algorithm,” Harvard Business School Working Paper, 20-067.
- Byrne, David P. and De Roos, Nicolas (2019) “Learning to Coordinate: A Study in Retail Gasoline,” *American Economic Review*, 109(2), 591-619
- Calvano, Emilio; Calzolari, Giacomo; Denicolò, Vincenzo; and Pastorello, Sergio (2020a) “Artificial Intelligence, Algorithmic Pricing, and Collusion,” *American Economic Review*, 110(10), 3267-3297.
- Calvano, Emilio; Calzolari, Giacomo; Denicolò, Vincenzo; and Pastorello, Sergio (2020b), “Algorithmic Collusion: A Real Problem for Competition Policy?” *CPI Antitrust Chronicle*, July, 1-7.
- Calvano, Emilio; Calzolari, Giacomo; Denicolò, Vincenzo; and Pastorello, Sergio (2021) “Algorithmic Collusion with Imperfect Monitoring,” *International Journal of Industrial Organization*, 79, Article 102712, 1-11.
- Compte, Olivier; Jenny, Frédéric; and Rey, Patrick (2002) “Capacity Constraints,

- Mergers and Collusion,” *European Economic Review*, 46, 1-29.
- Ezrachi, Ariel and Stucke, Maurice E. (2016) *Virtual Competition*. Harvard University Press.
- Fischer, Christian and Normann, Hans-Theo (2019) “Collusion and Bargaining in Asymmetric Cournot Duopoly: An Experiment,” *European Economic Review*, 111, 360-379.
- Friedman, Daniel; Huck, Steffen; Oprea, Ryan; and Weidenholzer, Simon (2015) “From Imitation to Collusion: Long-Run Learning in a Low-Information Environment,” *Journal of Economic Theory*, 155, 185-205.
- Fudenberg, Drew and Tirole, Jean (1989) “Noncooperative Game Theory for Industrial Organization: An Introduction and Overview,” in Richard Schmalensee and Robert D. Willig [eds.] *Handbook of Industrial Organization*, Volume I, Elsevier, 259-327.
- Green, Edward J.; Marshall, Robert C.; and Marx, Leslie M. (2014) “Tacit Collusion in Oligopoly,” in Roger D. Blair and D. Daniel Sokol [eds.] *The Oxford Handbook of International Antitrust Economics*, Volume 2, Oxford University Press, DOI: 10.1093/oxfordhb/9780199388592.013.0019.
- Green, Edward J. and Porter, Robert H. (1984) “Noncooperative Collusion under Imperfect Price Information,” *Econometrica*, 52, 87-100.
- Harrington, Joseph E., Jr. (2019) “Developing Competition Law for Collusion by Autonomous Artificial Agents,” *Journal of Competition Law & Economics*, 14(3), 331-363.
- Harrington, Joseph E., Jr. (2021) “The Effect of Outsourcing Pricing Algorithms on Market Competition,” *SSRN*, id 3798847.
- Horstmann, Niklas; Krämer, Jan; and Schnurr, Daniel (2018) “Number Effects and Tacit Collusion in Experimental Oligopolies,” *Journal of Industrial Economics*, 66(3), 650-770.
- Huck, Steffen; Normann, Hans-Theo; and Oechssler, Jörg (2004) “Two Are Few and Four Are Many: Number Effects in Experimental Oligopolies,” *Journal of Economic Behavior and Organization*, 53, 435-446.
- Igami, Mitsuru and Sugaya, Takuo (2022) “Measuring the Incentive to Collude; The Vitamin Cartels, 1990-1999,” *Review of Economic Studies*, rdab 052, to appear.
- Johnson, Justin P.; Rhodes, Andrew; and Wildenbeest, Matthijs (2020) “Platform

- Design When Sellers Use Pricing Algorithms,” *SSRN*, id 3691621.
- Klein, Timo (2021) “Autonomous Algorithmic Collusion: Q-Learning under Sequential Pricing,” *Rand Journal of Economics*, 52(3), 538-599.
- Miller, Nathan H.; Sheu, Gloria; and Weinberg, Matthew C. (2021) “Oligopolistic Price Leadership and Mergers; The United States Beer Industry,” *American Economic Review*, 111(10), 3123-3159.
- Miller, Nathan H. and Weinberg, Matthew C. (2017) “Understanding the Price Effects of the MillerCoors Joint Venture,” *Econometrica*, 85(6), 1763-1791.
- Organization for Economic Co-operation and Development (OECD) (2017) “Algorithm and Collusion: Background Note by the Secretariat,” OECD DAF/COMP(2017)4.
- Slade, Margaret E. (1987) “Interfirm Rivalry in a Repeated Game: An Empirical Test of Tacit Collusion,” *Journal of Industrial Economics*, 35, 499-516
- Tobin, James (1969) “A General Equilibrium Approach to Monetary Theory,” *Journal of Money, Credit, and Banking*, 1, 15-29.
- Waltman, Ludo and Kaymak, Uzey (2008) “Q-Learning Agents in a Cournot Oligopoly Models,” *Journal of Economic Dynamics & Control*, 32, 3275-3293.
- Werner, Tobias (2021) “Algorithmic and Human Collusion,” *SSRN*, id 3960738.

- 大竹文雄 (2019) 『行動経済学の使い方』, 岩波新書。
- 小田切宏之 (2010) 『企業経済学』 第2版, 東洋経済新報社。
- 小田切宏之 (2019) 『産業組織論—理論・戦略・政策を学ぶ』, 有斐閣。
- 公正取引委員会 (2021) 「アルゴリズム/AIと競争政策」, デジタル市場における競争政策に関する研究会報告書, 3月31日。
- 曾我部東馬 (2019) 『強化学習アルゴリズム入門—「平均」からはじめる基礎と応用』, オーム社。

(注) *SSRN* = Social Science Research Network (<https://www.ssrn.com/>)

NBER = National Bureau of Economic Research (<https://www.nber.org/>)